aws

Management Guide

Amazon EMR

Amazon EMR: Management Guide

Table of Contents

Was ist Amazon EMR? 1
Übersicht 1
Verstehen von Clustern und Knoten 2
Übermitteln von Aufträgen an einen Cluster 3
Verarbeiten von Daten 3
Verstehen des Cluster-Lebenszyklus 5
Vorteile 7
Kosteneinsparungen 8
AWS-Integration 8
Bereitstellung 9
Skalierbarkeit und Flexibilität 9
Zuverlässigkeit 10
Sicherheit 11
Überwachung 13
Verwaltungsschnittstellen 13
Architektur 14
Speicher 14
Cluster-Ressourcenverwaltung 15
Datenverarbeitungs-Frameworks 16
Anwendungen und Programme 17
Einrichten von Amazon EMR 18
Registrieren für ein AWS-Konto 18
Einen Administratorbenutzer erstellen 18
Erstellen eines Amazon-EC2-Schlüsselpaares für SSH 19
Nächste Schritte 20
Erste Schritte-Tutorial 21
Übersicht 21
Schritt 1: Planen und Konfigurieren 22
Speicher für Amazon EMR vorbereiten 22
Bereiten Sie eine Anwendung mit Eingabedaten für Amazon EMR vor 23
Starten eines Amazon-EMR-Clusters 25
Schritt 2: Verwalten 29
Arbeit bei Amazon EMR einreichen 29
Ergebnisse anzeigen 35

Schritt 3: Bereinigen ... 40
So beenden Sie Ihren Cluster ... 40
Löschen von S3-Ressourcen ... 43
Nächste Schritte ... 43
Erkunden Sie Big-Data-Anwendungen für Amazon EMR ... 44
Planen Sie Cluster-Hardware, Netzwerke und Sicherheit ... 44
Verwalten von Clustern ... 44
Verwenden Sie eine andere Schnittstelle ... 44
Stöbern Sie im technischen Blog von EMR ... 44
Was ist neu an der Konsole? ... 45
In welcher Konsole bin ich? ... 45
Verwenden der alten Konsole ... 46
Zusammenfassung der Unterschiede ... 47
Cluster-Kompatibilität zwischen alter und neuer Konsole ... 47
Unterschiede beim Erstellen von Clustern ... 47
Unterschiede beim Auflisten und Suchen nach Clustern ... 49
Unterschiede beim Anzeigen oder Bearbeiten von Clusterdetails ... 51
Unterschiede bei der Arbeit mit Sicherheitskonfigurationen ... 52
Amazon EMR Studio ... 53
Schlüsselfeatures ... 53
Feature-Verlauf ... 54
Funktionsweise ... 55
Authentifizierung und Benutzeranmeldung ... 56
Zugriffskontrolle ... 59
Workspaces ... 60
Notebook-Speicher ... 61
Überlegungen ... 62
Überlegungen ... 62
Bekannte Probleme ... 63
Feature-Einschränkungen ... 65
Service Limits ... 65
Bewährte Methoden für VPC und Subnetze ... 65
Cluster-Voraussetzungen ... 66
EMR Studio konfigurieren ... 68
Administratorberechtigungen zum Erstellen eines EMR-Studios ... 69
Ein Amazon EMR Studio einrichten ... 74

Ein Studio verwalten ... 139
Den EMR-Studio-Netzwerkverkehr steuern ... 147
Cluster-Vorlagen erstellen ... 150
Zugriff und Berechtigungen für Git-basierte Repositorien ... 156
Spark-Aufträge optimieren ... 160
Verwenden Sie EMR Studio ... 161
Grundlagen von Workspace ... 162
Zusammenarbeit im Workspace ... 170
Einen Workspace mit einer Laufzeit-Rolle ausführen ... 173
Führen Sie Workspace-Notebooks programmgesteuert aus ... 179
Durchsuchen Sie Daten mit SQL Explorer ... 179
Ordnen Sie einen Computer einem Workspace zu ... 181
Git-Repositorys verknüpfen ... 188
Debuggen Sie Anwendungen und Aufträge ... 192
Installieren Sie Kernel und Bibliotheken ... 197
Magische Befehle ... 198
Verwenden Sie mehrsprachige Notebooks mit Spark-Kerneln ... 207
EMR-Notebooks ... 210
Notebooks in der neuen Konsole ... 211
Über den Übergang ... 211
Was müssen Sie als Nächstes tun? ... 212
Vorteile von Workspace ... 212
Erforderliche Berechtigungen ... 213
Überlegungen ... 214
Cluster-Voraussetzungen ... 215
Unterschiede in den Funktionalitäten nach Cluster-Release-Version ... 216
Limits für gleichzeitig angefügte EMR-Notebooks ... 217
Jupyter Notebook und Python-Versionen ... 218
Sicherheitsüberlegungen ... 218
Erstellen eines Notebook ... 218
Arbeiten mit EMR-Notebooks ... 222
Grundlegendes zum Notebook-Status ... 222
Arbeiten mit dem Notebook-Editor ... 224
Wechseln von Clustern ... 225
Löschen von Notebooks und Notebook-Dateien ... 226
Freigeben von Notebook-Dateien ... 227

Programmatische Ausführung 228
Übersicht 228
Berechtigungen 229
Einschränkungen 230
Beispiele 230
Beispiele für einen CLI-Befehl 231
Boto3-SDK-Beispielskript 237
Ruby-Beispielskript 240
Benutzer-Identitätswechsel für Spark 242
Einrichten der Spark-Benutzerkennung 242
Verwenden des Spark-Widgets für die Auftragsüberwachung 243
Sicherheit 244
Installieren und Verwenden von Kerneln und Bibliotheken 245
..... 246
Installieren von Kernels und Python-Bibliotheken auf einem Cluster-Primärknoten 246
Überlegungen und Einschränkungen bei Bibliotheken für Notebooks 249
Arbeiten mit Notebook-Bibliotheken 250
Verknüpfen von Git-basierten Repositorys mit EMR Notebooks 251
Voraussetzungen und Überlegungen 252
Hinzufügen eines Git-basierten Repositorys zu Amazon EMR 256
Aktualisieren oder Löschen eines Git-basierten Repositorys 259
Verknüpfen oder Aufheben der Verknüpfung eines Git-basierten Repositorys 260
Erstellen eines neuen Notebooks mit einem zugehörigen Git-Repository 263
Verwenden von Git-Repositorys in einem Notebook 264
Cluster planen und konfigurieren 266
Schnell einen Cluster starten 266
Cluster-Standort und Datenspeicher konfigurieren 268
Eine AWS-Region auswählen 268
Mit Storage- und Dateisystemen arbeiten 270
Eingabedaten vorbereiten 274
Einen Ausgabespeicherort konfigurieren 290
Primärknoten planen und konfigurieren 297
Unterstützte Anwendungen und Features 298
Amazon-EMR-Clustern mit mehreren Primärknoten starten 308
Amazon-EMR-Integration mit EC2-Platzierungsgruppen 311
Überlegungen und bewährte Methoden 317

EMR-Cluster auf AWS Outposts ... 319
Voraussetzungen ... 320
Einschränkungen ... 320
Überlegungen zur Netzwerkkonnektivität ... 321
Erstellen eines Amazon-EMR-Clusters auf einem AWS Outposts ... 321
EMR-Cluster in AWS Local Zones ... 323
Unterstützte Instance-Typen ... 324
Erstellen eines Amazon-EMR-Clusters auf Local Zones ... 324
Docker konfigurieren ... 326
Docker-Registrierungen ... 327
Konfigurieren von Docker-Registrierungen ... 328
YARN für den Zugriff auf Amazon ECR auf EMR 6.0.0 und früher konfigurieren ... 329
Steuern der Cluster-Beendigung ... 331
Konfigurieren eines Clusters zum Fortfahren oder Beenden nach der Schrittausführung ... 332
Verwenden einer Richtlinie zur automatischen Beendigung ... 336
Verwenden des Beendigungsschutzes ... 342
Arbeiten mit AMIs ... 351
Übersicht ... 351
Verwenden des Standard-AMI ... 352
Verwenden eines benutzerdefinierten AMI ... 385
Änderung der Amazon-Linux-Version beim Erstellen eines Clusters ... 399
Größenangabe des Amazon-EBS-Root-Gerät-Datenträgers ... 401
Konfigurieren der Cluster-Software ... 403
Erstellen Sie Bootstrap-Aktionen ... 404
Cluster-Hardware und Netzwerken konfigurieren ... 410
Grundsätzliches zu Knotentypen ... 411
Amazon-EC2-Instances konfigurieren ... 414
Konfigurieren der Cluster-Protokollierung und des Debuggings ... 865
Standardmäßige Protokolldateien ... 865
Archivieren von Protokolldateien in Amazon S3 ... 866
Protokollspeicherorte ... 872
Das Debugging-Tool aktivieren ... 873
Informationen zur Debugging-Option ... 876
Tag-Cluster ... 876
Tag (Markierung)-Einschränkungen ... 878
Markieren von Ressourcen für die Fakturierung ... 878

Hinzufügen von Tags zu einem Cluster ... 879
Tags in einem Cluster anzeigen ... 882
Tags aus einem Cluster entfernen ... 884
Treiber und Drittanbieter-Anwendungsintegration ... 885
Verwenden von Business-Intelligence-Tools in Amazon EMR ... 885
Sicherheit ... 887
Sicherheitskonfigurationen ... 887
Datenschutz ... 888
AWS Identity and Access Management mit Amazon EMR ... 888
Kerberos ... 888
Lake Formation ... 889
Secure Socket Shell (SSH) ... 889
Amazon EC2-Sicherheitsgruppen ... 889
Updates des standardmäßigen Amazon Linux AMI ... 889
Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden ... 890
Eine Sicherheitskonfiguration erstellen ... 891
Angabe einer Sicherheitskonfiguration für einen Cluster ... 921
Datenschutz ... 923
Verschlüsseln von Daten im Ruhezustand und im Transit ... 924
IAM mit Amazon EMR ... 939
Zielgruppe ... 939
Authentifizierung mit Identitäten ... 940
Verwalten des Zugriffs mit Richtlinien ... 944
Funktionsweise von Amazon EMR mit IAM ... 947
Schritte für Laufzeit-Rollen für Amazon EMR ... 955
Konfigurieren von Servicerollen für Amazon EMR ... 964
Beispiele für identitätsbasierte Richtlinien ... 1020
Authentifizieren von Cluster-Knoten ... 1060
Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen ... 1061
Verwendung der Kerberos-Authentifizierung ... 1061
Verwendung der LDAP-Authentifizierung ... 1102
Integrieren von Amazon EMR mit Lake Formation ... 1114
Wie Amazon EMR mit Lake Formation funktioniert ... 1115
Voraussetzungen ... 1116
Wie Amazon EMR mit Lake Formation funktioniert ... 1116
Hudi und Lake Formation ... 1120

Überlegungen 1122
Integrieren Sie Amazon EMR mit Apache Ranger 1122
Übersicht über Ranger 1123
Anwendungsunterstützung und Einschränkungen 1126
Amazon EMR für Apache Ranger einrichten 1129
Apache-Ranger-Plugins 1147
Fehlerbehebung für Apache Ranger 1176
Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen 1180
Arbeiten mit von Amazon EMR verwalteten Sicherheitsgruppen 1182
Arbeiten mit zusätzlichen Sicherheitsgruppen 1193
Angeben von Sicherheitsgruppen 1194
Sicherheitsgruppe für EMR Notebooks 1198
Blockieren des öffentlichen Zugriffs 1200
Compliance-Validierung 1208
Ausfallsicherheit 1208
Sicherheit der Infrastruktur 1209
Herstellen einer Verbindung mit Amazon EMR über einen Schnittstellen-VPC-Endpunkt ... 1210
Verwalten von Clustern 1215
Verbinden mit einem Cluster 1215
Bevor Sie sich verbinden 1216
Mit dem Primärknoten über SSH verbinden 1220
Übermitteln von Arbeit an einen Cluster 1247
Schritte mit der Konsole hinzufügen 1248
Schritte mit der CLI hinzufügen 1253
Ausführen mehrerer Schritte 1255
Anzeigen von Schritten 1256
Abbrechen von Schritten 1257
Einen Cluster anzeigen und überwachen 1259
Cluster-Status und -Details anzeigen 1260
Verbessertes Schritt-Debuggen 1268
Anwendungsverlauf anzeigen 1270
Anzeige von -Protokolldateien 1281
Anzeigen von Cluster-Instances in Amazon EC2 1287
CloudWatch-Ereignisse und Metriken 1288
Anzeigen von Cluster-Anwendungsmetriken mit Ganglia 1356
Protokollieren von Amazon-EMR-API-Aufrufen mit AWS CloudTrail 1356

Clusterskalierung verwenden 1359
Überlegungen 1361
Verwaltete Skalierung 1361
Auto Scaling mit einer benutzerdefinierten Richtlinie 1389
Die Größe eines aktiven Clusters anpassen 1402
Timeouts bei der Bereitstellung 1411
Cluster-Herunterskalierung 1416
Einen Cluster beenden 1421
Von der Konsole aus beenden 1422
Über CLI beenden 1423
Über API beenden 1424
Einen Cluster klonen 1425
Automatisieren wiederkehrender Cluster mit AWS Data Pipeline 1427
Fehlersuche bei Clustern 1428
Tools zur Fehlerbehebung 1428
Anzeigen von Cluster-Details 1429
Anzeigen von Fehlerdetails 1429
Führen Sie Skripts aus und konfigurieren Sie Prozesse 1430
Anzeige von -Protokolldateien 1430
Überwachen Sie die Leistung des Clusters 1431
Prozesse anzeigen und neu starten 1431
Anzeigen von ausgeführten Prozessen 1432
Beenden und Neustarten von Prozessen 1433
Häufige Fehler 1436
Fehlercodes 1437
Ressourcenfehler 1452
Fehler bei der Ein- und Ausgabe 1464
Berechtigungsfehler 1467
Hive-Cluster-Fehler 1468
VPC-Fehler 1470
Streaming-Cluster-Fehler 1474
Benutzerdefinierte JAR-Cluster-Fehler 1476
Fehler in AWS GovCloud (USA-West) 1476
Finden Sie einen fehlenden Cluster 1477
Fehlerbehebung für ausgefallene Cluster 1477
Schritt 1: Daten über das Problem sammeln 1478

Schritt 2: Die Umgebung prüfen ... 1479
Schritt 3: Die letzte Statusänderung überprüfen ... 1480
Schritt 4: Die Protokolldateien überprüfen ... 1481
Schritt 5: Den Cluster Schritt für Schritt testen ... 1482
Fehlerbehebung für langsame Cluster ... 1483
Schritt 1: Daten über das Problem sammeln ... 1484
Schritt 2: Die Umgebung prüfen ... 1485
Schritt 3: Die Protokolldateien prüfen ... 1486
Schritt 4: Den Zustand des Clusters und der Instance überprüfen ... 1488
Schritt 5: Nach gesperrten Gruppen suchen ... 1490
Schritt 6: Konfigurationseinstellungen überprüfen ... 1490
Schritt 7: Eingabedaten überprüfen ... 1494
Problembehandlung bei einem Lake-Formation-Cluster ... 1494
Der Zugriff auf den Data Lake ist nicht zulässig ... 1494
Sitzungsablauf ... 1494
Keine Berechtigungen für Benutzer in der angeforderten Tabelle ... 1495
Abfragen von kontenübergreifenden Daten, die mit Lake Formation geteilt wurden ... 1495
Einfügen in, Erstellen und Ändern von Tabellen ... 1496
Schreiben von Anwendungen, die Cluster starten und verwalten ... 1498
Umfassendes Amazon-EMR-Java-Quellcodebeispiel ... 1498
Grundlegende Konzepte für API-Aufrufe ... 1502
Endpunkte für Amazon EMR ... 1503
Angeben von Cluster-Parametern in Amazon EMR ... 1503
Availability Zones in Amazon EMR ... 1504
So verwenden Sie weitere Dateien und Bibliotheken in Amazon-EMR-Clustern ... 1504
So verwenden Sie SDKs zum Aufrufen von Amazon-EMR-APIs ... 1505
So erstellen Sie einen Amazon-EMR-Cluster mit der AWS SDK for Java ... 1505
Amazon EMR Service Quotas verwalten ... 1508
Was sind Amazon EMR Service Quotas? ... 1508
Amazon EMR Service Quotas verwalten ... 1509
Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden ... 1509
AWS-Glossar ... 1513

Was ist Amazon EMR?

Bei Amazon EMR (früher Amazon Elastic MapReduce genannt) handelt es sich um eine verwaltete Cluster-Plattform, die die Ausführung von Big-Data-Frameworks wie in Apache Hadoop und Apache Spark in AWS vereinfacht, um riesige Datenmengen zu verarbeiten und zu analysieren. Die Verwendung dieser Frameworks und verwandter Open-Source-Projekte, können Sie Daten zu Analysezwecken und Business-Intelligence-Workloads verarbeiten. Amazon EMR zum Transformieren und Verschieben lässt auch große Datenmengen in und aus anderen AWS-Datenspeichern und Datenbanken verwenden, wie z. B. Amazon Simple Storage Service (Amazon S3) und Amazon DynamoDB.

Wenn Sie Amazon EMR erstmalig verwenden, empfehlen wir, zusätzlich zu diesem Abschnitt die folgenden Abschnitte zu lesen:

- Amazon EMR – Auf dieser Service-Seite finden Sie die Highlights, Produktdetails und Preisinformationen.
- Tutorial: Erste Schritte mit Amazon EMR – Mit diesem Tutorial können Sie schnell mit Amazon EMR beginnen.

In diesem Abschnitt

- Übersicht über Amazon EMR
- Vorteile der Verwendung von Amazon EMR
- Überblick über die Amazon-EMR-Architektur

Übersicht über Amazon EMR

Dieses Thema bietet eine Übersicht über die Amazon-EMR-Cluster, einschließlich der Übermittlung von Aufträgen an einen Cluster, der Verarbeitung von Daten und der verschiedenen Status, die der Cluster während der Verarbeitung durchläuft.

In diesem Thema

- Verstehen von Clustern und Knoten
- Übermitteln von Aufträgen an einen Cluster
- Verarbeiten von Daten
- Verstehen des Cluster-Lebenszyklus

Verstehen von Clustern und Knoten

Die zentrale Komponente des Amazon EMR ist der Cluster. Ein Cluster ist eine Sammlung von Amazon Elastic Compute Cloud (Amazon EC2)-Instances. Jede Instance in einem Cluster wird als Knoten bezeichnet. Jeder Knoten verfügt über eine Rolle im Cluster – Knotentyp genannt. Amazon EMR installiert auch verschiedene Softwarekomponenten auf den einzelnen Knotentypen und überträgt so jedem Knoten eine Rolle in einer verteilten Anwendung wie Apache Hadoop.

Amazon EMR verfügt über die folgenden Knotentypen:

- Primärknoten: Knoten, der den Cluster durch die Ausführung von Softwarekomponenten verwaltet, die die Verteilung von Daten und Aufgaben auf andere Knoten zur Verarbeitung koordinieren. Der Primärknoten überwacht den Status der Aufgaben und überwacht den Zustand des Clusters. Jeder Cluster verfügt über einen Primärknoten und es ist möglich, einen Einzelknoten-Cluster nur mit dem Primärknoten zu erstellen.
- Core-Knoten: Knoten mit Software-Komponenten, die Aufgaben ausführen und Daten im HDFS (Hadoop Distributed File System) auf dem Cluster speichern. Multiknoten-Cluster enthalten mindestens einen Core-Knoten.
- Aufgabenknoten: Knoten mit Software-Komponenten, die nur Aufgaben ausführen und keine Daten in HDFS speichern. Aufgabenknoten sind optional.

Im folgenden Diagramm ist ein Cluster mit einem Primärknoten und vier Core-Knoten dargestellt.

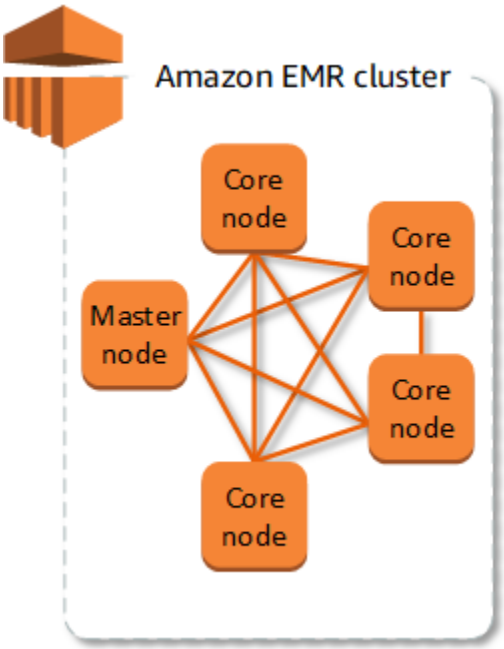

Übermitteln von Aufträgen an einen Cluster

Bei Ausführung eines Clusters in Amazon EMR haben Sie mehrere Möglichkeiten, die auszuführende Arbeit anzugeben.

- Stellen Sie die gesamte Definition der auszuführenden Arbeit in Funktionen bereit, die Sie als Schritte angeben, wenn Sie einen Cluster erstellen. Dies wird in der Regel für Cluster durchgeführt, die eine bestimmte Datenmenge verarbeiten und nach Abschluss der Verarbeitung beendet werden.
- Erstellen Sie einen langlebigen Cluster und verwenden Sie die Amazon-EMR-Konsole, die Amazon-EMR-API oder die AWS CLI, um die Schritte, die einzelne oder mehrere Aufträge umfassen können, zu übermitteln. Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.
- Erstellen Sie einen Cluster, stellen Sie nach Bedarf eine Verbindung zum Primärknoten und zu anderen Knoten mit SSH her und verwenden Sie die von den installierten Anwendungen bereitgestellten Schnittstellen, um Aufgaben auszuführen und Abfragen zu senden entweder in Skripts oder interaktiv. Weitere Informationen finden Sie im Handbuch zu Amazon-EMR-Versionen.

Verarbeiten von Daten

Wenn Sie einen Cluster starten, bestimmen Sie die zu installierenden Frameworks und Anwendungen, damit Ihren Anforderungen an die Datenverarbeitung entsprochen wird. Um Daten in Ihrem Amazon-EMR-Cluster zu verarbeiten, können Sie Aufträge oder Abfragen direkt an installierte Anwendungen senden oder alternativ die Schritte im Cluster ausführen.

Übermitteln von Aufträgen direkt an die Anwendungen

Sie können Aufträge direkt an die Software übermitteln, die auf Ihrem Amazon-EMR-Cluster installiert ist, und anschließend damit interagieren. Dazu stellen Sie in der Regel eine sichere Verbindung mit dem Primärknoten her und greifen auf die Schnittstellen und Tools zu, die für die Software, die direkt auf Ihrem Cluster ausgeführt wird, verfügbar sind. Weitere Informationen finden Sie unter Verbinden mit einem Cluster.

Ausführen von Schritten zur Verarbeitung von Daten

Sie können einem Amazon-EMR-Cluster einen oder mehrere angeordnete Schritte übermitteln. Jeder Schritt ist eine Arbeitseinheit mit Anweisungen zur Verarbeitung von Daten durch auf dem Cluster installierte Software.

Es folgt ein Beispiel für einen Prozess mit vier Schritten:

1. Übermitteln Sie die Eingabedatenmenge für die Verarbeitung.
2. Verarbeiten Sie die Ausgabe des ersten Schritts mithilfe eines Pig-Programms.
3. Verarbeiten Sie eine zweites Eingabedatenmenge mithilfe eines Hive-Programms.
4. Schreiben Sie einen Ausgabedatensatz.

Wenn Sie Daten in Amazon EMR verarbeiten, wird die Eingabe als Daten in Dateien gespeichert, die sich im zugrunde liegenden Dateisystem, wie z. B. Amazon S3 oder HDFS, befinden. Diese Daten werden während des Verarbeitungsablaufs von einem Schritt zum nächsten weitergeleitet. Im letzten Schritt werden die Ausgabedaten in einen bestimmten Speicherort geschrieben, wie zum Beispiel in einen Amazon-S3-Bucket.

Die Schritte werden in der folgenden Reihenfolge ausgeführt:

1. Eine Anfrage wird übermittelt, um mit den Verarbeitungsschritten zu beginnen.
2. Der Status aller Schritte wird auf PENDING (AUSSTEHEND) festgelegt.
3. Wenn der erste Schritt der Sequenz gestartet wird, wird dessen Status in RUNNING (WIRD AUSGEFÜHRT) geändert. Die anderen Schritte bleiben im Status PENDING (AUSSTEHEND).
4. Nachdem der erste Schritt abgeschlossen ist, wird dessen Status in COMPLETED (ABGESCHLOSSEN) geändert.
5. Der nächste Schritt der Sequenz wird gestartet und dessen Status wird in RUNNING (WIRD AUSGEFÜHRT) geändert. Nachdem er abgeschlossen ist, wird dessen dessen Status in COMPLETED (ABGESCHLOSSEN) geändert.
6. Dieses Muster wiederholt sich für jeden Schritt, bis alle Schritte abgeschlossen sind und die Verarbeitung beendet wird.

Das folgende Diagramm stellt die Schrittsequenz sowie die Statusänderung für die einzelnen Schritte während der Verarbeitung dar.

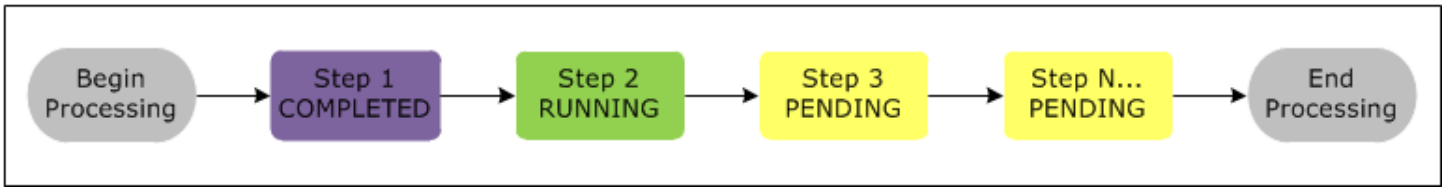

Wenn ein Schritt während der Verarbeitung fehlschlägt, wechselt der Status zu FEHLGESCHLAGEN. Sie können für jeden Schritt festlegen, was als Nächstes geschieht. Standardmäßig werden alle verbleibenden Schritte in der Sequenz auf ABGEBROCHEN festgelegt und wenn ein vorangehender Schritt fehlschlägt. Außerdem können Sie das Ignorieren des Fehlers aktivieren, damit die verbleibenden Schritte ausgeführt werden oder der Cluster sofort beendet wird.

Das folgende Diagramm stellt die Schrittsequenz sowie die standardmäßige Statusänderung dar, wenn ein Schritt während der Verarbeitung fehlschlägt.

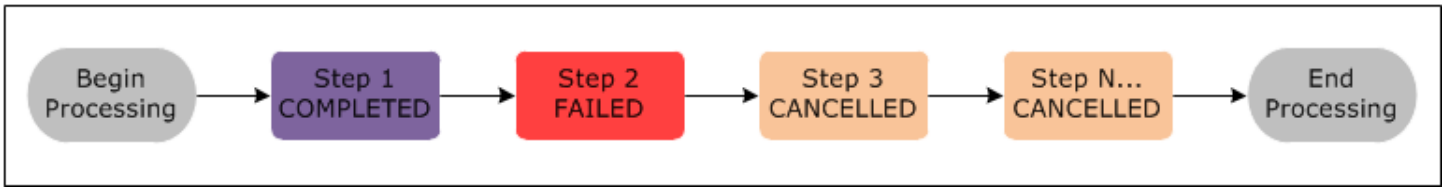

Verstehen des Cluster-Lebenszyklus

Ein erfolgreicher Amazon-EMR-Cluster befolgt diesen Prozess:

1. Amazon EMR stellt zunächst EC2-Instances im Cluster für jede Instance nach Maßgabe Ihrer Spezifikationen bereit. Weitere Informationen finden Sie unter Cluster-Hardware und Netzwerken konfigurieren. Amazon EMR verwendet für alle Instances das Standard-AMI für Amazon EMR oder ein von Ihnen angegebenes benutzerdefiniertes Amazon-Linux-AMI. Weitere Informationen finden Sie unter Verwenden eines benutzerdefinierten AMI. Während dieser Phase ist der Cluster-Status auf `STARTING` gesetzt.
2. Amazon EMR; führt Bootstrap-Aktionen aus, die Sie für jede Instance angeben. Sie können Bootstrap-Aktionen verwenden, um benutzerdefinierte Anwendungen zu installieren und erforderliche Anpassungen vorzunehmen. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software. Während dieser Phase ist der Cluster-Status auf `BOOTSTRAPPING` gesetzt.
3. Amazon EMR installiert die nativen Anwendungen, die Sie angeben, wenn Sie den Cluster erstellen, z. B. Hive, Hadoop, Spark usw.
4. Nachdem Bootstrap-Aktionen erfolgreich abgeschlossen und native Anwendungen installiert wurden, lautet der Cluster-Status `RUNNING`. An diesem Punkt können Sie die Verbindung zu Cluster-Instances herstellen. Der Cluster führt sequenziell die Schritte aus, die Sie beim Erstellen des Clusters angegeben haben. Sie können zusätzliche Schritte senden, die dann nach Abschluss der vorherigen Schritte ausgeführt werden. Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.

5. Nachdem die Schritte erfolgreich ausgeführt wurden, erhält der Cluster den Status `WAITING`. Wenn ein Cluster für die automatische Beendigung nach Abschluss des letzten Schritts konfiguriert ist, wechselt der Cluster den Status `TERMINATING`-Zustand und dann in den `TERMINATED`-Zustand. Wenn der Cluster so konfiguriert ist, dass er wartet, müssen Sie ihn manuell herunterfahren, wenn Sie ihn nicht mehr benötigen. Nachdem Sie den Cluster manuell beenden haben, wird dieser in den Status `TERMINATING` versetzt und danach in den Status `TERMINATED`.

Ein Fehler im Cluster-Lebenszyklus veranlasst, Amazon EMR den Cluster und dessen Instances zu beenden, sofern Sie nicht den Beendigungsschutz aktivieren. Wenn ein Cluster wegen eines Fehlers beendet wird, werden alle auf dem Cluster befindlichen Daten gelöscht und dem Cluster-Status wird der Status `TERMINATED_WITH_ERRORS` zugewiesen. Wenn Sie den Beendigungsschutz aktiviert haben, können Sie Daten vom Cluster abrufen und anschließend den Beendigungsschutz entfernen und den Cluster beenden. Weitere Informationen finden Sie unter Verwenden des Beendigungsschutzes.

Das folgende Diagramm stellt den Lebenszyklus eines Clusters dar und wie die einzelnen Lebenszyklusphasen einem bestimmten Cluster-Status zugeordnet sind.

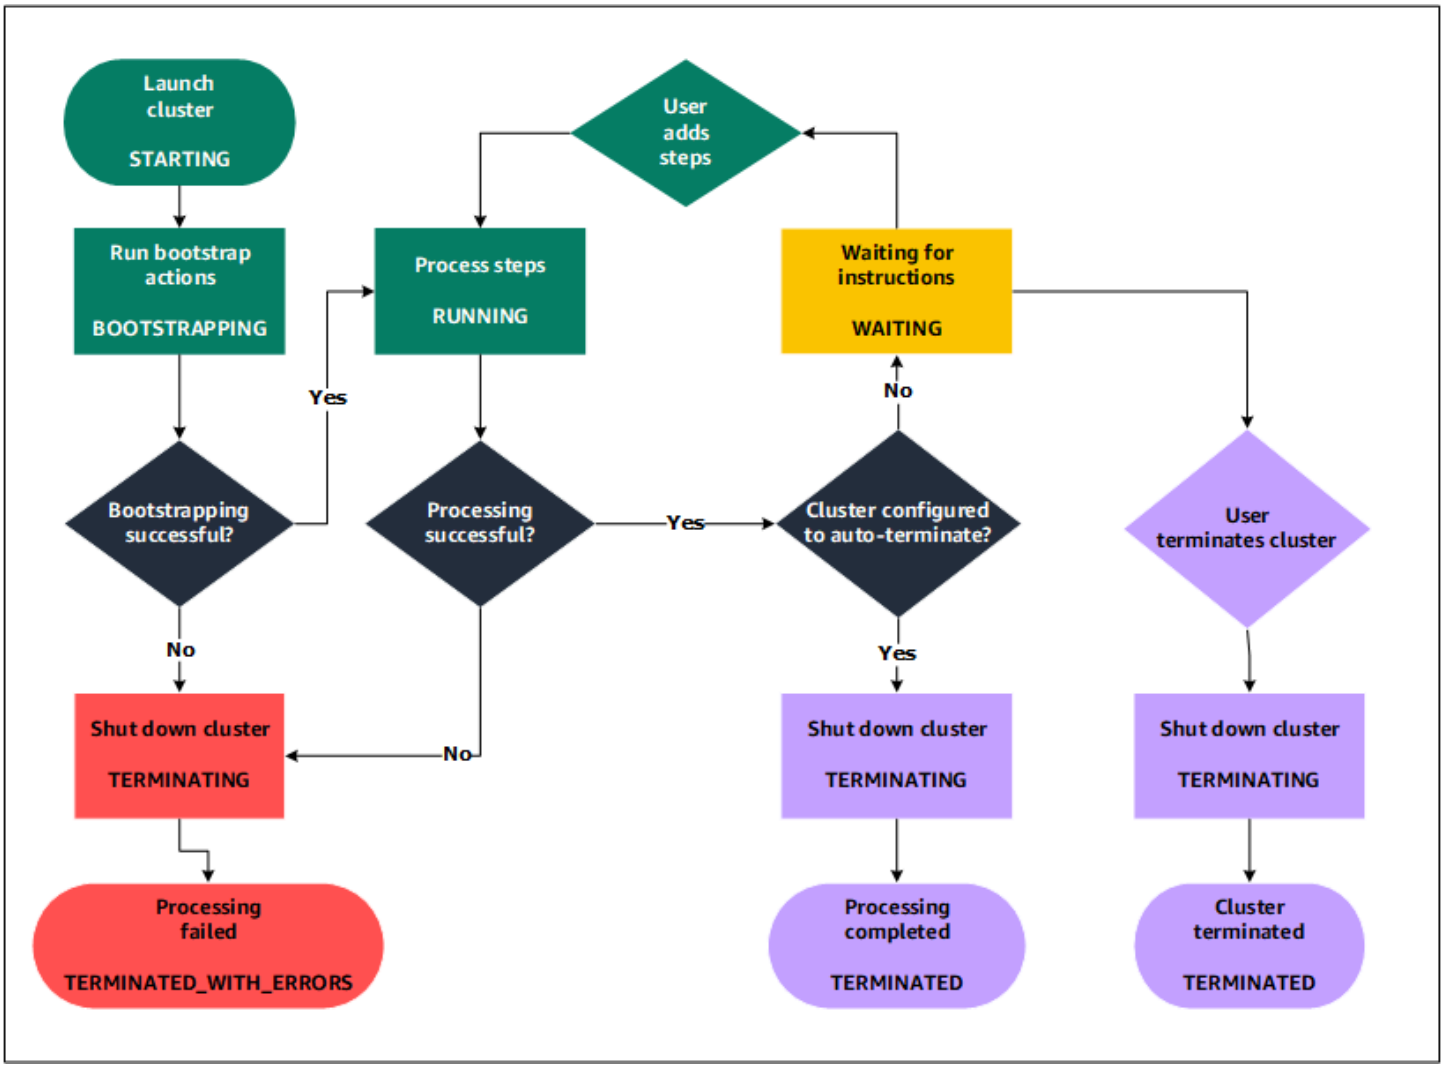

Vorteile der Verwendung von Amazon EMR

Es gibt zahlreiche Vorteile für die Verwendung von Amazon EMR. Dieser Abschnitt bietet eine Übersicht über die Vorteile und stellt Ihnen Links zu weiteren Informationen zur Verfügung.

Themen

- Kosteneinsparungen
- AWS-Integration
- Bereitstellung
- Skalierbarkeit und Flexibilität
- Zuverlässigkeit
- Sicherheit

- Überwachung
- Verwaltungsschnittstellen

Kosteneinsparungen

Amazon EMR Preisgestaltung richtet sich nach dem Instance-Typ und der Anzahl der Amazon-EC2-Instances, die Sie bereitstellen, sowie der Region, in der Sie den Cluster starten. On-Demand-Preise bieten einen niedrigen Stundensatz, allerdings können Sie die Kosten weiter senken, indem Sie Reserved Instances erwerben oder auf Spot-Instances bieten. Spot Instances können bedeutende Kostenersparnisse bieten – in einigen Fällen betragen sie nur ein Zehntel der On-Demand-Preise.

> **Note**
>
> Wenn Sie Amazon S3, Amazon Kinesis oder DynamoDB mit Ihrem EMR-Cluster verwenden, fallen für diese Services zusätzliche Gebühren an, die getrennt von Ihrer Amazon-EMR-Nutzung berechnet werden.

> **Note**
>
> Wenn Sie einen Amazon EMR-Cluster in einem privaten Subnetz einrichten, empfehlen wir, dass Sie auch VPC-Endpunkte für Amazon S3 einrichten. Wenn sich Ihr EMR-Cluster in einem privaten Subnetz ohne VPC-Endpunkte für Amazon S3 befindet, fallen zusätzliche NAT-Gateway-Gebühren an, die mit S3-Verkehr verbunden sind, da der Verkehr zwischen Ihrem EMR-Cluster und S3 nicht innerhalb Ihrer VPC verbleibt.

Weitere Informationen zu Preisoptionen und Details finden Sie unter Amazon-EMR-Preise.

AWS-Integration

Amazon EMR kann mit anderen AWS-Services integriert werden, um für den Cluster Funktionen und Funktionalität im Zusammenhang mit Netzwerk, Speicher, Sicherheit usw. bereitzustellen. In der folgenden Liste finden Sie einige Beispiele für diese Integration:

- Amazon EC2 für die Instances, die als Knoten im Cluster vorhanden sind
- Amazon Virtual Private Cloud (Amazon VPC) zur Konfiguration des virtuellen Netzwerks, in dem Sie Ihre Instances starten

- Amazon S3 zum Speichern von Ein- und Ausgabedaten
- Amazon CloudWatch zur Überwachung der Cluster-Leistung und Konfiguration von Alarmen
- AWS Identity and Access Management (IAM) zum Konfigurieren von Berechtigungen
- AWS CloudTrail zur Prüfung von Anfragen an den Service
- AWS Data Pipeline zum Planen und Starten Ihrer Cluster
- AWS Lake Formation, um Daten in einem Amazon S3 Data Lake zu entdecken, zu katalogisieren und zu sichern

Bereitstellung

Ihr EMR-Cluster besteht aus EC2-Instances, die die Aufgaben ausführen, die Sie Ihrem Cluster übermitteln. Wenn Sie einen Cluster starten, konfiguriert Amazon EMR die Instances mit den von Ihnen ausgewählten Anwendungen, wie beispielsweise Apache Hadoop oder Spark. Wählen Sie die Größe und den Typ der Instance aus, die am ehesten den Verarbeitungsanforderungen Ihres Clusters entsprechen: Stapelverarbeitung, schnelle Abfragen, Streaming-Daten oder große Datenspeicher. Weitere Informationen zu den für Amazon EMR verfügbaren Instance-Typen finden Sie unter Cluster-Hardware und Netzwerken konfigurieren.

Amazon EMR bietet verschiedene Möglichkeiten zum Konfigurieren von Software auf Ihrem Cluster. Sie können beispielsweise eine Amazon-EMR-Version installieren, die eine Reihe ausgewählter Anwendungen umfasst, einschließlich vielseitiger Frameworks wie Hadoop und Anwendungen, wie beispielsweise Hive, Pig oder Spark. Darüber hinaus können Sie auch eine der zahlreichen MapR-Verteilungen installieren. Amazon EMR verwendet Amazon Linux so können Sie auch Software unter Verwendung des Paket-Managers yum oder direkt von der Quelle manuell auf Ihrem Cluster installieren. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Software.

Skalierbarkeit und Flexibilität

Amazon EMR bietet Flexibilität, sodass Sie Ihren Cluster nach oben oder unten skalieren können, wenn sich Ihre Anforderungen an die Datenverarbeitung ändern. Sie können die Größe des Clusters ändern, um während Spitzenlastzeiten Instances hinzuzufügen, und um Instances zu entfernen, wenn die Spitzenlastzeiten nachlassen. So verfügen Sie über mehr Kontrolle über Ihre Kosten. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters.

Amazon EMR bietet außerdem die Option, mehrere Instance-Gruppen auszuführen. So können Sie sie in einer Gruppe On-Demand-Instances verwenden, um die Verarbeitungsleistung sicherzustellen,

während Sie in einer anderen Gruppe Spot Instances verwenden, um Ihre Aufträge schneller abzuschließen und Kosten zu senken. Sie können auch verschiedene Instance-Typen mischen, um die Preisvorteile von bestimmten Spot-Instance-Typen zu nutzen. Weitere Informationen finden Sie unter Wann sollten Sie Spot Instances verwenden?.

Darüber hinaus bietet Amazon EMR die Flexibilität, verschiedene Dateisysteme für Ihre Eingabe-, Ausgabe- und Zwischendaten zu verwenden. Für die Verarbeitung von Daten, die Sie nicht länger als den Lebenszyklus Ihres Clusters speichern müssen, können Sie beispielsweise das Hadoop Distributed File System (HDFS) auswählen, das auf den Primär- und Core-Knoten Ihres Clusters ausgeführt wird. Sie können möglicherweise auch das EMR File System (EMRFS) für die Verwendung mit Amazon S3 auswählen. Es kann als Daten-Layer für Anwendungen auf Ihrem Cluster dienen, sodass Sie die Datenverarbeitung und den Speicher trennen und Daten außerhalb des Lebenszyklus Ihres Clusters erhalten können. EMRFS bietet Ihnen die Möglichkeit, Ihre Anforderungen an die Datenverarbeitung und an den Speicher nach oben oder nach unten zu skalieren. Sie können Ihre Anforderungen an die Datenverarbeitung skalieren, indem Sie die Größe Ihres Clusters verändern, und Ihre Speicheranforderungen skalieren, indem Sie Amazon S3 verwenden. Weitere Informationen finden Sie unter Mit Storage- und Dateisystemen arbeiten.

Zuverlässigkeit

Amazon EMR; überwacht die Knoten in Ihrem Cluster und beendet und ersetzt eine Instance automatisch, wenn ein Fehler auftritt.

Amazon EMR bietet Konfigurationsoptionen, anhand denen Sie steuern, ob der Cluster beendet werden soll automatisch oder manuell. Wenn Sie Ihren Cluster so konfigurieren, dass er automatisch beendet wird, erfolgt das, nachdem alle Schritte abgeschlossen sind. Dies wird auch als vorübergehender Cluster bezeichnet. Sie können den Cluster jedoch auch so konfigurieren, dass er nach Abschluss der Verarbeitung weiter ausgeführt wird. Auf diese Weise können Sie ihn manuell beenden, wenn Sie ihn nicht länger benötigen. Alternativ können Sie einen Cluster erstellen, mit den installierten Anwendungen direkt interagieren und den Cluster, wenn Sie ihn nicht mehr benötigen, manuell beenden. Die Cluster in diesen Beispielen werden als langlebige Cluster bezeichnet.

Zusätzlich können Sie den Beendigungsschutz konfigurieren, um zu verhindern, dass Instances im Cluster aufgrund von Fehlern oder Problemen während der Verarbeitung beendet werden. Wenn der Beendigungsschutz aktiviert ist, können Sie die Daten vor der Beendigung von den Instances wiederherstellen. Die Standardeinstellungen für diese Optionen unterscheiden sich, je nachdem, ob Sie einen Cluster über die Konsole, die CLI oder die API starten. Weitere Informationen finden Sie unter Verwenden des Beendigungsschutzes.

Sicherheit

Amazon EMR nutzt AWS-Services, wie IAM und Amazon VPC und unterstützt Features wie Amazon-EC2-Schlüsselpaare, um Ihnen zu helfen, Ihre Cluster und Daten zu sichern.

IAM

Amazon EMR kann mit IAM integriert werden, um Berechtigungen zu verwalten. Sie definieren Berechtigungen mit IAM-Richtlinien, die Sie Benutzern oder IAM-Gruppen anfügen. Die Berechtigungen, die Sie in den Richtlinie definieren, legen fest, welche Aktionen diese Benutzer oder Gruppenmitglieder ausführen können, und auf welche Ressourcen sie zugreifen können. Weitere Informationen finden Sie unter Funktionsweise von Amazon EMR mit IAM.

Darüber hinaus verwendet Amazon EMR, IAM-Rollen für den Amazon EMR selbst und das EC2-Instance-Profil für die Instances. Diese Rollen erteilen dem Service und den Instances die Berechtigungen, in Ihrem Auftrag auf andere AWS-Services zuzugreifen. Es gibt sowohl für den Amazon-EMR-Service als auch für das EC2-Instance-Profil eine standardmäßige Rolle. Die Standardrollen verwenden von AWS verwaltete Richtlinien, die automatisch erstellt werden, wenn Sie das erste Mal einen EMR-Cluster über die Konsole starten und Standardberechtigungen auswählen. Sie können die IAM-Standardrollen auch über die AWS CLI erstellen. Wenn Sie die Berechtigungen lieber selber verwalten möchten, anstatt sie über AWS laufen zu lassen, können Sie für den Service und das Instance-Profil benutzerdefinierte Rollen auswählen. Weitere Informationen finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.

Sicherheitsgruppen

Amazon EMR verwendet Sicherheitsgruppen, um den ein- und ausgehenden Datenverkehr zu Ihren EC2-Instances zu steuern. Wenn Sie einen Cluster starten, verwendet Amazon EMR eine Sicherheitsgruppe für die primäre-Instance und eine Sicherheitsgruppe, die von den Core-/Aufgaben-Instances gemeinsam genutzt wird. Amazon EMR konfiguriert die Sicherheitsgruppenregeln, um die Kommunikation zwischen den Instances im Cluster sicherzustellen. Optional können Sie, falls Sie erweiterte Regeln benötigen, zusätzliche Sicherheitsgruppen konfigurieren und sie den primäre und Core-/Aufgaben-Instances zuweisen. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Verschlüsselung

Amazon EMR unterstützt die optionale Amazon S3 serverseitige und clientseitige Verschlüsselung mit EMRFS, um die von Ihnen in Amazon S3 gespeicherten Daten zu schützen. Bei der serverseitigen Verschlüsselung werden Ihre Daten von Amazon S3 nach dem Hochladen verschlüsselt.

Bei der clientseitigen Verschlüsselung erfolgt der Ver- und Entschlüsselungsvorgang im EMRFS-Client auf Ihrem EMR-Cluster. Sie verwalten den Stammschlüssel für die clientseitige Verschlüsselung über AWS Key Management Service (AWS KMS) oder Ihr eigenes Schlüsselverwaltungssystem.

Weitere Informationen finden Sie unter Amazon-S3-Verschlüsselung mithilfe von EMRFS-Eigenschaften angeben.

Amazon VPC

Amazon EMR unterstützt das Starten von Clustern in einer Virtual Private Cloud (VPC) in Amazon VPC. Eine VPC ist ein isoliertes, virtuelles Netzwerk in AWS, das die Möglichkeit bietet, erweiterte Aspekte der Netzwerkkonfiguration und des Zugriffs zu steuern. Weitere Informationen finden Sie unter Netzwerk konfigurieren.

AWS CloudTrail

Amazon EMR kann mit CloudTrail integriert werden, um Informationen zu Anfragen zu protokollieren, die von Ihrem AWS-Konto oder im Namen Ihres -Kontos gesendet wurden. Anhand dieser Informationen können Sie verfolgen, wer wann auf Ihr Cluster zugreift sowie die IP-Adresse, von der die Anforderung gestellt wird. Weitere Informationen finden Sie unter Protokollieren von Amazon-EMR-API-Aufrufen mit AWS CloudTrail.

Amazon-EC2-Schlüsselpaare

Indem Sie eine sichere Verbindung zwischen Ihrem Remotecomputer und dem Primärknoten herstellen, können Sie Ihren Cluster überwachen und damit interagieren. Sie verwenden das Netzwerkprotokoll Secure Shell (SSH) für diese Verbindung oder Kerberos für die Authentifizierung. Wenn Sie SSH verwenden, ist ein Amazon-EC2-Schlüsselpaar erforderlich. Weitere Informationen finden Sie unter Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen.

Überwachung

Sie können die Amazon-EMR-Management-Schnittstellen und Protokolldateien verwenden, um Probleme mit dem Cluster zu beheben, z. B. bei Ausfällen oder Fehlern. Amazon EMR bietet die Möglichkeit, Protokolldateien in Amazon S3 zu archivieren, sodass Sie Protokolle speichern und Probleme beheben können, auch nachdem der Cluster beendet wurde. Amazon EMR bietet in der Amazon-EMR-Konsole auch ein optionales Debugging-Tool, mit dem Sie die Protokolldateien im Hinblick auf Schritte, Aufträge und Aufgaben durchsuchen können. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings.

Amazon EMR kann mit CloudWatch integriert werden, um Leistungsmetriken für den Cluster und für Aufträge innerhalb des Clusters nachzuverfolgen. Sie können Alarme im Hinblick auf eine Vielzahl von Metriken konfigurieren, z. B. ob der Cluster inaktiv ist oder wie viel Prozent des Speicherplatzes verbraucht wurden. Weitere Informationen finden Sie unter Überwachung von Amazon-EMR-Metriken mit CloudWatch.

Verwaltungsschnittstellen

Es gibt mehrere Möglichkeiten, mit Amazon EMR zu interagieren:

- Konsole – eine grafische Benutzerschnittstelle, die Sie verwenden können, um Clusters zu starten oder zu verwalten. Hier füllen Sie Webformulare aus, um Detaildaten zum Starten von Clusters anzugeben, Detaildaten von vorhandenen Clusters anzuzeigen und Clusters zu debuggen bzw. zu beenden. Die Konsole bietet die einfachste Möglichkeit für die ersten Schritte mit Amazon EMR keine Programmierkenntnisse erforderlich. Die Konsole ist online unter https://console.aws.amazon.com/elasticmapreduce/home verfügbar.
- AWS Command Line Interface (AWS CLI) – eine Client-Anwendung, die Sie auf Ihrem lokalen Rechner ausführen, um eine Verbindung zu Amazon EMR herzustellen sowie Cluster zu erstellen und zu verwalten. Die AWS CLI enthält einen featurereichen Satz von Befehlen speziell für Amazon EMR. Damit schreiben Sie Skripts, die das Starten und Verwalten der Clusters automatisieren. Die AWS CLI ist die beste Option, wenn Sie es vorziehen, von einer Befehlszeile aus zu arbeiten. Weitere Informationen und Beispiele finden Sie unter Amazon EMR in der AWS CLI-Befehlsreferenz.
- Software Development Kit (SDK) – SDKs stellt Funktionen bereit, die Amazon EMR aufrufen, um Clusters zu erstellen und zu verwalten. Mit ihnen können Sie Anwendungen schreiben, die das Erstellen und Verwalten von Clusters automatisieren. Die Verwendung des SDK ist die beste Option, wenn Sie die Funktionen von Amazon EMR erweitern oder anpassen möchten. Amazon EMR ist derzeit in den folgenden SDKs verfügbar: Go, Java, .NET (C# und VB.NET), Node.js,

PHP, Python und Ruby. Weitere Informationen über diese SDKs, finden Sie unter Tools für AWS und Amazon-EMR-Beispielcode und -Bibliotheken.

- Web Service API – eine Low-Level-Schnittstelle, die Sie benutzen können, um den Webservice direkt mithilfe von JSON aufzurufen. Die Verwendung der API ist die beste Option, wenn Sie ein eigenes SDK erstellen wollen, das Amazon EMR aufruft. Weitere Informationen finden Sie in der Amazon-EMR-API-Referenz.

Überblick über die Amazon-EMR-Architektur

Die Service-Architektur von Amazon EMR besteht aus mehreren Ebenen, die dem Cluster jeweils bestimmte Möglichkeiten und Funktionen bereitstellen. Dieser Abschnitt bietet eine Übersicht über die jeweiligen Ebenen und Komponenten.

In diesem Thema

- Speicher
- Cluster-Ressourcenverwaltung
- Datenverarbeitungs-Frameworks
- Anwendungen und Programme

Speicher

Die Speicherschicht umfasst die verschiedenen Dateisysteme, die Sie in Ihrem Cluster verwendet werden. Es gibt mehrere verschiedene Speicheroptionen wie nachfolgend beschrieben.

Hadoop Distributed File System (HDFS)

Hadoop Distributed File System (HDFS) ist ein verteiltes, skalierbares Dateisystem für Hadoop. HDFS verteilt die auf verschiedenen Instances im Cluster gespeicherten Daten, wobei mehrere Kopien von Daten auf unterschiedlichen Instances gespeichert werden, um sicherzustellen, dass bei Ausfall einer einzelnen Instance keine Daten verloren gehen. HDFS ist flüchtiger Speicher, der zurückgefordert wird, wenn Sie einen Cluster beenden. HDFS ist nützlich für das Speichern von Zwischenergebnissen während der MapReduce-Verarbeitung oder für Workloads, die eine erhebliche zufällige E/-A-Leistung aufweisen.

Weitere Informationen finden Sie unter Instance-Speicher im HDFS-Benutzerhandbuch auf der Website von Apache Hadoop.

EMR File System (EMRFS)

Amazon EMR erweitert mittels des EMR File System (EMRFS) Hadoop durch die Hinzufügung des direkten Zugriffs auf in Amazon S3 gespeicherte Daten, als ob es sich um ein Dateisystem wie HDFS handeln würde. Sie können entweder HDFS oder Amazon S3 als das Dateisystem Ihres Clusters verwenden. In der Regel wird Amazon S3 zum Speichern der Ein- und Ausgabedaten verwendet, Zwischenergebnisse werden in HDFS gespeichert.

Lokales Dateisystem

Das lokale Dateisystem bezieht sich auf einen lokal verbundenen Datenträger. Wenn Sie einen Hadoop-Cluster erstellen, werden die einzelnen Knoten aus einer Amazon-EC2-Instance erstellt, die einen vorkonfigurierten Block mit bereits zugeordnetem Festplattenspeicher, einen sogenannten Instance-Speicher, aufweist. Die Daten auf den Instance-Speicher-Volumes bleiben nur während des Lebenszyklus der Amazon-EC2-Instance erhalten.

Cluster-Ressourcenverwaltung

Der Ressourcenverwaltungs-Layer ist verantwortlich für die Verwaltung der Cluster-Ressourcen und die Planung der Aufträge für die Datenverarbeitung.

Amazon EMR verwendet standardmäßig YARN (Yet Another Resource Negotiator). Dabei handelt es sich um eine Komponente, die in Apache Hadoop 2.0 eingeführt wurde und mit der die Cluster-Ressourcen für mehrere Datenverarbeitungs-Frameworks zentral verwaltet werden können. Es gibt jedoch auch andere Frameworks und Anwendungen, die in Amazon EMR bereitgestellt werden und nicht YARN als Ressourcenmanager verwenden. Amazon EMR verfügt außerdem auf jedem Knoten, der YARN-Komponenten verwaltet, über einen Agenten, der den Cluster stabil erhält und mit dem Amazon-EMR-Service kommuniziert.

Da Spot Instances häufig zum Ausführen von Aufgabenknoten verwendet werden, verfügt Amazon EMR über Standardfunktionen für die Planung von YARN-Aufträge, sodass laufende Aufträge nicht fehlschlagen, wenn Aufgabenknoten, die auf Spot Instances ausgeführt werden, beendet werden. Amazon EMR ermöglicht dies, indem Anwendungsmasterprozesse nur auf Core-Knoten ausgeführt werden können. Der Anwendungsmasterprozess steuert die Ausführung von Aufträgen und muss während der gesamten Laufzeit des Auftrags aktiv bleiben.

Amazon-EMR-Version 5.19.0 und höher verwendet zu diesem Zweck das integrierte YARN-Knotenbeschriftungsfeature. (Frühere Versionen verwendeten einen Code-Patch). Die Eigenschaften in den Klassifizierungen `yarn-site` und in der `capacity-scheduler`-Konfiguration sind

standardmäßig so konfiguriert, dass der YARN-Kapazitätsplaner und der Fair-Scheduler die Vorteile von Knotenbezeichnungen nutzen. Amazon EMR kennzeichnet Core-Knoten automatisch mit dem `CORE`-Label und legt Eigenschaften fest, sodass Anwendungsmaster nur für Knoten mit dem CORE-Label geplant werden. Durch manuelles Ändern verwandter Eigenschaften in den Konfigurationsklassifizierungen von Yarn-Site und Kapazitätsplaner oder direkt in den zugehörigen XML-Dateien könnte diese Feature beeinträchtigt oder verändert werden.

Datenverarbeitungs-Frameworks

Der Datenverarbeitungs-Framework-Layer ist die Engine, die zur Verarbeitung und Analyse der Daten verwendet wird. Es stehen viele Frameworks zur Verfügung, die auf YARN ausgeführt werden oder über ihre eigene Ressourcenverwaltung verfügen. Es gibt unterschiedliche Frameworks für die verschiedenen Verarbeitungsanforderungen, beispielsweise Stapel, Interaktiv, In-Memory, Streaming und so weiter. Das Framework, das Sie auswählen sollten, hängt von Ihrem Anwendungsfall ab. Dies wirkt sich auf die Sprachen und Schnittstellen der Anwendungsebene aus, d. h. der Ebene, über die mit den zu verarbeitenden Daten interagiert wird. Die hauptsächlichen Verarbeitungs-Frameworks für Amazon EMR sind Hadoop MapReduce und Spark.

Hadoop MapReduce

Hadoop MapReduce ist ein Open-Source-Programmiermodell für die verteilte Datenverarbeitung. Es vereinfacht den Prozess der Entwicklung paralleler verteilter Anwendungen, indem die gesamte Logik gehandhabt wird, während Sie die Funktionen "Map" und "Reduce" bereitstellen. Die Funktion "Map" führt eine Zuordnung von Daten und Sätzen von Schlüssel/Wert-Paaren durch, die als Zwischenergebnisse bezeichnet werden. Die Funktion "Reduce" kombiniert die Zwischenergebnisse, wendet weitere Algorithmen an und generiert das Endergebnis. Für MapReduce stehen mehrere Frameworks zur Verfügung, darunter auch Hive, das automatisch Map-und Reduce-Programme generiert.

Weitere Informationen finden Sie unter Wie Karten- und Reduziervorgänge tatsächlich ausgeführt werden auf der Wiki-Website von Apache Hadoop.

Apache Spark

Spark ist ein Cluster-Framework und Programmiermodell für die Verarbeitung von Big-Data-Workloads. Spark ist, genau wie Hadoop MapReduce, ein verteiltes Open-Source-Verarbeitungssystem. Es verwendet jedoch für die Ausführungspläne azyklische Graphen und nutzt für die Datensätze In-Memory-Caching. Wenn Sie Spark auf Amazon EMR ausführen, können Sie

über EMRFS direkt auf Ihre Daten in Amazon S3 zugreifen. Spark unterstützt mehrere interaktive Abfragen Module wie beispielsweise SparkSQL.

Weitere Informationen finden Sie unter Apache Spark in Amazon-EMR-Clusters in den Amazon-EMR-Versionshinweise.

Anwendungen und Programme

Amazon EMR unterstützt zahlreiche Anwendungen, wie Hive, Pig, und die Spark Streaming-Bibliothek, um beispielsweise mithilfe komplexerer Programmiersprachen Verarbeitungs-Workloads zu erstellen, Machine-Learning-Algorithmen zu nutzen, Anwendungen für die Stream-Verarbeitung zu erstellen und Data Warehouses zu entwickeln. Darüber hinaus unterstützt Amazon EMR auch Open-Source-Projekte, die ihre eigene Cluster-Management-Funktionalität mitbringen und nicht YARN verwenden.

Sie können verschiedene Bibliotheken und Sprachen verwenden, um mit den Anwendungen, die Sie in Amazon EMR ausführen, zu interagieren. Sie können beispielsweise Java, Hive oder Pig mit MapReduce oder Spark Streaming, Spark SQL, MLlib und GraphX mit Spark verwenden.

Weitere Informationen finden Sie im Handbuch zu Amazon-EMR-Versionen.

Einrichten von Amazon EMR

Führen Sie die Aufgaben in diesem Abschnitt aus, bevor Sie einen Amazon-EMR-Cluster zum ersten Mal starten:

Bevor Sie Amazon EMR zum ersten Mal verwenden, führen Sie die folgenden Schritte aus:

Registrieren für ein AWS-Konto

Wenn Sie kein AWS-Konto haben, führen Sie die folgenden Schritte zum Erstellen durch.

Anmeldung für ein AWS-Konto

1. Öffnen Sie https://portal.aws.amazon.com/billing/signup.
2. Folgen Sie den Online-Anweisungen.

   Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

   Wenn Sie sich für ein AWS-Konto anmelden, wird ein Root-Benutzer des AWS-Kontos erstellt. Der Stammbenutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Methode zur Gewährleistung der Sicherheit sollten Sie den administrativen Zugriff einem administrativen Benutzer zuweisen und nur den Root-Benutzer verwenden, um Aufgaben auszuführen, die einen Root-Benutzerzugriff erfordern.

AWS sendet Ihnen eine Bestätigungs-E-Mail, sobald die Registrierung abgeschlossen ist. Sie können jederzeit Ihre aktuelle Kontoaktivität anzeigen und Ihr Konto verwalten. Rufen Sie dazu https://aws.amazon.com/ auf und klicken Sie auf Mein Konto.

Einen Administratorbenutzer erstellen

Nachdem Sie sich für ein AWS-Konto registriert haben, erstellen Sie einen Administratorbenutzer, damit Sie nicht den Root-Benutzer für alltägliche Aufgaben verwenden.

Schützen Ihres Root-Benutzer des AWS-Kontos

1. Melden Sie sich bei der AWS Management Console als Kontobesitzer an, indem Sie Stammbenutzer auswählen und Ihre AWS-Konto-E-Mail-Adresse eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

   Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter Anmelden als Root-Benutzer im Benutzerhandbuch zu AWS-Anmeldung.
2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

   Anweisungen dazu finden Sie unter Aktivieren eines virtuellen MFA-Geräts für den Root-Benutzer Ihres AWS-Konto (Konsole) im IAM-Benutzerhandbuch.

Einen Administratorbenutzer erstellen

- Weisen Sie einem Administratorbenutzer in AWS IAM Identity Center Administratorzugriff für Ihre täglichen administrativen Aufgaben zu.

  Anleitungen dazu finden Sie unter Erste Schritte im AWS IAM Identity Center-Benutzerhandbuch.

Als Administratorbenutzer anmelden

- Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

  Hilfe bei der Anmeldung mit einem IAM-Identity-Center-Benutzer finden Sie unter Anmelden beim AWS-Zugangsportal im Benutzerhandbuch zu AWS-Anmeldung.

Erstellen eines Amazon-EC2-Schlüsselpaares für SSH

> **Note**
>
> Mit Amazon-EMR-Version 5.10.0 oder höher können Sie Kerberos zur Authentifizierung von Benutzern und SSH-Verbindungen zu einem Cluster konfigurieren. Weitere Informationen finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.

Um die Knoten in einem Cluster über einen sicheren Kanal mithilfe des Secure Shell (SSH)-Protokolls zu authentifizieren und eine Verbindung zu ihnen herzustellen, erstellen Sie ein Amazon Elastic Compute Cloud (Amazon EC2)-Schlüsselpaar, bevor Sie den Cluster starten. Außerdem können Sie auch einen Cluster ohne ein Schlüsselpaar erstellen. Dies geschieht normalerweise mit vorübergehenden Clusters, die starten, gewisse Schritte ausführen und dann automatisch beendet werden.

Wenn …	Dann …
Sie haben bereits ein Amazon-EC2-Schlüsselpaar, das Sie verwenden möchten, oder Sie müssen sich nicht bei Ihrem Cluster authentifizieren.	Überspringen Sie diesen Schritt.
Sie müssen ein Schlüsselpaar erstellen.	Sehen Sie unter Erstellen Ihres Schlüsselpaares mithilfe von Amazon EC2.

Nächste Schritte

- Hinweise zur Erstellung eines Beispielclusters finden Sie unter Tutorial: Erste Schritte mit Amazon EMR.
- Weitere Informationen zur Konfiguration eines benutzerdefinierten Clusters und zur Steuerung des Zugriffs darauf finden Sie unter Cluster planen und konfigurieren und Sicherheit in Amazon EMR.

Tutorial: Erste Schritte mit Amazon EMR

Übersicht

Mit Amazon EMR können Sie in nur wenigen Minuten einen Cluster einrichten, um Daten mit Big-Data-Frameworks zu verarbeiten und zu analysieren. Dieses Tutorial zeigt Ihnen, wie Sie einen Beispielcluster mit Spark starten und wie Sie ein einfaches PySpark-Skript ausführen, das in einem Amazon-S3-Bucket gespeichert ist. Es behandelt wichtige Amazon-EMR-Aufgaben in drei Workflow-Hauptkategorien: Planen und Konfigurieren, Verwalten und Aufräumen.

Während Sie das Tutorial durcharbeiten, finden Sie Links zu detaillierteren Themen und im Nächste Schritte Abschnitt Ideen für weitere Schritte. Bei weiteren Fragen oder Problemen können Sie sich an das Amazon-EMR-Team wenden, indem Sie einen Beitrag im Diskussionsforum veröffentlichen.

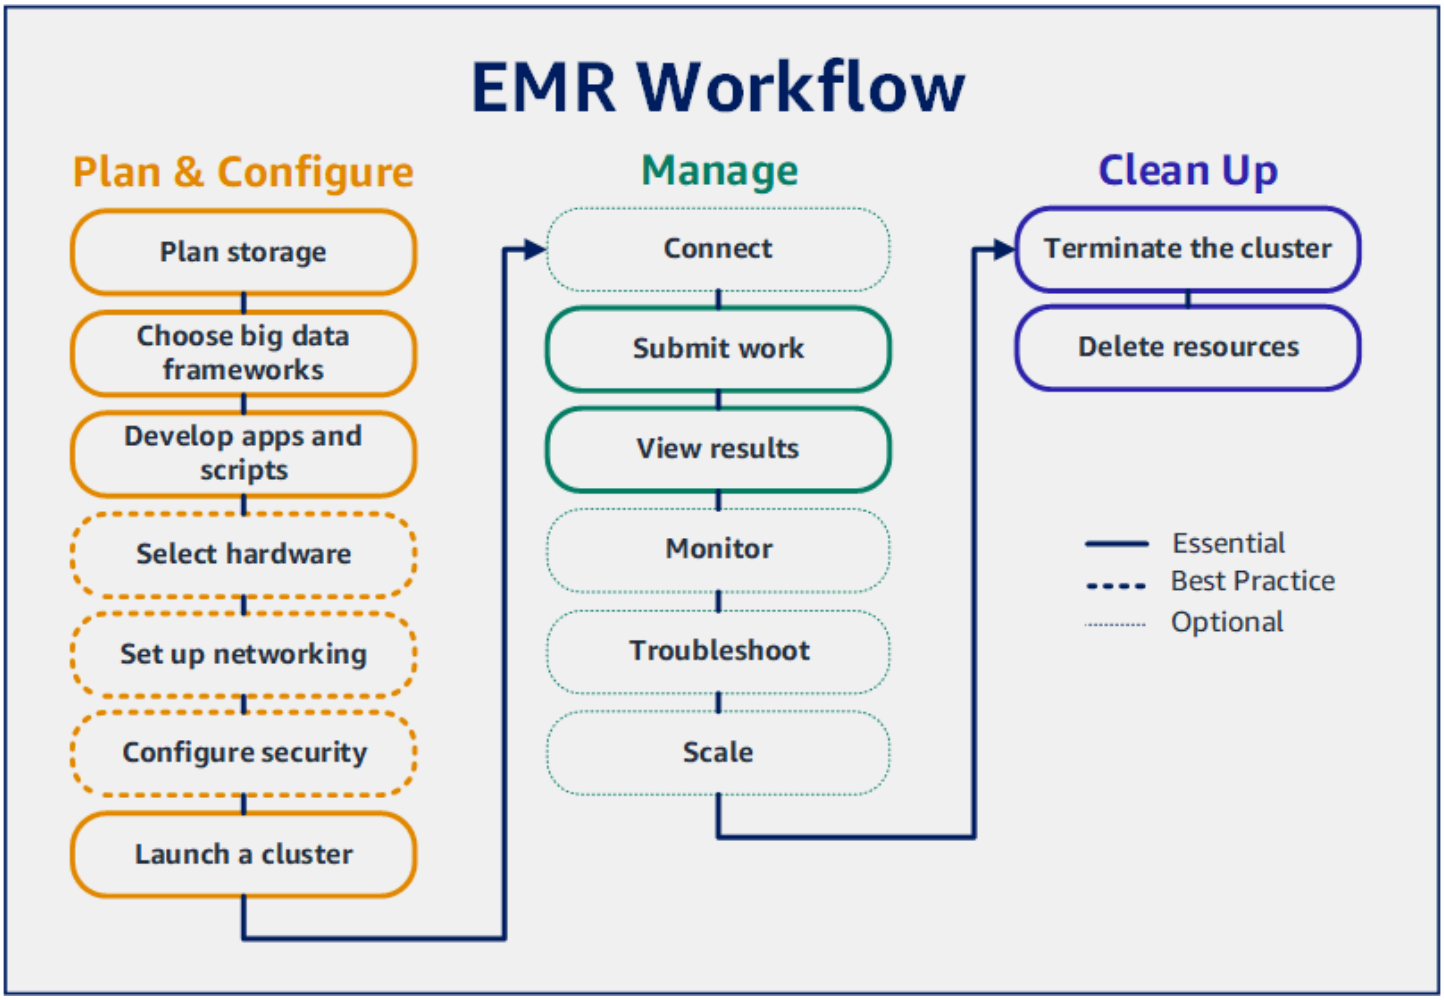

Voraussetzungen

- Stellen Sie vor dem Starten eines Amazon-EMR-Clusters sicher, dass Sie die Aufgaben unter Einrichten von Amazon EMR ausführen.

Kosten

- Der erstellte Beispiel-Cluster wird in einer Live-Umgebung ausgeführt. Für den Cluster fallen nur minimale Gebühren an. Stellen Sie sicher, dass Sie die Bereinigungsaufgaben im letzten Schritt dieses Tutorials ausführen, um zusätzliche Kosten zu vermeiden. Gebühren fallen pro Sekunde gemäß den Amazon-EMR-Preisen an. Die Gebühren variieren auch je nach Region. Weitere Informationen finden Sie unter Amazon-EMR-Preise.
- Für kleine Dateien, die Sie in Amazon S3 speichern, können geringe Gebühren anfallen. Einige oder alle Gebühren für Amazon S3 können erlassen werden, wenn Sie sich innerhalb der Nutzungsgrenzen des AWS kostenlosen Kontingents befinden. Weitere Informationen finden Sie unter Amazon-S3-Preise und AWS kostenloses Kontingent.

Schritt 1: Planung und Konfiguration eines Amazon-EMR-Clusters

Speicher für Amazon EMR vorbereiten

Wenn Sie Amazon EMR verwenden, können Sie aus einer Vielzahl von Dateisystemen wählen, um Eingabedaten, Ausgabedaten und Protokolldateien zu speichern. In diesem Tutorial verwenden Sie EMRFS zum Speichern von Daten in einem S3-Bucket. EMRFS ist eine Implementierung des Hadoop-Dateisystems, mit der Sie reguläre Dateien in Amazon S3 lesen und schreiben können. Weitere Informationen finden Sie unter Mit Storage- und Dateisystemen arbeiten.

Um einen Bucket zu erstellen, befolgen Sie die Anweisungen unter Wie wird ein S3 Bucket erstellt? im Konsolen-Benutzerhandbuch zu Amazon Simple Storage Service. Erstellen Sie den Bucket in derselben AWS-Region, in der Sie Ihren Amazon-EMR Cluster starten möchten. Zum Beispiel USA West (Oregon) us-west-2.

Für Buckets und Ordner, die Sie mit Amazon EMR verwenden, gelten die folgenden Einschränkungen:

- Namen können Kleinbuchstaben, Zahlen, Bindestriche (-) und Punkte (.) enthalten.
- Namen dürfen nicht mit Zahlen enden.

- Bucket-Namen müssen in allen AWS-Konten eindeutig sein.
- Ein Ausgabeordner muss leer sein.

Bereiten Sie eine Anwendung mit Eingabedaten für Amazon EMR vor

Die gängigste Methode zur Vorbereitung eines Antrags für Amazon EMR besteht darin, den Antrag und seine Eingabedaten in Amazon S3 hochzuladen. Wenn Sie dann Arbeit an Ihren Cluster senden, geben Sie die Amazon-S3-Speicherorte für Ihr Skript und Ihre Daten an.

In diesem Schritt laden Sie ein PySpark-Beispielskript zu Ihrem Amazon-S3-Bucket hoch. Wir haben ein PySpark-Skript zur Verfügung gestellt, das Sie verwenden können. Das Skript verarbeitet Inspektionsdaten von Lebensmittelbetrieben und gibt eine Ergebnisdatei in Ihrem S3-Bucket zurück. In der Ergebnisdatei sind die zehn Einrichtungen mit den meisten Verstößen vom Typ „Rot“ aufgeführt.

Sie laden auch Beispiel-Eingabedaten auf Amazon S3 hoch, damit das PySpark-Skript sie verarbeiten kann. Bei den Eingabedaten handelt es sich um eine modifizierte Version der Inspektionsergebnisse des Gesundheitsministeriums in King County, Washington, von 2006 bis 2020. Weitere Informationen finden Sie unter King County Open Data: Daten zur Inspektion von Lebensmittelbetrieben. Nachfolgend sehen Sie einige Beispielzeilen aus dem Datensatz.

```
name, inspection_result, inspection_closed_business, violation_type, violation_points
100 LB CLAM, Unsatisfactory, FALSE, BLUE, 5
100 PERCENT NUTRICION, Unsatisfactory, FALSE, BLUE, 5
7-ELEVEN #2361-39423A, Complete, FALSE, , 0
```

Um das PySpark-Beispielskript für EMR vorzubereiten

1. Kopieren Sie den Beispielcode unten mit einem Editor Ihrer Wahl in eine neue Datei.

```
import argparse

from pyspark.sql import SparkSession

def calculate_red_violations(data_source, output_uri):
    """
    Processes sample food establishment inspection data and queries the data to
 find the top 10 establishments
    with the most Red violations from 2006 to 2020.
```

```
    :param data_source: The URI of your food establishment data CSV, such as 's3://
DOC-EXAMPLE-BUCKET/food-establishment-data.csv'.
    :param output_uri: The URI where output is written, such as 's3://DOC-EXAMPLE-
BUCKET/restaurant_violation_results'.
    """
    with SparkSession.builder.appName("Calculate Red Health
 Violations").getOrCreate() as spark:
        # Load the restaurant violation CSV data
        if data_source is not None:
            restaurants_df = spark.read.option("header", "true").csv(data_source)

        # Create an in-memory DataFrame to query
        restaurants_df.createOrReplaceTempView("restaurant_violations")

        # Create a DataFrame of the top 10 restaurants with the most Red violations
        top_red_violation_restaurants = spark.sql("""SELECT name, count(*) AS
 total_red_violations
          FROM restaurant_violations
          WHERE violation_type = 'RED'
          GROUP BY name
          ORDER BY total_red_violations DESC LIMIT 10""")

        # Write the results to the specified output URI
        top_red_violation_restaurants.write.option("header",
 "true").mode("overwrite").csv(output_uri)

if __name__ == "__main__":
    parser = argparse.ArgumentParser()
    parser.add_argument(
        '--data_source', help="The URI for you CSV restaurant data, like an S3
 bucket location.")
    parser.add_argument(
        '--output_uri', help="The URI where output is saved, like an S3 bucket
 location.")
    args = parser.parse_args()

    calculate_red_violations(args.data_source, args.output_uri)
```

2. Speichern Sie die Datei als `health_violations.py`.
3. Laden Sie Ihre `health_violations.py` in Amazon S3 in den Bucket hoch, den Sie als Voraussetzung für dieses Tutorial erstellt haben. Anweisungen finden Sie unter Hochladen eines Objekts in Ihren Bucket im Handbuch „Erste Schritte“ für Amazon Simple Storage Service.

Um die Probeneingabedaten für EMR vorzubereiten

1. Laden Sie die ZIP-Datei food_establishment_data.zip herunter.
2. Entpacken und speichern Sie `food_establishment_data.zip` als `food_establishment_data.csv` auf Ihrem Computer.
3. Laden Sie die CSV-Datei in den S3-Bucket hoch, den Sie für dieses Tutorial erstellt haben. Anweisungen finden Sie unter Hochladen eines Objekts in Ihren Bucket im Handbuch „Erste Schritte“ für Amazon Simple Storage Service.

Weitere Informationen zum Einrichten von Daten für EMR finden Sie unter Eingabedaten vorbereiten.

Starten eines Amazon-EMR-Clusters

Nachdem Sie einen Speicherort und Ihre Anwendung vorbereitet haben, können Sie einen Amazon-EMR-Beispielcluster starten. In diesem Schritt starten Sie einen Apache-Spark-Cluster mit der neuesten Amazon-EMR-Version.

New console

So starten Sie einen Cluster mit installiertem Spark über die neue Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Notieren Sie sich auf der Seite Cluster erstellen die Standardwerte für Version, Instance-Typ, Anzahl der Instances und Berechtigungen. Diese Felder werden automatisch mit Werten aufgefüllt, die für Allzweck-Cluster geeignet sind.
4. Geben Sie im Feld Clustername einen eindeutigen Clusternamen ein, um Ihren Cluster leichter identifizieren zu können, z. B. *`Mein erster Cluster`*.
5. Wählen Sie unter Anwendungen die Spark-Option, um Spark auf Ihrem Cluster zu installieren.

> **Note**
>
> Wählen Sie die Anwendungen aus, die Sie in Ihrem Amazon-EMR-Cluster haben möchten, bevor Sie den Cluster starten. Sie können nach dem Start keine Anwendungen zu einem Cluster hinzufügen oder daraus entfernen.

6. Aktivieren Sie unter Cluster-Protokolle das Kontrollkästchen Cluster-spezifische Protokolle in Amazon S3 veröffentlichen. Ersetzen Sie den Amazon-S3-Standortwert durch den Amazon-S3-Bucket, den Sie erstellt haben, gefolgt von **`/logs`**. Zum Beispiel **`s3://DOC-EXAMPLE-BUCKET/logs`**. Durch das Hinzufügen von **`/logs`** wird ein neuer Ordner namens „logs“ in Ihrem Bucket erstellt, in den Amazon EMR die Protokolldateien Ihres Clusters kopieren kann.
7. Wählen Sie unter Sicherheitskonfiguration und Berechtigungen Ihr EC2-Schlüsselpaar aus. Wählen Sie im selben Abschnitt das Dropdownmenü Servicerolle für Amazon EMR aus und wählen Sie EMR_DefaultRole aus. Wählen Sie dann das Dropdownmenü IAM-Rolle für Instance-Profil und dann EMR_EC2_DefaultRole aus.
8. Wählen Sie Cluster erstellen aus, um den Cluster zu starten und die Cluster-Detailseite zu öffnen.
9. Suchen Sie den Cluster-Status neben dem Clusternamen. Der Status ändert sich von Starten zu Läuft zu Wartend, wenn Amazon EMR den Cluster bereitstellt. Möglicherweise müssen Sie das Aktualisierungs-Symbol auf der rechten Seite betätigen oder Ihren Browser aktualisieren, um Updates zu sehen.

Ihr Clusterstatus ändert sich in Wartend, wenn der Cluster betriebsbereit ist, läuft und bereit ist, Arbeit anzunehmen. Weitere Informationen zum Lesen der Cluster-Zusammenfassung finden Sie unter Cluster-Status und -Details anzeigen. Weitere Informationen zu Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus.

Old console

So starten Sie einen Cluster mit installiertem Spark über die alte Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Cluster erstellen aus, um den Assistenten für Schnelloptionen zu öffnen.

3. Notieren Sie sich die Standardwerte für Version, Instance-Typ, Anzahl der Instances und Berechtigungen auf der Seite Cluster erstellen – Schnelloptionen. Diese Felder werden automatisch mit Werten gefüllt, die für Allzweck-Cluster funktionieren.
4. Geben Sie einen Clusternamen ein, um den Cluster leichter identifizieren zu können. Zum Beispiel *Mein erster Cluster*.
5. Lassen Sie die Protokollierung aktiviert, ersetzen Sie jedoch den Wert des S3-Ordners durch den Amazon-S3-Bucket, den Sie erstellt haben, gefolgt von **/logs**. Zum Beispiel **s3://DOC-EXAMPLE-BUCKET/logs**. Durch das Hinzufügen von **/logs** wird ein neuer Ordner namens „logs“ in Ihrem Bucket erstellt, in den EMR die Protokolldateien Ihres Clusters kopieren kann.
6. Wählen Sie unter Anwendungen die Spark-Option, um Spark auf Ihrem Cluster zu installieren.

   > **Note**
   >
   > Wählen Sie die Anwendungen aus, die Sie in Ihrem Amazon-EMR-Cluster haben möchten, bevor Sie den Cluster starten. Sie können nach dem Start keine Anwendungen zu einem Cluster hinzufügen oder daraus entfernen.

7. Wählen Sie unter Sicherheit und Zugriff Ihr EC2-Schlüsselpaar aus.
8. Wählen Sie Cluster erstellen aus, um den Cluster zu starten und die Cluster-Statusseite zu öffnen.
9. Suchen Sie den Cluster-Status neben dem Clusternamen. Der Status ändert sich von Starten zu Läuft zu Wartend, wenn Amazon EMR den Cluster bereitstellt. Möglicherweise müssen Sie das Aktualisierungs-Symbol auf der rechten Seite betätigen oder Ihren Browser aktualisieren, um Updates zu sehen.

Ihr Clusterstatus ändert sich in Wartend, wenn der Cluster betriebsbereit ist, läuft und bereit ist, Arbeit anzunehmen. Weitere Informationen zum Lesen der Cluster-Zusammenfassung finden Sie unter Cluster-Status und -Details anzeigen. Weitere Informationen zu Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus.

CLI

So starten Sie einen Cluster mit installiertem Spark mit AWS CLI

1. Erstellen Sie IAM-Standardrollen, die Sie dann verwenden können, um Ihren Cluster zu erstellen, indem Sie den folgenden Befehl verwenden.

```
aws emr create-default-roles
```

   Weitere Informationen zu `create-default-roles` finden Sie in der AWS CLI-Befehlsreferenz.

2. Erstellen Sie einen Spark-Cluster mit dem folgenden Befehl. Geben Sie mit der `--name`-Option einen Namen für Ihren Cluster ein und geben Sie den Namen Ihres EC2-Schlüsselpaars mit der `--ec2-attributes`-Option an.

```
aws emr create-cluster \
--name "<My First EMR Cluster>" \
--release-label <emr-5.36.1> \
--applications Name=Spark \
--ec2-attributes KeyName=<myEMRKeyPairName> \
--instance-type m5.xlarge \
--instance-count 3 \
--use-default-roles
```

   Notieren Sie sich die anderen erforderlichen Werte für `--instance-type`, `--instance-count` und `--use-default-roles`. Diese Werte wurden für Allzweck-Cluster ausgewählt. Weitere Informationen zu `create-cluster` finden Sie in der AWS CLI-Befehlsreferenz.

   > **Note**
   >
   > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

   Die Ausgabe sollte ungefähr wie die folgende aussehen. Die Ausgabe zeigt `ClusterId` und `ClusterArn` Ihres neuen Clusters. Notieren Sie sich Ihre `ClusterId`. Sie verwenden `ClusterId`, um den Clusterstatus zu überprüfen und Arbeiten einzureichen.

```
{
    "ClusterId": "myClusterId",
    "ClusterArn": "myClusterArn"
}
```

3. Überprüfen Sie Ihren Clusterstatus mit dem folgenden Befehl.

```
aws emr describe-cluster --cluster-id <myClusterId>
```

Mit dem `Status`-Objekt für Ihren neuen Cluster sollten Sie eine Ausgabe wie die folgende sehen.

```
{
    "Cluster": {
        "Id": "myClusterId",
        "Name": "My First EMR Cluster",
        "Status": {
            "State": "STARTING",
            "StateChangeReason": {
                "Message": "Configuring cluster software"
            }
        }
     }
}
```

Der `State`-Wert ändert sich von `STARTING` zu `RUNNING` zu `WAITING`, wenn Amazon EMR den Cluster bereitstellt.

Der Cluster-Status ändert sich zu **`WAITING`**, in dem ein Cluster betriebsbereit und bereit ist, Arbeit anzunehmen. Weitere Informationen zu Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus.

Schritt 2: Ihren Amazon-EMR-Cluster verwalten

Arbeit bei Amazon EMR einreichen

Nachdem Sie einen Cluster gestartet haben, können Sie Arbeiten an den laufenden Cluster senden, um Daten zu verarbeiten und zu analysieren. In einem Schritt reichen Sie Arbeiten an einen Amazon-

EMR-Cluster ein. Ein Schritt ist eine Arbeitseinheit, die aus einer oder mehreren Aktionen besteht. Sie könnten beispielsweise einen Schritt zur Berechnung von Werten oder zur Übertragung und Verarbeitung von Daten einreichen. Sie können Schritte beim Erstellen eines Clusters oder an einen laufenden Cluster senden. In diesem Teil des Tutorials übermitteln Sie `health_violations.py` als Schritt an Ihren laufenden Cluster. Weitere Informationen zu Schritten finden Sie unter Übermitteln von Arbeit an einen Cluster.

New console

Um eine Spark-Anwendung als Schritt mit der neuen Konsole einzureichen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Clusters aus, und wählen Sie dann den Cluster aus, für den Sie Arbeit einreichen möchten. Der Clusterstatus muss Wartend lauten.
3. Wählen Sie Schritte und dann Schritt hinzufügen.
4. Konfigurieren Sie den Schritt anhand der folgenden Richtlinien:

   - Wählen Sie für Typ die Option Spark-Anwendung aus. Sie sollten zusätzliche Felder für den Bereitstellungsmodus, den Speicherort der Anwendung und die Optionen Spark-Submit sehen.
   - Geben Sie unter Name einen neuen Namen ein. Wenn Sie viele Schritte in einem Cluster haben, hilft Ihnen die Benennung der einzelnen Schritte dabei, den Überblick zu behalten.
   - Behalten Sie für den Bereitstellungsmodus den Standardwert Clustermodus bei. Weitere Informationen zu Spark-Bereitstellungsmodi finden Sie unter Übersicht über den Clustermodus in der Apache-Spark-Dokumentation.
   - Geben Sie unter Anwendungsort den Speicherort Ihres `health_violations.py`-Skripts in Amazon S3 ein, z. B. *`s3://DOC-EXAMPLE-BUCKET/health_violations.py`*.
   - Lassen Sie das Feld mit den Spark-Submit-Optionen leer. Weitere Informationen zu den `spark-submit`-Optionen finden Sie unter Starten von Anwendungen mit spark-submit.
   - Geben Sie im Feld Argumente die folgenden Argumente und Werte ein:

     ```
     --data_source s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv
     --output_uri s3://DOC-EXAMPLE-BUCKET/myOutputFolder
     ```

Ersetzen Sie *s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv* durch den S3-Bucket-URI der Eingabedaten, in denen Sie die Daten in Bereiten Sie eine Anwendung mit Eingabedaten für Amazon EMR vor vorbereitet haben.

Ersetzen Sie *DOC-EXAMPLE-BUCKET* durch den Namen des Buckets, den Sie für dieses Tutorial erstellt haben, und ersetzen Sie *MyOutputFolder* durch einen Namen für Ihren Cluster-Ausgabeordner.

- Übernehmen Sie unter Aktion bei Fehler des Schrittes die Standardeinstellung Fortfahren. Auf diese Weise wird der Cluster weiter ausgeführt, wenn der Schritt fehlschlägt.

5. Wählen Sie Hinzufügen, um den Schritt zu senden. Der Schritt wird in der Konsole mit dem Status Ausstehend angezeigt.
6. Überwachen Sie den Status des Schritts. Der Wert sollte sich von Ausstehend zu Wird ausgeführt zu Abgeschlossen ändern. Um den Status in der Konsole zu aktualisieren, wählen Sie das Aktualisierungssymbol rechts neben dem Filter aus. Die Ausführung des Skripts dauert etwa eine Minute. Wenn sich der Status in Abgeschlossen, ändert, wurde der Schritt erfolgreich abgeschlossen.

Old console

Um eine Spark-Anwendung als Schritt mit der alten Konsole einzureichen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie unter Clusterliste den Namen des Clusters aus. Der Clusterstatus muss Wartend lauten.
3. Wählen Sie Steps (Schritte) und dann Add step (Schritt hinzufügen).
4. Konfigurieren Sie den Schritt anhand der folgenden Richtlinien:

   - Wählen Sie für Step type die Option Spark application aus. Es sollten zusätzliche Felder für den Bereitstellungsmodus, die Spark-Submit-Optionen und den Speicherort der Anwendung angezeigt werden.
   - Behalten Sie für Name den Standardwert bei oder geben Sie einen neuen Namen ein. Wenn Sie viele Schritte in einem Cluster haben, hilft Ihnen die Benennung der einzelnen Schritte dabei, den Überblick zu behalten.

- Behalten Sie für den Bereitstellungsmodus den Standardwert Cluster bei. Weitere Informationen zu Spark-Bereitstellungsmodi finden Sie unter Übersicht über den Clustermodus in der Apache-Spark-Dokumentation.
- Lassen Sie das Feld mit den Spark-Submit-Optionen leer. Weitere Informationen zu den `spark-submit`-Optionen finden Sie unter Starten von Anwendungen mit Spark-Submit.
- Geben Sie unter Anwendungsort den Speicherort Ihres `health_violations.py`-Skripts in Amazon S3 ein. Zum Beispiel *`s3://DOC-EXAMPLE-BUCKET/health_violations.py`*.
- Geben Sie im Feld Argumente die folgenden Argumente und Werte ein:

  ```
  --data_source s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv
  --output_uri s3://DOC-EXAMPLE-BUCKET/myOutputFolder
  ```

  Ersetzen Sie *`s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv`* durch den S3-URI der Eingabedaten, in denen Sie die Daten in Bereiten Sie eine Anwendung mit Eingabedaten für Amazon EMR vor vorbereitet haben.

  Ersetzen Sie *`DOC-EXAMPLE-BUCKET`* durch den Namen des Buckets, den Sie für dieses Tutorial erstellt haben, und ersetzen Sie *`MyOutputFolder`* durch einen Namen für Ihren Cluster-Ausgabeordner.
- Akzeptieren Sie für Aktion bei einem Fehler die Standardoption Fortfahren, sodass der Cluster weiterläuft, wenn der Schritt fehlschlägt.

5. Wählen Sie Hinzufügen, um den Schritt zu senden. Der Schritt wird in der Konsole mit dem Status Ausstehend angezeigt.
6. Prüfen Sie, ob sich der Status des Schritts von Ausstehend zu Wird ausgeführt zu Abgeschlossen geändert hat. Um den Status in der Konsole zu aktualisieren, wählen Sie das Aktualisierungssymbol rechts neben dem Filter aus. Die Ausführung des Skripts dauert etwa eine Minute.

Sie werden wissen, dass der Schritt erfolgreich abgeschlossen wurde, wenn der Status auf Abgeschlossen geändert wird.

CLI

Um eine Spark-Anwendung als Schritt einzureichen, verwenden Sie AWS CLI

1. Stellen Sie sicher, dass Sie `ClusterId` des Clusters haben, den Sie in Starten eines Amazon-EMR-Clusters gestartet haben. Sie können Ihre Cluster-ID auch mit dem folgenden Befehl abrufen.

   ```
   aws emr list-clusters --cluster-states WAITING
   ```

2. Senden Sie `health_violations.py` als Schritt mit dem `add-steps`-Befehl und Ihrem `ClusterId`.

   - Sie können einen Namen für Ihren Schritt angeben, indem Sie *„Meine Spark-Anwendung“* ersetzen. Ersetzen Sie im `Args`-Array *s3://DOC-EXAMPLE-BUCKET/health_violations.py* mit dem Speicherort Ihrer `health_violations.py`-Anwendung.
   - Ersetzen Sie *s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv* mit dem S3-Speicherort Ihres `food_establishment_data.csv`-Datensatzes.
   - Ersetzen Sie *s3://DOC-EXAMPLE-BUCKET/MyOutputFolder* durch den S3-Pfad Ihres angegebenen Buckets und einen Namen für Ihren Cluster-Ausgabeordner.
   - `ActionOnFailure=CONTINUE` bedeutet, dass der Cluster weiter ausgeführt wird, wenn der Schritt fehlschlägt.

   ```
   aws emr add-steps \
   --cluster-id <myClusterId> \
   --steps Type=Spark,Name="<My Spark
    Application>",ActionOnFailure=CONTINUE,Args=[<s3://DOC-EXAMPLE-
   BUCKET/health_violations.py>,--data_source,<s3://DOC-EXAMPLE-BUCKET/
   food_establishment_data.csv>,--output_uri,<s3://DOC-EXAMPLE-BUCKET/
   MyOutputFolder>]
   ```

   Weitere Informationen zum Senden von Schritten mithilfe der CLI finden Sie in der AWS CLI-Befehlsreferenz.

   Nachdem Sie den Schritt eingereicht haben, sollten Sie eine Ausgabe wie die folgende mit einer Liste von `StepIds` sehen. Da Sie einen Schritt eingereicht haben, wird in der Liste nur

eine ID angezeigt. Kopieren Sie Ihre Schritt-ID. Sie verwenden Ihre Schritt-ID, um den Status des Schritts zu überprüfen.

```
{
    "StepIds": [
        "s-1XXXXXXXXXXA"
    ]
}
```

3. Fragen Sie den Status Ihres Schritts mit dem `describe-step`-Befehl ab.

```
aws emr describe-step --cluster-id <myClusterId> --step-id <s-1XXXXXXXXXXA>
```

Die Ausgabe sollte ungefähr wie die folgende aussehen, mit Informationen zu Ihrem Schritt.

```
{
    "Step": {
        "Id": "s-1XXXXXXXXXXA",
        "Name": "My Spark Application",
        "Config": {
            "Jar": "command-runner.jar",
            "Properties": {},
            "Args": [
                "spark-submit",
                "s3://DOC-EXAMPLE-BUCKET/health_violations.py",
                "--data_source",
                "s3://DOC-EXAMPLE-BUCKET/food_establishment_data.csv",
                "--output_uri",
                "s3://DOC-EXAMPLE-BUCKET/myOutputFolder"
            ]
        },
        "ActionOnFailure": "CONTINUE",
        "Status": {
            "State": "COMPLETED"
        }
    }
}
```

Der `State`-Wert des Schritts ändert sich mit der Ausführung des Schritts von `PENDING` zu `RUNNING` zu `COMPLETED`. Die Ausführung des Schritts dauert etwa eine Minute, sodass Sie den Status möglicherweise einige Male überprüfen müssen.

Sie wissen, dass der Schritt erfolgreich war, wenn sich `State` in **`COMPLETED`** ändert.

Weitere Informationen zum Schrittlebenszyklus finden Sie unter Ausführen von Schritten zur Verarbeitung von Daten.

Ergebnisse anzeigen

Nachdem ein Schritt erfolgreich ausgeführt wurde, können Sie seine Ausgabeergebnisse in Ihrem Amazon-S3-Ausgabeordner anzeigen.

So sehen Sie die Ergebnisse von **`health_violations.py`**

1. Öffnen Sie die Amazon S3-Konsole unter https://console.aws.amazon.com/s3/.
2. Wählen Sie den Bucket-Namen und dann den Ausgabeordner aus, den Sie beim Absenden des Schritts angegeben haben. Zum Beispiel *`DOC-EXAMPLE-BUCKET`* und dann *`MyOutputFolder`*.
3. Stellen Sie sicher, dass die folgenden Elemente in Ihrem Ausgabeordner angezeigt werden:
   - Ein kleines Objekt namens `_SUCCESS`.
   - Eine CSV-Datei, die mit dem Präfix `part-` beginnt, die Ihre Ergebnisse enthält.
4. Wählen Sie das Objekt mit Ihren Ergebnissen aus und klicken Sie dann auf Herunterladen, um die Ergebnisse in Ihrem lokalen Dateisystem zu speichern.
5. Öffnen Sie die Ergebnisse in Ihrem Editor Ihrer Wahl. In der Ausgabedatei sind die zehn Lebensmittelbetriebe mit den meisten roten Verstößen aufgeführt. Die Ausgabedatei zeigt auch die Gesamtzahl der roten Verstöße für jeden Betrieb.

   Es folgt ein Beispiel für ein `health_violations.py`-Ergebnis.

```
name, total_red_violations
SUBWAY, 322
T-MOBILE PARK, 315
WHOLE FOODS MARKET, 299
PCC COMMUNITY MARKETS, 251
TACO TIME, 240
```

```
MCDONALD'S, 177
THAI GINGER, 153
SAFEWAY INC #1508, 143
TAQUERIA EL RINCONSITO, 134
HIMITSU TERIYAKI, 128
```

Weitere Informationen zur Amazon-EMR-Clusterausgabe finden Sie unter Einen Ausgabespeicherort konfigurieren.

(Optional) Stellen Sie eine Verbindung zu Ihrem laufenden Amazon-EMR-Cluster her

Wenn Sie Amazon EMR verwenden, möchten Sie möglicherweise eine Verbindung zu einem laufenden Cluster herstellen, um Protokolldateien zu lesen, den Cluster zu debuggen oder CLI-Tools wie die Spark-Shell zu verwenden. Mit Amazon EMR können Sie mithilfe des Secure Shell (SSH)-Protokolls eine Verbindung zu einem Cluster herstellen. In diesem Abschnitt erfahren Sie, wie Sie SSH konfigurieren, eine Verbindung zu Ihrem Cluster herstellen und Protokolldateien für Spark anzeigen. Weitere Informationen zum Herstellen einer Verbindung mit einem Cluster finden Sie unter Authentifizieren von Amazon-EMR-Cluster-Knoten.

Autorisieren von SSH-Verbindungen zu Ihrem Cluster

Bevor Sie eine Verbindung zu Ihrem Cluster herstellen, müssen Sie Ihre Cluster-Sicherheitsgruppen ändern, um eingehende SSH-Verbindungen zu autorisieren. Amazon-EC2-Sicherheitsgruppen fungieren als virtuelle Firewalls für Ihre Instances zur Steuerung des ein- und ausgehenden Datenverkehrs zu Ihrem Cluster. Als Sie Ihren Cluster für dieses Tutorial erstellt haben, hat Amazon EMR in Ihrem Namen die folgenden Sicherheitsgruppen erstellt:

ElasticMapReduce-master

Die standardmäßige verwaltete Amazon-EMR-Sicherheitsgruppe, die mit dem Primärknoten verknüpft ist. In einem Amazon-EMR-Cluster ist der Primärknoten eine Amazon-EC2-Instance, die den Cluster verwaltet.

ElasticMapReduce-slave

Die Standardsicherheitsgruppe, die Core- und Aufgabenknoten zugeordnet ist.

New console

Um SSH-Zugriff für vertrauenswürdige Quellen für die primäre Sicherheitsgruppe mit der neuen Konsole zu ermöglichen

Um Ihre Sicherheitsgruppen zu bearbeiten, benötigen Sie die Berechtigung, Sicherheitsgruppen für die VPC zu verwalten, in der sich der Cluster befindet. Weitere Informationen finden Sie im IAM-Benutzerhandbuch unter Ändern von Benutzerberechtigungen und unter Beispielrichtlinie, die die Verwaltung von EC2-Sicherheitsgruppen ermöglicht.

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten. Dadurch wird die Cluster-Detailseite geöffnet. Die Registerkarte Eigenschaften auf dieser Seite sollte vorausgewählt sein.
3. Wählen Sie auf der Registerkarte Eigenschaften unter Netzwerk den Pfeil neben EC2-Sicherheitsgruppen (Firewall) aus, um diesen Abschnitt zu erweitern. Wählen Sie unter Primärknoten den Link zur Sicherheitsgruppe aus. Wenn Sie die folgenden Schritte abgeschlossen haben, können Sie optional zu diesem Schritt zurückkehren, Core- und Aufgabenknoten auswählen und die folgenden Schritte wiederholen, um dem SSH-Client Zugriff auf Core- und Aufgabenknoten zu gewähren.
4. Daraufhin wird die EC2-Konsole geöffnet. Wählen Sie die Registerkarte Eingehende Regeln und anschließend Eingehende Regeln bearbeiten aus.
5. Suchen Sie mit den folgenden Einstellungen nach einer Regel für eingehenden Datenverkehr, die öffentlichen Zugriff ermöglicht. Falls sie existiert, wählen Sie Löschen, um sie zu entfernen.

   - Typ

     SSH
   - Port

     22
   - Source (Quelle)

     Benutzerdefiniert 0.0.0.0/0

> **Warning**
>
> Vor Dezember 2020 verfügte die ElasticMapReduce-Master-Sicherheitsgruppe über eine vorkonfigurierte Regel, die eingehenden Datenverkehr auf Port 22 aus allen Quellen zuließ. Diese Regel wurde erstellt, um die ersten SSH-Verbindungen zum Hauptknoten zu vereinfachen. Wir empfehlen Ihnen dringend, diese Eingangsregel zu entfernen und den Datenverkehr auf vertrauenswürdige Quellen zu beschränken.

6. Scrollen Sie zum Ende der Regelliste und wählen Sie Regel hinzufügen.
7. Wählen Sie für Type (Typ) SSH aus. Wenn Sie SSH auswählen, wird automatisch TCP für Protokoll und 22 für Portbereich eingegeben.
8. Wählen Sie als Quelle Meine IP aus, um Ihre IP-Adresse automatisch als Quelladresse hinzuzufügen. Sie können auch einen Bereich benutzerdefinierter vertrauenswürdiger Client-IP-Adressen hinzufügen oder zusätzliche Regeln für andere Clients erstellen. In vielen Netzwerkumgebungen werden IP-Adressen dynamisch zugewiesen, sodass Sie in Zukunft möglicherweise Ihre IP-Adressen für vertrauenswürdige Clients aktualisieren müssen.
9. Wählen Sie Save (Speichern).
10. Wählen Sie optional Core- und Aufgabenknoten aus der Liste aus und wiederholen Sie die obigen Schritte, um dem SSH-Client Zugriff auf Core- und Aufgabenknoten zu gewähren.

Old console

Wie Sie vertrauenswürdigen Quellen SSH-Zugriff auf die primäre Sicherheitsgruppe mit der alten Konsole gewähren

Um Ihre Sicherheitsgruppen zu bearbeiten, benötigen Sie die Berechtigung, Sicherheitsgruppen für die VPC zu verwalten, in der sich der Cluster befindet. Weitere Informationen finden Sie im IAM-Benutzerhandbuch unter Ändern von Benutzerberechtigungen und unter Beispielrichtlinie, die die Verwaltung von EC2-Sicherheitsgruppen ermöglicht.

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Clusters (Cluster) aus. Wählen Sie den Namen des Clusters, den Sie ändern möchten.

3. Wählen Sie unter Sicherheit und Zugriff den Link Sicherheitsgruppen für Master.
4. Wählen Sie aus der Liste ElasticMapReduce-master.
5. Wählen Sie die Registerkarte Eingehende Regeln und anschließend Eingehende Regeln bearbeiten aus.
6. Suchen Sie mit den folgenden Einstellungen nach einer Regel für eingehenden Datenverkehr, die öffentlichen Zugriff ermöglicht. Falls sie existiert, wählen Sie Löschen, um sie zu entfernen.

   - Typ

     SSH
   - Port

     22
   - Source (Quelle)

     Benutzerdefiniert 0.0.0.0/0

   > **Warning**
   >
   > Vor Dezember 2020 verfügte die ElasticMapReduce-Master-Sicherheitsgruppe über eine vorkonfigurierte Regel, die eingehenden Datenverkehr auf Port 22 aus allen Quellen zuließ. Diese Regel wurde erstellt, um die ersten SSH-Verbindungen zum Primärknoten zu vereinfachen. Wir empfehlen Ihnen dringend, diese Eingangsregel zu entfernen und den Datenverkehr auf vertrauenswürdige Quellen zu beschränken.

7. Scrollen Sie zum Ende der Regelliste und wählen Sie Regel hinzufügen.
8. Wählen Sie für Type (Typ) SSH aus.

   Wenn Sie SSH auswählen, wird automatisch TCP für Protokoll und 22 für Portbereich eingegeben.
9. Wählen Sie als Quelle Meine IP aus, um Ihre IP-Adresse automatisch als Quelladresse hinzuzufügen. Sie können auch einen Bereich benutzerdefinierter vertrauenswürdiger Client-IP-Adressen hinzufügen oder zusätzliche Regeln für andere Clients erstellen. In vielen Netzwerkumgebungen werden IP-Adressen dynamisch zugewiesen, sodass Sie in Zukunft möglicherweise Ihre IP-Adressen für vertrauenswürdige Clients aktualisieren müssen.

10. Wählen Sie Save (Speichern).
11. Wählen Sie optional ElasticMapReduce-slave aus der Liste aus und wiederholen Sie die obigen Schritte, um dem SSH-Client Zugriff auf Core- und Aufgabenknoten zu ermöglichen.Clients zuzulassen.

Herstellen einer Verbindung mit dem Cluster mit AWS CLI

Unabhängig von Ihrem Betriebssystem können Sie mit dem AWS CLI eine SSH-Verbindung zu Ihrem Cluster herstellen.

Um eine Verbindung zu Ihrem Cluster herzustellen und Protokolldateien anzuzeigen, verwenden Sie AWS CLI

1. Stellen Sie mit dem folgenden Befehl eine SSH-Verbindung zu Ihrem Cluster her. Ersetzen Sie *<mykeypair.key>* durch den vollständigen Pfad und Dateinamen Ihrer Schlüsselpaardatei. Zum Beispiel `C:\Users\<username>\.ssh\mykeypair.pem`.

   ```
   aws emr ssh --cluster-id <j-2AL4XXXXXX5T9> --key-pair-file <~/mykeypair.key>
   ```

2. Navigieren Sie zu `/mnt/var/log/spark`, um auf die Spark-Protokolle auf dem Hauptknoten Ihres Clusters zuzugreifen. Sehen Sie sich dann die Dateien an diesem Speicherort an. Eine Liste zusätzlicher Protokolldateien auf dem Hauptknoten finden Sie unter Protokolldateien auf dem Primärknoten anzeigen.

   ```
   cd /mnt/var/log/spark
   ls
   ```

Schritt 3: Ihre Amazon-EMR-Ressourcen bereinigen

So beenden Sie Ihren Cluster

Nachdem Sie Arbeit an Ihren Cluster übermittelt und die Ergebnisse Ihrer PySpark-Anwendung angesehen haben, können Sie den Cluster beenden. Durch das Beenden eines Clusters werden alle mit dem Cluster verbundenen Amazon-EMR-Gebühren und Amazon-EC2-Instances gestoppt.

Wenn Sie einen Cluster kündigen, speichert Amazon EMR Metadaten über den Cluster zwei Monate lang kostenlos. Archivierte Metadaten helfen Ihnen dabei, den Cluster für einen neuen Auftrag zu

klonen oder die Cluster-Konfiguration zu Referenzzwecken wiederaufzugreifen. Zu den Metadaten gehören keine Daten, die der Cluster in S3 schreibt, oder Daten, die in HDFS auf dem Cluster gespeichert sind.

> **Note**
>
> Mit der Amazon-EMR-Konsole können Sie nach dem Beenden des Clusters keinen Cluster aus der Listenansicht löschen. Ein beendeter Cluster verschwindet von der Konsole, wenn Amazon EMR seine Metadaten löscht.

New console

Wie Sie den Cluster mit der neuen Konsole beenden

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie Clusters und dann den Cluster aus, den Sie beenden möchten.
3. Wählen Sie im Dropdownmenü Aktionen die Option Cluster beenden aus.
4. Wählen Sie im Dialogfenster Beenden. Je nach Clusterkonfiguration kann die Kündigung 5 bis 10 Minuten dauern. Weitere Informationen zum Amazon-EMR-Cluster finden Sie unter Einen Cluster beenden.

Old console

Um den Cluster mit der alten Konsole zu beenden

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Clusters und dann den Cluster aus, den Sie beenden möchten. Zum Beispiel *`Mein erster EMR-Cluster`*.
3. Wählen Sie Terminate, um die Aufforderung Cluster beenden zu öffnen.
4. Wählen Sie in der offenen Eingabeaufforderung die Option Beenden. Je nach Clusterkonfiguration kann die Kündigung 5 bis 10 Minuten dauern. Weitere Informationen zum Beenden von Amazon-EMR-Clustern finden Sie unter Einen Cluster beenden.

> **Note**
>
> Wenn Sie das Tutorial genau befolgt haben, sollte der Beendigungsschutz deaktiviert sein. Der Cluster-Beendigungsschutz verhindert ein versehentliches Beenden. Wenn der Beendigungsschutz aktiviert ist, werden Sie aufgefordert, die Einstellung zu ändern, bevor Sie den Cluster beenden. Wählen Sie Ändern, Aus.

CLI

So beenden Sie den Cluster mit der AWS CLI

1. Initiieren Sie den Vorgang zur Clusterbeendigung mit dem folgenden Befehl. Ersetzen Sie *<myClusterId>* durch die ID Ihres Beispielclusters. Der Befehl gibt keine Ausgabe zurück.

```
aws emr terminate-clusters --cluster-ids <myClusterId>
```

2. Um zu überprüfen, ob der Clusterbeendigungsprozess im Gange ist, überprüfen Sie den Clusterstatus mit dem folgenden Befehl.

```
aws emr describe-cluster --cluster-id <myClusterId>
```

Im Folgenden finden Sie eine Beispielausgabe im JSON-Format. Der Cluster `Status` sollte sich von **`TERMINATING`** zu **`TERMINATED`** ändern. Die Beendigung kann je nach Clusterkonfiguration 5 bis 10 Minuten dauern. Weitere Informationen zum Beenden eines Amazon-EMR-Clusters finden Sie unter Einen Cluster beenden.

```
{
    "Cluster": {
        "Id": "j-xxxxxxxxxxxx",
        "Name": "My Cluster Name",
        "Status": {
            "State": "TERMINATED",
            "StateChangeReason": {
                "Code": "USER_REQUEST",
                "Message": "Terminated by user request"
            }
        }
    }
```

```
}
```

Löschen von S3-Ressourcen

Um zusätzliche Gebühren zu vermeiden, sollten Sie Ihren Amazon-S3-Bucket löschen. Durch das Löschen des Buckets werden alle Amazon-S3-Ressourcen für dieses Tutorial entfernt. Ihr Bucket sollte Folgendes enthalten:

- Das PySpark-Skript
- Der Eingabedatensatz
- Ihr Ordner mit den Ausgabeergebnissen
- Ihr Ordner für Protokolldateien

Möglicherweise müssen Sie zusätzliche Schritte unternehmen, um gespeicherte Dateien zu löschen, wenn Sie Ihr PySpark-Skript oder Ihre Ausgabe an einem anderen Ort gespeichert haben.

> **Note**
>
> Ihr Cluster muss beendet werden, bevor Sie Ihren Bucket löschen können. Andernfalls dürfen Sie den Bucket möglicherweise nicht leeren.

Um Ihren Bucket zu löschen, befolgen Sie die Anweisungen unter Wie lösche ich einen S3-Bucket? im Benutzerhandbuch zu Amazon Simple Storage Service.

Nächste Schritte

Sie haben jetzt Ihren ersten Amazon-EMR-Cluster von Anfang bis Ende gestartet. Sie haben auch wichtige EMR-Aufgaben wie das Vorbereiten und Einreichen von Big-Data-Anwendungen, das Anzeigen von Ergebnissen und das Beenden eines Clusters erledigt.

Verwenden Sie die folgenden Themen, um mehr über zu erfahren, wie Sie Ihren Amazon-EMR-Workflow anpassen können.

Erkunden Sie Big-Data-Anwendungen für Amazon EMR

Entdecken und vergleichen Sie die Big-Data-Anwendungen, die Sie auf einem Cluster installieren können, im Amazon-EMR-Versionshandbuch. Der Versionshandbuch beschreibt jede EMR-Version und enthält Tipps zur Verwendung von Frameworks wie Spark und Hadoop auf Amazon EMR.

Planen Sie Cluster-Hardware, Netzwerke und Sicherheit

In diesem Tutorial haben Sie einen einfachen EMR-Cluster erstellt, ohne erweiterte Optionen zu konfigurieren. Mit den erweiterten Optionen können Sie Amazon-EC2-Instance-Typen, Cluster-Netzwerke und Cluster-Sicherheit angeben. Weitere Informationen zur Planung und Einführung eines Clusters, der Ihren Anforderungen entspricht, finden Sie unter Cluster planen und konfigurieren und Sicherheit in Amazon EMR.

Verwalten von Clustern

Erfahren Sie mehr über die Arbeit mit laufenden Clustern unter Verwalten von Clustern. Um einen Cluster zu verwalten, können Sie eine Verbindung zum Cluster herstellen, Schritte debuggen und die Clusteraktivitäten und den Zustand verfolgen. Mit EMR-verwalteter Skalierung können Sie die Clusterressourcen auch an die Workload-Anforderungen anpassen.

Verwenden Sie eine andere Schnittstelle

Zusätzlich zur Amazon-EMR-Konsole können Sie Amazon EMR mithilfe der AWS Command Line Interface-Webservice-API oder eines der vielen unterstützten AWS-SDKs verwalten. Weitere Informationen finden Sie unter Verwaltungsschnittstellen.

Sie können auch auf vielfältige Weise mit Anwendungen interagieren, die auf Amazon-EMR-Clustern installiert sind. Einige Anwendungen wie Apache Hadoop veröffentlichen Weboberflächen, die Sie sich ansehen können. Weitere Informationen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Stöbern Sie im technischen Blog von EMR

Exemplarische Vorgehensweisen und ausführliche technische Diskussionen zu den neuen Amazon-EMR-Features finden Sie im AWS-Big-Data-Blog.

Was ist neu an der Konsole?

Amazon EMR wurde auf ein neues Erlebnis migriert. Die neue Konsole bietet eine aktualisierte Oberfläche, die Ihnen eine intuitive Möglichkeit bietet, Ihre Amazon-EMR-Umgebung zu verwalten, und Ihnen bequemen Zugriff auf Dokumentation, Produktinformationen und andere Ressourcen bietet. Auf dieser Seite werden wichtige Unterschiede zwischen der alten und der neuen Konsolenoberfläche AWS Management Console für Amazon EMR beschrieben.

In welcher Konsole bin ich?

Um festzustellen, welche Amazon-EMR-Konsole Sie derzeit verwenden, sehen Sie sich die URL für die Konsolenseite in Ihrem Browser an:

- Neue Konsolen-URL– https://console.aws.amazon.com/emr
- URL der alten Konsole – https://console.aws.amazon.com/elasticmapreduce

> **Note**
>
> Amazon EMR bietet eine neue Konsolenerfahrung. Die alte Konsole ist veraltet und ist nicht mehr verfügbar.

Die Funktionen der Amazon-EMR-Konsole werden schrittweise auf das neue Erlebnis migriert. In der folgenden Tabelle sind die wichtigsten Amazon-EMR-Konsolenkomponenten und ihr Konsolenmigrationsstatus aufgeführt.

Komponente für Amazon-EMR-Konsole	New console	Alte Konsole
EMR Studio[1]	✓	✓
Cluster erstellen und verwalten	✓	✓
Blockieren des öffentlichen Zugriffs	✓	✓

Komponente für Amazon-EMR-Konsole	New console	Alte Konsole
Überwachen von Amazon CloudWatch Events	✓	✓
Sicherheitskonfigurationen	✓	✓
Virtuelle Cluster (Amazon EMR in EKS)	✓	✓
Anzeigen und Verwalten Ihrer Amazon Virtual Private Cloud-Subnetze [2]	✓	✓
Notebooks[3]	✓	✓

[1] EMR Studio verwendet die neue Benutzeroberfläche sowohl in der neuen als auch in der alten Konsole.

[2] In der neuen Konsole können Sie Ihre Amazon-VPC-Subnetze im Bereich Netzwerk anzeigen und verwalten, wenn Sie einen Cluster erstellen. Verwenden Sie in der alten Konsole den Link in der linken Navigationsleiste, um auf die Liste der Amazon-VPC-Subnetze zuzugreifen.

[3] EMR Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Verwenden der alten Konsole

Amazon EMR bietet eine neue Konsolenerfahrung. Die alte Konsole ist veraltet und ist nicht mehr verfügbar.

Zusammenfassung der Unterschiede

In diesem Abschnitt werden die Unterschiede zwischen der alten Amazon-EMR-Konsole und der neuen Amazon-EMR-Konsole beschrieben. Die Unterschiede lassen sich in die folgenden Kategorien einteilen:

- Cluster-Kompatibilität zwischen alter und neuer Konsole
- Unterschiede beim Erstellen von Clustern
- Unterschiede beim Anzeigen oder Bearbeiten von Clusterdetails
- Unterschiede beim Auflisten und Suchen nach Clustern
- Unterschiede bei der Arbeit mit Sicherheitskonfigurationen

Cluster-Kompatibilität zwischen alter und neuer Konsole

In einigen Fällen ist ein Cluster, den Sie in der alten Amazon-EMR-Konsole erstellt haben, möglicherweise nicht mit der neuen Konsole kompatibel. In der folgenden Liste werden die Kompatibilitätsanforderungen für die neue Amazon-EMR-Konsole beschrieben.

- Die neue Konsole unterstützt Cluster, die in den Amazon-EMR-Versionen 5.20.1 und höher erstellt wurden.
- In der neuen Konsole können Sie Cluster klonen, das Auto Scaling verwenden, aber Sie können nur neue Cluster erstellen, wenn Sie sie manuell skalieren oder verwaltete Skalierung verwenden möchten.

Um Cluster zu erstellen und mit ihnen zu arbeiten, die nicht mit der neuen Konsole kompatibel sind, können Sie das AWS Command Line Interface (AWS CLI), das AWS-SDK oder die alte Konsole verwenden.

Unterschiede beim Erstellen von Clustern

In der folgenden Tabelle sind die Unterschiede aufgeführt, die Sie erwarten können, wenn Sie Cluster mit der neuen Amazon-EMR-Konsole im Gegensatz zur alten Amazon-EMR-Konsole erstellen.

Funktion	New console	Alte Konsole
	Primär, Core, Aufgabe	Haupt, Core, Aufgabe

Funktion	New console	Alte Konsole
Terminologie: Amazon-EMR-Cluster-Knotentypen		
Von Amazon EMR unterstützte Versionen 1	Amazon-EMR-Version 5.20.1 und höher	Alle Amazon-EMR-Versionen
Schnelles Starten eines Clusters	Verwenden Sie die Schaltfläche Cluster erstellen im Bereich Zusammenfassung	Verwenden Sie die Seite Cluster erstellen – Schnelloptionen
Konfiguration eines Timeouts für die Spot-Bereitstellung	Definieren Sie einen Timeout-Zeitraum für die Bereitstellung von Instances für jede Flotte in Ihrem Cluster.	Sie können ein Bereitstellungs-Timeout nicht anpassen, wenn Sie einen Cluster erstellen.
Servicerollen und Amazon-EC2-Instance-Profilrolle	Die neue Konsole erstellt keine Standardrollen. Sie müssen Rollen mit der IAM-Konsole erstellen oder eine bereits erstellte IAM-Rolle auswählen	Unterstützt die Standardrollenerstellung mit V1- und V2-Richtlinien, oder Sie können eine bereits erstellte IAM-Rolle auswählen
Transparenz der Cluster	Von der Amazon-EMR-Konsole aus können Sie einen Cluster nicht für alle Benutzer sichtbar machen. Ihre IAM-Richtlinie bestimmt den Clusterzugriff	In der Amazon-EMR-Konsole können Sie einen Cluster für alle Benutzer sichtbar machen, wenn Sie die veralteten v1-Richtlinien zur Rollenerstellung verwenden.

Funktion	New console	Alte Konsole
Netzwerk – konfigurieren Sie private Subnetze	Sie müssen Amazon-S3 -Endpunkte und NAT-Gateways von ihren jeweiligen Amazon-S3- und Amazon-VPC-Konsolen aus konfigurieren.	Sie können Amazon-S3-Endpunkte und NAT-Gateways direkt über den Workflow „Cluster erstellen“ in der alten Konsole konfigurieren.
Konsistente Ansicht des EMR-Dateisystems (EMRFS CV)	Mit der Veröffentlichung von Amazon S3 mit starker Lese-nach-Schreib-Konsistenz am 1. Dezember 2020 müssen Sie EMRFS CV nicht mit Ihren EMR-Clustern verwenden	EMRFS CV ist aktiviert, aber Sie können EMRFS CV deaktivieren und die verwendete Amazon-DynamoDB-Datenbank löschen. Weitere Informationen finden Sie unter Konsistente Ansicht
Debugging	Sie können Aufträge mithilfe der Benutzeroberfläche der Anwendung auf der Cluster-Detailseite debuggen	Sie können ein Debugger-Tool (Schritt 3 in den erweiterten Optionen) verwenden, um Aufträge für Cluster zu debuggen, die auf den Amazon-EMR-Versionen 4.1.0 bis 5.27.0 ausgeführt werden.

[1] Sie können in der neuen Konsole keine Cluster mit Versionen vor Amazon EMR 5.20.1 erstellen oder bearbeiten, aber alle vorhandenen Cluster, die mit Versionen vor 5.20.1 erstellt wurden, funktionieren weiterhin. Um Cluster mit Amazon-EMR-Versionen vor 5.20.1 zu erstellen und zu bearbeiten, verwenden Sie die API oder CLI oder wechseln Sie zurück zur alten Konsole.

Unterschiede beim Auflisten und Suchen nach Clustern

In der folgenden Tabelle sind die Unterschiede aufgeführt, die Sie erwarten können, wenn Sie Cluster in der Listenansicht mit der neuen Amazon-EMR-Konsole im Gegensatz zur alten Amazon-EMR-Konsole anzeigen und danach suchen.

> **Note**
>
> Sowohl für die alte als auch für die neue Konsole gilt: Wenn Sie einen Datenfilter auf die Clusterliste anwenden, wird die gesamte Datenbank abgefragt. Wenn Sie jedoch eine Textzeichenfolge in das Suchfeld eingeben, gilt die Suche nur für die Ergebnisse, die die Liste clientseitig geladen hat.

Funktion	New console	Alte Konsole
Anzeigen von Cluster-Details	Sie können die Cluster-ID auswählen, um umfassende Cluster-Details wie Konfigurationsoptionen, persistente Anwendungs-Benutzeroberflächen und Protokolle anzuzeigen.	Sie können jede Clusterzeile erweitern und reduzieren, um Informationen wie Konfigurationsdetails anzuzeigen und auf Links für die Clusterüberwachung und Protokolle zuzugreifen.
Suchen nach Clustern	Verwenden Sie ein einziges Suchfeld, um Textsuchabfragen einzugeben und Datenfilter wie „Status = Beliebiger aktiver Status“ zu erstellen und anzuwenden.	Verwenden Sie ein Dropdownmenü, um den Status der Cluster (Aktiv, Terminiert, Fehlgeschlagen) zu verfeinern, und ein separates Feld, um eine Textsuchabfrage einzugeben.
Nach ausgefallenen Clustern suchen	Um nach ausgefallenen Clustern zu suchen, wenden Sie den Filter Status = Mit Fehlern beendet an.	Um nach ausgefallenen Clustern zu suchen, wenden Sie den Filter Fehlgeschlagene Cluster an.

Unterschiede beim Anzeigen oder Bearbeiten von Clusterdetails

In der folgenden Tabelle sind die Unterschiede aufgeführt, die Sie erwarten können, wenn Sie die Details für einen vorhandenen Cluster mit der neuen Amazon-EMR-Konsole im Gegensatz zur alten Amazon-EMR-Konsole anzeigen oder bearbeiten.

Funktion	New console	Alte Konsole
Anzeige der Instances in Ihren Instance-Gruppen und Instance-Flotten sowie der Optionen für Skalierung, Bereitstellung, Größenänderung und Kündigung	Instance-Optionen und -Details finden Sie auf der Registerkarte Instances. Sehen Sie sich die Kündigungsoptionen auf der Registerkarte „Eigenschaften“ an.	Sehen Sie sich die Optionen für die Konfiguration und Kündigung der Instance auf der Registerkarte Hardware an.
Benutzeroberflächen, Protokolle und Konfigurationen von Apps anzeigen (Apache-Spark-Benutzeroberfläche, Spark-Verlaufsservice, Apache-Tez-Benutzeroberfläche, YARN-Zeitleistenserver)	Sehen Sie sich die Cluster-Konfigurationen auf der Registerkarte Konfigurationen an. Starten Sie eine persistente Live-Anwendungsoberfläche, um die Protokolle für eine Anwendung auf der Registerkarte „Anwendungen“ anzuzeigen.	Sehen Sie sich die Cluster-Konfigurationen auf der Registerkarte Konfigurationen an. Starten Sie eine persistente Live-Anwendungsoberfläche, um die Protokolle für eine Anwendung auf der Registerkarte Benutzeroberflächen für Anwendungen anzuzeigen. Ab Januar 2023 ist der Anwendungsverlauf auf hoher Ebene nicht mehr verfügbar.
Exportieren eines Clusters nach CLI	Die Option ist in den Aktionsmenüs „Cluster-Detail“ und „Listenansicht“ als „Befehl zum Klonen eines Clusters anzeigen“ verfügbar	Diese Option ist in den Aktionsmenüs der Cluster-Listenansicht als „AWS CLI exportieren“ verfügbar

Unterschiede bei der Arbeit mit Sicherheitskonfigurationen

In der folgenden Tabelle sind die Unterschiede aufgeführt, die Sie erwarten können, wenn Sie Sicherheitsoptionen mit der neuen Amazon-EMR-Konsole im Gegensatz zur alten Amazon-EMR-Konsole konfigurieren.

Funktion	New console	Alte Konsole
Klonen von Sicherheitskonfigurationen	✓	
Föderierte Verwaltung mit Trino und Apache Ranger	✓	
Eine Runtime-Rolle verwenden, um Arbeit an einen Cluster zu übermitteln [1]	✓	
Zugriff auf EMR-Dateisystem (EMRFS)	Amazon S3 Access Points	AWS Identity and Access Management (IAM)-Rollen
AWS Lake Formation-Zugriffskontrollen	Laufzeit-Rollen	SAML-Verbund

[1] Um eine Rolle während der Schrittübermittlung zu übergeben, muss Ihr Cluster eine Sicherheitskonfiguration mit einer angehängten IAM-Berechtigungsrichtlinie verwenden, sodass ein Benutzer nur die genehmigten Rollen weitergeben kann und Ihre Aufträge auf Amazon-EMR-Ressourcen zugreifen können. Weitere Informationen finden Sie unter Schritte für Laufzeit-Rollen für Amazon EMR.

Amazon EMR Studio

Amazon EMR Studio ist eine webbasierte integrierte Entwicklungsumgebung (IDE) für vollständig verwaltete Jupyter Notebooks, die auf Amazon-EMR-Clustern ausgeführt werden. Sie können ein EMR Studio für Ihr Team einrichten, um in R, Python, Scala und PySpark geschriebene Anwendungen zu entwickeln, zu visualisieren und zu debuggen. EMR Studio ist in AWS Identity and Access Management (IAM) und IAM Identity Center integriert, sodass sich Benutzer mit ihren Unternehmensanmeldedaten anmelden können.

Sie können ein EMR Studio kostenlos erstellen. Wenn Sie EMR Studio verwenden, fallen Gebühren für Amazon-S3-Speicher und Amazon-EMR-Cluster an. Highlights, weitere Produktdetails und Preise finden Sie auf der Serviceseite für Amazon EMR Studio.

Hauptfeatures von EMR Studio

Amazon EMR Studio bietet die folgenden Features:

- Authentifizieren Sie Benutzer mit AWS Identity and Access Management (IAM) oder AWS IAM Identity Center (IAM Identity Center) und Ihrem Enterprise Identity Provider.
- Greifen Sie bei Bedarf auf Amazon-EMR-Cluster zu und starten Sie sie, um Jupyter-Notebook-Aufträge auszuführen.
- Stellen Sie auf EKS-Clustern eine Verbindung zu Amazon EMR her, um Arbeit einzureichen, während der Auftrag ausgeführt wird.
- Erkunden und speichern Sie Beispiel-Notebooks. Weitere Informationen zu den Beispielnotebooks finden Sie im EMR Studio Notebook GitHub-Repository für Beispiele.
- Analysieren Sie Daten mit Python, PySpark, Spark Scala, Spark R oder SparkSQL und installieren Sie benutzerdefinierte Kernel und Bibliotheken.
- Arbeiten Sie in Echtzeit mit anderen Benutzern in demselben Workspace zusammen. Weitere Informationen finden Sie unter Konfigurieren Sie die Zusammenarbeit im Workspace.
- Verwenden Sie den EMR Studio SQL Explorer, um Ihren Datenkatalog zu durchsuchen, SQL-Abfragen auszuführen und Ergebnisse herunterzuladen, bevor Sie mit den Daten in einem Notebook arbeiten.
- Führen Sie parametrisierte Notebooks als Teil von geplanten Workflows mit einem Orchestrierungstool wie Apache Airflow oder Amazon Managed Workflows für Apache Airflow aus.

Weitere Informationen finden Sie unter Orchestrieren von Analyseaufträgen auf EMR Notebooks mithilfe von MWAA im AWS-Big-Data-Blog.

- Verknüpfen Sie Code-Repositorys wie GitHub und BitBucket.
- Verfolgen und debuggen Sie Jobs mit dem Spark History Server, der Tez-Benutzeroberfläche oder dem YARN-Timeline-Server.

EMR Studio ist auch HIPAA-fähig und nach HITRUST CSF und SOC 2 zertifiziert. Weitere Informationen über HIPAA-Compliance für AWS-Services finden Sie unter https://aws.amazon.com/compliance/hipaa-compliance/. Weitere Informationen zur HITRUST CSF-Konformität für AWS-Services finden Sie unter https://aws.amazon.com/compliance/hitrust/. Weitere Informationen zu anderen Compliance-Programmen für AWS-Services finden Sie unter AWS-Services im Leistungsumfang nach Compliance-Programmen.

Verlauf der Features von Amazon EMR Studio

In dieser Tabelle sind Aktualisierungen zur Funktion Amazon EMR Managed Scaling aufgeführt.

Datum der Veröffentlichung	Funktion
26. Oktober 2023	Es wurde die Möglichkeit hinzugefügt, eine Serverless-EMR-Anwendung mit interaktiven Funktionen zu erstellen.
28. Februar 2023	Kundenverwaltete AWS KMS-Schlüsselunterstützung für die Speicherung von Anwendungsprotokollen für Serverless-EMR-Anwendungen hinzugefügt.
23. Februar 2023	Es wurde die Erstellung von IAM-Rollen mit einem Klick für die Serverless-EMR-Auftragsübermittlung hinzugefügt. ECR-Suche hinzugefügt, wenn Sie ein benutzerdefiniertes Image für EMR-Serverless-Anwendungen auswählen.
27. Januar 2023	Notebooks mit Headless-Ausführung können den Fortschritt jeder einzelnen Zellenausführung `%execute_notebook` auf magische Weise verfolgen.
23. Januar 2023	Persistente Anwendungen wurden für schnellere Startzeiten optimiert.

Wie Amazon EMR Studio funktioniert

Ein Amazon EMR Studio ist eine Amazon-EMR-Ressource, die Sie für ein Team von Benutzern erstellen. EMR Studio ist eine webbasierte, integrierte Entwicklungsumgebung für vollständig verwaltete Jupyter-Notebooks, die auf Amazon-EMR-Clustern ausgeführt werden. Benutzer melden sich mit Unternehmensanmeldeinformationen bei einem Studio an.

Jedes EMR Studio, das Sie erstellen, verwendet die folgenden AWS-Ressourcen:

- Eine Amazon Virtual Private Cloud (VPC) mit Subnetzen – Benutzer führen Studio-Kernel und -Anwendungen auf Amazon EMR und Amazon EMR auf EKS-Clustern in der angegebenen VPC aus. Ein EMR Studio kann eine Verbindung zu jedem Cluster in den Subnetzen herstellen, die Sie beim Erstellen des Studios angeben.
- IAM-Rollen und Berechtigungsrichtlinien – Um Benutzerberechtigungen zu verwalten, erstellen Sie IAM-Berechtigungsrichtlinien, die Sie der IAM-Identität eines Benutzers oder einer Benutzerrolle zuordnen. EMR Studio verwendet auch eine IAM-Servicerolle und Sicherheitsgruppen, um mit anderen AWS-Services zusammenzuarbeiten. Weitere Informationen finden Sie unter Zugriffskontrolle und Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio.
- Sicherheitsgruppen – EMR Studio verwendet Sicherheitsgruppen, um einen sicheren Netzwerkkanal zwischen dem Studio und einem EMR-Cluster einzurichten.
- Ein Amazon-S3-Backup-Speicherort – EMR Studio speichert Notebookarbeiten an einem Amazon-S3-Speicherort.

In den folgenden Schritten wird beschrieben, wie Sie ein EMR Studio erstellen und verwalten:

1. Erstellen Sie ein Studio in Ihrem AWS-Konto mit entweder IAM- oder IAM-Identity-Center-Authentifizierung. Detaillierte Anweisungen finden Sie unter Ein Amazon EMR Studio einrichten.
2. Weisen Sie Ihrem Studio Benutzer und Gruppen zu. Verwenden Sie Berechtigungsrichtlinien, um detaillierte Berechtigungen für jeden Benutzer festzulegen. Weitere Informationen finden Sie im Thema EMR-Studio-Benutzer zuweisen und verwalten .
3. Beginnen Sie mit der Überwachung von EMR-Studio-Aktionen mit AWS CloudTrail-Ereignissen. Weitere Informationen finden Sie unter Amazon-EMR-Studio-Aktionen überwachen.
4. Bieten Sie Studio-Benutzern mehr Cluster-Optionen mit Cluster-Vorlagen und Amazon EMR in EKS-verwalteten Endpunkten.

Authentifizierung und Benutzeranmeldung

Amazon EMR Studio unterstützt zwei Authentifizierungsmodi: den IAM-Authentifizierungsmodus und den IAM-Identity-Center-Authentifizierungsmodus. Der IAM-Modus verwendet AWS Identity and Access Management (IAM), während der IAM-Identity-Center-Modus AWS IAM Identity Center verwendet. Wenn Sie ein EMR Studio erstellen, wählen Sie den Authentifizierungsmodus für alle Benutzer dieses Studios.

IAM-Authentifizierungsmodus

Im IAM-Authentifizierungsmodus können Sie entweder die IAM-Authentifizierung oder den IAM-Verbund verwenden.

Mit der IAM-Authentifizierung können Sie IAM-Identitäten wie Benutzer, Gruppen und Rollen in IAM verwalten. Sie gewähren Benutzern Zugriff auf ein Studio mit IAM-Berechtigungsrichtlinien und attributbasierter Zugriffskontrolle (ABAC).

Mit dem IAM-Verbund können Sie Vertrauen zwischen einem externen Identitätsanbieter (IdP) aufbauen und AWS-Benutzeridentitäten über Ihren IdP verwalten.

Authentifizierungsmodus von IAM Identity Center

Mit dem IAM-Identity-Center-Authentifizierungsmodus können Sie Benutzern Verbundzugriff auf ein EMR Studio gewähren. Sie können IAM Identity Center verwenden, um Benutzer und Gruppen aus Ihrem IAM-Identity-Center-Verzeichnis, Ihrem vorhandenen Unternehmensverzeichnis oder einem externen IdP wie Azure Active Directory (AD) zu authentifizieren. Sie verwalten dann Benutzer mit Ihrem Identitätsanbieter (IdP).

EMR Studio unterstützt die Verwendung der folgenden Identitätsanbieter für IAM Identity Center:

- AWS Managed Microsoft AD und selbstverwaltetes Active Directory – Weitere Informationen finden Sie unter Verbindung mit Ihrem Microsoft-AD-Verzeichnis herstellen.
- SAML-basierte Anbieter – Eine vollständige Liste finden Sie unter Unterstützte Identitätsanbieter.
- Das IAM-Identity-Center-Verzeichnis – Weitere Informationen finden Sie unter Identitäten im IAM Identity Center verwalten.

Wie sich die Authentifizierung auf die Anmeldung und die Benutzerzuweisung auswirkt

Der Authentifizierungsmodus, den Sie für EMR Studio wählen, wirkt sich darauf aus, wie sich Benutzer bei einem Studio anmelden, wie Sie einen Benutzer einem Studio zuweisen und wie Sie Benutzer autorisieren (ihnen Berechtigungen erteilen), Aktionen wie das Erstellen neuer Amazon-EMR-Cluster auszuführen.

In der folgenden Tabelle sind die Anmeldemethoden für EMR Studio nach Authentifizierungsmodus zusammengefasst.

EMR-Studio-Anmeldeoptionen nach Authentifizierungsmodus

Authentifizierungsmodus	Anmelde-Methode	Beschreibung
• IAM (Authentifizierung und Verbund) • IAM Identity Center	EMR-Studio-URL	Benutzer melden sich mit der Studio-Zugriffs-URL bei einem Studio an. Zum Beispiel `https://xxxxxxxxxxxxxxxxxxxxxx.emrstudio-prod.us-east-1.amazonaws.com` . Benutzer geben IAM-Anmeldeinformationen ein, wenn Sie die IAM-Authentifizierung verwenden. Wenn Sie IAM-Verbund oder IAM Identity Center verwenden, leitet EMR Studio Benutzer zur Eingabe der Anmeldeinformationen zur Anmelde-URL Ihres Identitätsanbieters weiter. Im Zusammenhang mit dem Identitätsverbund wird diese Anmeldeoption als vom Serviceanbieter (SP) initiierte Anmeldung bezeichnet.
• IAM (Verbund) • IAM Identity Center	Identitätsanbieter-(IdP)-Portal	Benutzer melden sich beim Portal Ihres Identitätsanbieters an, z. B. beim Azure-Portal, und starten die Amazon-EMR-Konsole. Nach dem Start der Amazon-EMR-Konsole wählen Benutzer ein Studio aus der Studio-Liste aus und öffnen es. Sie können EMR Studio auch als SAML-Anwendung konfigurieren, sodass sich Benutzer über das Portal Ihres Identitätsanbieters bei einem

Authentifizierungsmodus	Anmelde-Methode	Beschreibung
		bestimmten Studio anmelden können. Anweisungen finden Sie unter So konfigurieren Sie ein EMR Studio als SAML-Anwendung in Ihrem IdP-Portal. Im Zusammenhang mit dem Identitätsverbund wird diese Anmeldeoption als vom Identitätsanbieter (IdP) initiierte Anmeldung bezeichnet.
• IAM (Authentifizierung)	AWS Management Console	Benutzer melden sich bei AWS Management Console mit IAM-Anmeldeinformationen an und öffnen ein Studio aus der Studios-Liste in der Amazon-EMR-Konsole.

In der folgenden Tabelle werden die Benutzerzuweisung und Autorisierung für EMR Studio nach Authentifizierungsmodus beschrieben.

EMR Studio Benutzerzuweisung und Autorisierung im Authentifizierungsmodus

Authentifizierungsmodus	Benutzerzuweisung	Benutzer-Autorisierung
IAM (Authentifizierung und Verbund)	Zulassen der `CreateStudioPresignedUrl` Aktion in einer IAM-Berechtigungsrichtlinie, die an eine IAM-Identität (Benutzer, Gruppe oder Rolle) angefügt ist. Lassen Sie für Verbundbenutzer die `CreateStudioPresignedUrl` -Aktion in einem IAM in der Berechtigungsrichtlinie zu, die Sie für die IAM-Rolle konfigurieren, die Sie für den Verbund verwenden.	Definieren Sie IAM-Berechtigungsrichtlinien, die bestimmte EMR-Studio-Aktionen zulassen. Hängen Sie für native Benutzer die IAM-Berechtigungsrichtlinie an eine IAM-Identität (Benutzer, Gruppe oder Rolle) an. Lassen Sie für Verbundbenutzer Studio-Aktionen in der Berechtigungsrichtlinie zu, die Sie für die IAM-Rolle konfigurieren, die Sie für den Verbund verwenden. Weitere Informationen finden Sie unter EMR-Studio-Benutzerberechti

Authentifizierungsmodus	Benutzerzuweisung	Benutzer-Autorisierung
	Verwenden Sie die attributb asierte Zugriffskontrolle (ABAC), um das Studio oder die Studios anzugeben, auf die der Benutzer zugreifen kann. Detaillierte Anweisungen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.	gungen für Amazon EC2 oder Amazon EKS konfigurieren.
IAM Identity Center	Weisen Sie einem Studio einen Benutzer zu, indem Sie den Benutzer einem Studio mit einer bestimmten Sitzungsrichtlinie zuordnen. Detaillierte Anweisungen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.	Definieren Sie IAM-Sitzungsrichtlinien, die bestimmte EMR-Studio-Aktionen zulassen. Ordnen Sie einem Benutzer eine Sitzungsrichtlinie zu, wenn Sie ihn einem Studio zuweisen. Weitere Informationen finden Sie unter Benutzerberechtigungen für den IAM-Identity-Center-Authentifizierungsmodus.

Zugriffskontrolle

In Amazon EMR Studio konfigurieren Sie die Benutzerautorisierung (Berechtigungen) mit identitätsbasierten AWS Identity and Access Management (IAM)-Richtlinien. In diesen Richtlinien geben Sie zulässige Aktionen und Ressourcen sowie die Bedingungen an, unter denen die Aktionen zulässig sind.

Benutzerberechtigungen für den IAM-Authentifizierungsmodus

Um Benutzerberechtigungen festzulegen, wenn Sie die IAM-Authentifizierung für EMR Studio verwenden, lassen Sie Aktionen zu, z. B. `elasticmapreduce:RunJobFlow` in einer IAM-Berechtigungsrichtlinie. Sie können eine oder mehrere zu verwendende Berechtigungsrichtlinien erstellen. Sie könnten beispielsweise eine grundlegende Richtlinie erstellen, die es einem

Benutzer nicht erlaubt, neue Amazon-EMR-Cluster zu erstellen, und eine weitere Richtlinie, die die Clustererstellung zulässt. Eine Liste aller Studio-Aktionen finden Sie unter AWS Identity and Access Management-Berechtigungen für EMR-Studio-Benutzer.

Benutzerberechtigungen für den IAM-Identity-Center-Authentifizierungsmodus

Wenn Sie die IAM-Identity-Center-Authentifizierung verwenden, erstellen Sie eine einzelne EMR-Studio-Benutzerrolle. Die Benutzerrolle ist eine dedizierte IAM-Rolle, die ein Studio annimmt, wenn sich ein Benutzer anmeldet.

Sie fügen der EMR-Studio-Benutzerrolle IAM-Sitzungsrichtlinien hinzu. Eine Sitzungsrichtlinie ist eine spezielle Art von IAM-Berechtigungsrichtlinie, die einschränkt, was ein Verbundbenutzer während einer Studio-Anmeldesitzung tun kann. Mit Sitzungsrichtlinien können Sie spezifische Berechtigungen für einen Benutzer oder eine Gruppe festlegen, ohne mehrere Benutzerrollen für EMR Studio erstellen zu müssen.

Wenn Sie einem Studio Benutzer und Gruppen zuweisen, ordnen Sie diesem Benutzer oder dieser Gruppe eine Sitzungsrichtlinie zu, um detaillierte Berechtigungen anzuwenden. Sie können die Sitzungsrichtlinie eines Benutzers oder einer Gruppe auch jederzeit aktualisieren. Amazon EMR speichert jede Sitzungsrichtlinienzuweisung, die Sie erstellen.

Weitere allgemeine Informationen zu Sitzungs-Richtlinien finden Sie unter Berechtigungen und Richtlinien im AWS Identity and Access Management-Benutzerhandbuch.

Workspaces

Workspaces sind die wichtigsten Bausteine von Amazon EMR Studio. Um Notebooks zu organisieren, erstellen Benutzer einen oder mehrere Workspaces in einem Studio. Weitere Informationen finden Sie unter Informationen über Workspace-Grundlagen.

Ähnlich wie Workspaces in JupyterLab behält ein Workspace den Status der Notebook-Arbeit bei. Die Workspace-Benutzeroberfläche erweitert jedoch die Open-Source-Benutzeroberfläche von JupyterLab um zusätzliche Tools, mit denen Sie EMR-Cluster erstellen und anhängen, Aufträge ausführen, Beispiel-Notebooks durchsuchen und Git-Repositorys verknüpfen können.

Die folgende Liste enthält die wichtigsten Features von EMR Studio Workspaces:

- Die Sichtbarkeit von Workspace basiert auf Studio. Workspaces, die Sie in einem Studio erstellen, sind in anderen Studios nicht sichtbar.

- Standardmäßig wird ein Workspace geteilt und kann von allen Studio-Benutzern gesehen werden. Es kann jedoch jeweils nur ein Benutzer einen Workspace öffnen und darin arbeiten. Um gleichzeitig mit anderen Benutzern zu arbeiten, können Sie Konfigurieren Sie die Zusammenarbeit im Workspace
- Sie können gleichzeitig mit anderen Benutzern in einem Workspace zusammenarbeiten, wenn Sie die Workspace-Zusammenarbeit aktivieren. Weitere Informationen finden Sie unter Konfigurieren Sie die Zusammenarbeit im Workspace.
- Notebooks in einem Workspace verwenden denselben EMR-Cluster, um Befehle auszuführen. Sie können einen Workspace an einen Amazon-EMR-Cluster anhängen, der auf Amazon EC2 ausgeführt wird, oder an einen virtuellen Amazon EMR in EKS-Cluster und verwalteten Endpunkt.
- Workspaces können zu einer anderen Availability Zone wechseln, die Sie den Subnetzen eines Studios zuordnen. Sie können einen Workspace beenden und neu starten, um den Failover-Prozess einzuleiten. Wenn Sie einen Workspace neu starten, startet EMR Studio den Workspace in einer anderen Availability Zone in der VPC des Studios, wenn das Studio mit Zugriff auf mehrere Availability Zones konfiguriert ist. Wenn das Studio nur über eine Availability Zone verfügt, versucht EMR Studio, den Workspace in einem anderen Subnetz zu starten. Weitere Informationen finden Sie unter Beheben von Workspace-Verbindungsproblemen.
- Ein Workspace kann eine Verbindung zu Clustern in allen Subnetzen herstellen, die einem Studio zugeordnet sind.

Weitere Informationen zum Erstellen und Konfigurieren von EMR Studio Workspaces finden Sie unter Informationen über Workspace-Grundlagen.

Notebook-Speicher in Amazon EMR Studio

Wenn Sie einen Workspace verwenden, speichert EMR Studio die Zellen in Notebookdateien automatisch in regelmäßigen Abständen an dem Amazon-S3-Speicherort, der mit Ihrem Studio verknüpft ist. Bei diesem Backup-Prozess bleibt die Arbeit zwischen den Sitzungen erhalten, sodass Sie später darauf zurückgreifen können, ohne Änderungen an ein Git-Repository zu übertragen. Weitere Informationen finden Sie unter Workspace-Inhalt speichern.

Wenn Sie eine Notebook-Datei aus einem Workspace löschen, löscht EMR Studio die Backup-Version für Sie aus Amazon S3. Wenn Sie jedoch einen Workspace löschen, ohne zuerst die zugehörigen Notebookdateien zu löschen, verbleiben die Notebookdateien in Amazon S3 und es fallen weiterhin Speichergebühren an. Weitere Informationen hierzu finden Sie unter Löschen Sie einen Workspace und Notebookdateien.

Überlegungen zu EMR Studio

Überlegungen

Beachten Sie Folgendes, wenn Sie mit EMR Studio arbeiten:

- EMR Studio ist in den folgenden AWS-Regionen verfügbar: USA Ost (Nord-Virginia, Ohio), USA West (Nordkalifornien, Oregon), Asien-Pazifik (Mumbai, Seoul, Singapur, Sydney, Tokio), Kanada (Zentral), EU (Frankfurt, Irland, London, Paris, Stockholm) und Südamerika (São Paulo).
- Damit Benutzer neue EMR-Cluster, die auf Amazon EC2 laufen, für einen Workspace bereitstellen können, können Sie ein EMR Studio mit einer Reihe von Cluster-Vorlagen verknüpfen. Administratoren können Clustervorlagen mit Service Catalog definieren und wählen, ob ein Benutzer oder eine Gruppe innerhalb eines Studios auf die Clustervorlagen zugreifen kann oder keine Clustervorlagen.
- Wenn Sie Zugriffsberechtigungen für in Amazon S3 gespeicherte Notebookdateien oder Lesegeheimnisse von AWS Secrets Manager definieren, verwenden Sie die Amazon-EMR-Servicerolle. Sitzungsrichtlinien werden mit diesen Berechtigungen nicht unterstützt.
- Sie können mehrere EMR-Studios erstellen, um den Zugriff auf EMR-Cluster in verschiedenen VPCs zu steuern.
- Verwenden Sie die AWS CLI, um Amazon EMR in EKS-Clustern einzurichten. Anschließend können Sie die Studio-Oberfläche verwenden, um Cluster an Workspaces mit einem verwalteten Endpunkt anzuhängen, um Notebook-Jobs auszuführen.
- EMR Studio unterstützt die folgenden magischen Python-Befehle nicht:
  - `%alias`
  - `%alias_magic`
  - `%automagic`
  - `%macro`
  - `%%js`
  - `%%javascript`
  - Ändern von `proxy_user` mit `%configure`
  - Ändern von `KERNEL_USERNAME` mit `%env` oder `%set_env`
- Amazon EMR in EKS-Cluster unterstützten keine SparkMagic-Befehle für EMR Studio.

- Um mehrzeilige Scala-Anweisungen in Notebookzellen zu schreiben, stellen Sie sicher, dass alle Zeilen bis auf die letzte mit einem Punkt enden. Im folgenden Beispiel wird die richtige Syntax für mehrzeilige Scala-Anweisungen verwendet.

```
val df = spark.sql("SELECT * from table_name).
        filter("col1=='value'").
        limit(50)
```

Bekannte Probleme

- Stellen Sie sicher, dass Sie Proxy-Management-Tools wie FoxyProxy oder SwitchyOmega im Browser deaktivieren, bevor Sie ein Studio erstellen. Aktive Proxys können Fehler verursachen, wenn Sie Studio erstellen wählen, und zu einer Netzwerkfehler-Fehlermeldung führen.
- Kernel, die auf Amazon EMR in EKS-Clustern ausgeführt werden, können aufgrund von Timeout-Problemen nicht gestartet werden. Wenn beim Starten des Kernels ein Fehler oder ein Problem auftritt, schließen Sie die Notebook-Datei, fahren Sie den Kernel herunter und öffnen Sie die Notebook-Datei erneut.
- Der Kernel-Neustartvorgang funktioniert nicht wie erwartet, wenn Sie einen Cluster von Amazon EMR in EKS verwenden. Nachdem Sie Kernel neu starten ausgewählt haben, aktualisieren Sie den Workspace, damit der Neustart wirksam wird.
- Wenn ein Workspace nicht an einen Cluster angehängt ist, wird eine Fehlermeldung angezeigt, wenn ein Studio-Benutzer eine Notebook-Datei öffnet und versucht, einen Kernel auszuwählen. Sie können diese Fehlermeldung ignorieren, indem Sie OK wählen, aber Sie müssen den Workspace an einen Cluster anhängen und einen Kernel auswählen, bevor Sie Notebook-Code ausführen können.
- Wenn Sie Amazon EMR 6.2.0 mit einer Sicherheitskonfiguration verwenden, um die Clustersicherheit einzurichten, erscheint die Workspace-Oberfläche leer und funktioniert nicht wie erwartet. Wir empfehlen Ihnen, eine andere unterstützte Version von Amazon EMR zu verwenden, wenn Sie Datenverschlüsselung oder Amazon-S3-Autorisierung für EMRFS für einen Cluster konfigurieren möchten. EMR Studio funktioniert mit den Amazon-EMR-Versionen 5.32.0 (Amazon-EMR-5.x-Serie) oder 6.2.0 (Amazon-EMR-6.x-Serie) und höher.
- Wenn Sie die Cluster-Spark-Benutzeroberfläche von einer Notebook-Datei aus starten, können Sie nach dem Ausführen des Notebook-Codes Informationen zu einem Auftrag sehen. Wenn Sie den Spark History Server jedoch über die Studio-Cluster-Liste starten, wird der Auftrag möglicherweise erst nach zwei Minuten angezeigt.

- Wenn Sie Debuggen von Amazon EMR, das in Amazon-EC2-Aufträgen ausgeführt wird, funktionieren die Links zur Spark-Benutzeroberfläche auf dem Cluster möglicherweise nicht oder werden nicht angezeigt. Um die Links zu regenerieren, erstellen Sie eine neue Notebook-Zelle und führen Sie den `%%info`-Befehl aus.
- Jupyter Enterprise Gateway bereinigt in den folgenden Amazon-EMR-Release-Versionen keine inaktiven Kernel auf dem Primärknoten eines Clusters: 5.32.0, 5.33.0, 6.2.0 und 6.3.0. Kernel im Leerlauf verbrauchen Rechenressourcen und können dazu führen, dass Cluster mit langer Laufzeit ausfallen. Mit dem folgenden Beispielskript können Sie die Kernelbereinigung im Leerlauf für Jupyter Enterprise Gateway konfigurieren. Sie können Mit dem Primärknoten über SSH verbinden oder das Skript als Schritt einreichen. Weitere Informationen finden Sie unter Befehle und Skripts auf einem Amazon-EMR-Cluster ausführen.

```
#!/bin/bash
sudo tee -a /emr/notebook-env/conf/jupyter_enterprise_gateway_config.py << EOF
c.MappingKernelManager.cull_connected = True
c.MappingKernelManager.cull_idle_timeout = 10800
c.MappingKernelManager.cull_interval = 300
EOF
sudo systemctl daemon-reload
sudo systemctl restart jupyter_enterprise_gateway
```

- Wenn Sie eine automatische Terminierungsrichtlinie mit den Amazon-EMR-Versionen 5.32.0, 5.33.0, 6.2.0 oder 6.3.0 verwenden, markiert Amazon EMR einen Cluster als inaktiv und beendet den Cluster möglicherweise automatisch, auch wenn Sie einen aktiven Python3-Kernel haben. Das liegt daran, dass bei der Ausführung eines Python3-Kernels kein Spark-Job auf dem Cluster gesendet wird. Um die automatische Terminierung mit einem Python3-Kernel zu verwenden, empfehlen wir die Verwendung von Amazon-EMR-Version 6.4.0 oder höher. Weitere Informationen zum Auto-Beenden finden Sie unter Verwenden einer Richtlinie zur automatischen Beendigung.
- Wenn Sie `%%display` nutzen, um einen Spark-DataFrame in einer Tabelle anzuzeigen, werden sehr breite Tabellen möglicherweise gekürzt. Sie können mit der rechten Maustaste auf die Ausgabe klicken und Neue Ansicht für Ausgabe erstellen auswählen, um eine scrollbare Ansicht der Ausgabe zu erhalten.
- Wenn Sie einen Spark-basierten Kernel wie PySpark, Spark oder SparkR starten, wird eine Spark-Sitzung gestartet, und wenn Sie eine Zelle in einem Notebook ausführen, werden Spark-Aufträge in dieser Sitzung in die Warteschlange gestellt. Wenn Sie eine laufende Zelle unterbrechen, wird der Spark-Auftrag weiter ausgeführt. Um den Spark-Auftrag zu beenden, sollten Sie die Cluster-interne Spark-Benutzeroberfläche verwenden. Weitere Informationen zur Verbindung mit einer

Spark-Benutzeroberfläche finden Sie unter Debuggen von Anwendungen und Aufträgen mit EMR Studio.

Feature-Einschränkungen

Amazon EMR Studio unterstützt die folgenden Amazon-EMR-Feature nicht:

- Anhängen und Ausführen von Aufträgen auf EMR-Clustern mit einer Sicherheitskonfiguration, die die Kerberos-Authentifizierung spezifiziert
- Cluster mit mehreren Primärknoten
- Cluster, die Amazon-EC2-Instances verwenden, die auf AWS Graviton2 für Amazon EMR der 6.x-Versionen unter 6.9.0 und 5.x-Versionen unter 5.36.1 basieren

Service-Limits für EMR Studio

In der folgenden Tabelle werden die Service-Limits für EMR Studio aufgeführt.

Item	Limit
EMR Studios	Maximal 100 pro AWS-Konto
Subnetze	Maximal fünf für jedes EMR-Studio
IAM-Identity-Center-Gruppen	Maximal fünf für jedes EMR-Studio
Benutzer von IAM Identity Center	Maximal 100 für jedes EMR-Studio

Bewährte Methoden für VPC und Subnetze

Die folgenden bewährten Methoden verwenden, um eine Amazon Virtual Private Cloud (Amazon VPC) mit Subnetzen für EMR Studio einzurichten:

- Sie können in Ihrer VPC maximal fünf Subnetze angeben, die Sie dem Studio zuordnen möchten. Wir empfehlen, dass Sie mehrere Subnetze in verschiedenen Availability Zones bereitstellen, um die Workspace-Verfügbarkeit zu unterstützen und Studio-Benutzern Zugriff auf Cluster in verschiedenen Availability Zones zu gewähren. Weitere Informationen zur Arbeit mit VPCs,

Subnetzen und Availability Zones finden Sie unter VPCs und Subnetze im Benutzerhandbuch für Amazon Virtual Private Cloud.

- Die von Ihnen angegebenen Subnetze sollten miteinander kommunizieren können.
- Damit Benutzer einen Workspace mit öffentlich gehosteten Git-Repositorys verknüpfen können, sollten Sie nur private Subnetze angeben, die über Network Address Translation (NAT) Zugriff auf das Internet haben. Weitere Informationen zum Einrichten eines privaten Subnetzes für Amazon EMR finden Sie unter Private Subnetze.
- Wenn Sie Amazon EMR auf EKS mit EMR Studio verwenden, muss mindestens ein gemeinsames Subnetz zwischen Ihrem Studio und dem Amazon-EKS-Cluster vorhanden sein, den Sie zum Registrieren eines virtuellen Clusters verwenden. Andernfalls wird Ihr verwalteter Endpunkt nicht als Option in Studio Workspaces angezeigt. Sie können einen Amazon-EKS-Cluster erstellen und ihn einem Subnetz zuordnen, das zum Studio gehört, oder Sie können ein Studio erstellen und die Subnetze Ihres EKS-Clusters angeben.
- Wenn Sie Amazon EMR in EKS mit EMR Studio verwenden möchten, wählen Sie die VPC für Ihre Amazon-EKS-Cluster-Worker-Knoten aus.

Cluster-Anforderungen für Amazon EMR Studio

Amazon-EMR-Cluster, die auf Amazon EC2 ausgeführt werden

Alle Amazon-EMR-Cluster, die auf Amazon EC2 ausgeführt werden und die Sie für einen EMR Studio Workspace erstellen, müssen die folgenden Anforderungen erfüllen. Cluster, die Sie mit der EMR-Studio-Oberfläche erstellen, erfüllen diese Anforderungen automatisch.

- Der Cluster muss Amazon-EMR-Versionen 5.32.0 (Amazon EMR 5.x-Serie) oder 6.2.0 (Amazon EMR 6.x-Serie) oder höher verwenden. Sie können mit der Amazon-EMR-Konsole, AWS Command Line Interface oder dem SDK einen Cluster erstellen und ihn dann an einen Workspace in EMR Studio anhängen. Studio-Benutzer können auch Cluster bereitstellen und anhängen, wenn sie einen Amazon-EMR-Workspace erstellen oder darin arbeiten. Weitere Informationen finden Sie unter Einen Computer an einen EMR Studio Workspace anhängen.
- Dieser Cluster muss sich innerhalb einer Amazon Virtual Private Cloud befinden. Die EC2-Classic-Plattform wird nicht unterstützt.
- Auf dem Cluster müssen Spark, Livy und Jupyter Enterprise Gateway installiert sein. Wenn Sie den Cluster für SQL Explorer verwenden möchten, sollten Sie sowohl Presto als auch Spark installieren.

- Um SQL Explorer verwenden zu können, muss der Cluster Amazon-EMR-Version 5.34.0 oder höher oder Version 6.4.0 oder höher verwenden und Presto installiert sein. Wenn Sie den AWS Glue Data Catalog als Hive-Metastore für Presto angeben möchten, müssen Sie ihn auf dem Cluster konfigurieren. Weitere Informationen finden Sie unter Verwendung von Presto mit dem AWS Glue Data Catalog.
- Der Cluster muss sich in einem privaten Subnetz mit Network Address Translation (NAT) befinden, um öffentlich gehostete Git-Repositorys mit EMR Studio verwenden zu können.

Wir empfehlen die folgenden Clusterkonfigurationen, wenn Sie mit EMR Studio arbeiten.

- Stellen Sie den Bereitstellungsmodus für Spark-Sitzungen auf den Clustermodus ein. Im Clustermodus werden die Anwendungsmasterprozesse auf den Core-Knoten und nicht auf dem Primärknoten eines Clusters platziert. Dadurch wird der Primärknoten von potenziellem Speicherdruck entlastet. Weitere Informationen finden Sie unter Cluster Mode Overview in der Apache Spark-Dokumentation.
- Ändern Sie das Livy-Timeout wie in der folgenden Beispielkonfiguration von der Standardeinstellung von einer Stunde auf sechs Stunden.

```
{
    "classification":"livy-conf",
        "Properties":{
            "livy.server.session.timeout":"6h",
            "livy.spark.deploy-mode":"cluster"
        }
}
```

- Erstellen Sie verschiedene Instance-Flotten mit bis zu 30 Instances und wählen Sie mehrere Instance-Typen in Ihrer Spot Instance-Flotte aus. Sie könnten beispielsweise die folgenden arbeitsspeicheroptimierten Instance-Typen für Spark-Workloads angeben: r5.2x, r5.4x, r5.8x, r5.12x, r5.16x, r4.2x, r4.4x, r4.8x, r4.12, usw. Weitere Informationen finden Sie unter Instance-Flotten konfigurieren.
- Verwenden Sie die kapazitätsoptimierte Zuweisungsstrategie für Spot Instances, um Amazon EMR dabei zu unterstützen, eine effektive Instance-Auswahl auf der Grundlage von Echtzeit-Kapazitätsinformationen von Amazon EC2 zu treffen. Weitere Informationen finden Sie unter Zuweisungsstrategie für Flotten.
- Aktivieren Sie die verwaltete Skalierung in Ihrem Cluster. Legen Sie den Parameter für die maximale Anzahl an Core-Knoten auf die minimale persistente Kapazität fest, die Sie verwenden

möchten, und konfigurieren Sie die Skalierung für eine gut diversifizierte Task-Flotte, die auf Spot Instances ausgeführt wird, um Kosten zu sparen. Weitere Informationen finden Sie unter Verwenden der verwalteten Skalierung in Amazon EMR.

Wir bitten Sie außerdem dringend, Amazon EMR Block Public Access aktiviert zu lassen und den eingehenden SSH-Verkehr auf vertrauenswürdige Quellen zu beschränken. Durch den eingehenden Zugriff auf einen Cluster können Benutzer Notebooks auf dem Cluster ausführen. Weitere Informationen finden Sie unter Verwenden von Amazon EMR Block Public Access und Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Cluster von Amazon EMR in EKS

Zusätzlich zu EMR-Clustern, die auf Amazon EC2 ausgeführt werden, können Sie Amazon EMR auf EKS-Clustern für EMR Studio mithilfe von AWS CLI einrichten und verwalten. Richten Sie Amazon EMR auf EKS-Clustern gemäß den folgenden Richtlinien ein:

- Erstellen Sie einen verwalteten HTTPS-Endpunkt für den Cluster von Amazon EMR in EKS. Benutzer hängen einen Workspace an einen verwalteten Endpunkt an. Der Amazon Elastic Kubernetes Service (EKS)-Cluster, den Sie zur Registrierung eines virtuellen Clusters verwenden, muss über ein privates Subnetz verfügen, um verwaltete Endgeräte zu unterstützen.
- Verwenden Sie einen Amazon-EKS-Cluster mit mindestens einem privaten Subnetz und Network Address Translation (NAT), wenn Sie öffentlich gehostete Git-Repositorys verwenden möchten.
- Vermeiden Sie die Verwendung von Amazon-EKS-optimierten Arm-Amazon-Linux-AMIs, die für Endpunkte, die von Amazon EMR auf EKS verwaltet werden, nicht unterstützt werden.
- Vermeiden Sie die AWS Fargate ausschließliche Verwendung von Amazon-EKS-Clustern, die nicht unterstützt werden.

Amazon EMR Studio konfigurieren

Dieser Abschnitt richtet sich an EMR-Studio-Administratoren. Es behandelt, wie Sie ein EMR Studio für Ihr Team einrichten, und enthält Anweisungen für Aufgaben wie das Zuweisen von Benutzern und Gruppen, das Einrichten von Clustervorlagen und das Optimieren von Apache Spark für EMR Studio.

Themen

- Administratorberechtigungen zum Erstellen und Verwalten eines EMR Studios
- Ein Amazon EMR Studio einrichten

- Ein Amazon EMR Studio verwalten
- Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio
- AWS CloudFormation-Vorlagen für Amazon EMR Studio erstellen
- Zugriff und Berechtigungen für Git-basierte Repositorys einrichten
- Spark-Aufträge in EMR Studio optimieren

Administratorberechtigungen zum Erstellen und Verwalten eines EMR Studios

Die auf dieser Seite beschriebenen IAM-Berechtigungen ermöglichen es Ihnen, ein EMR Studio zu erstellen und zu verwalten. Weitere Informationen zu erforderlichen Berechtigungen finden Sie unter Erforderliche Berechtigungen zum Verwalten eines EMR-Studios.

Erforderliche Berechtigungen zum Verwalten eines EMR-Studios

In der folgenden Tabelle sind die Vorgänge im Zusammenhang mit der Erstellung und Verwaltung eines EMR-Studios aufgeführt. In der Tabelle werden auch die für jeden Vorgang erforderlichen Berechtigungen angezeigt.

> **Note**
>
> Sie benötigen nur IAM-Identity-Center- und `SessionMapping`-Studio-Aktionen, wenn Sie den IAM-Identity-Center-Authentifizierungsmodus verwenden.

Berechtigungen zum Erstellen und Verwalten eines EMR Studios

Operation	Berechtigungen
Ein Studio erstellen	`"elasticmapreduce:CreateStudio", "sso:CreateManagedApplicationInstance", "iam:PassRole"`
Ein Studio beschreiben	`"elasticmapreduce:DescribeStudio", "sso:GetManagedApplicationInstance"`

Operation	Berechtigungen
Studios auflisten	`"elasticmapreduce:ListStudios"`
Ein Studio löschen	`"elasticmapreduce:DeleteStudio", "sso:DeleteManagedApplicationInstance"`
Additional permissions required when you use IAM Identity Center mode	
Einem Studio Benutzer oder Gruppen zuweisen	`"elasticmapreduce:CreateStudioSessionMapping", "sso:GetProfile", "sso:ListDirectoryAssociations", "sso:ListProfiles", "sso:AssociateProfile" "sso-directory:SearchUsers", "sso-directory:SearchGroups", "sso-directory:DescribeUser", "sso-directory:DescribeGroup"`
Rufen Sie die Studio-Zuweisungsdetails für einen bestimmten Benutzer oder eine bestimmte Gruppe ab	`"sso-directory:SearchUsers", "sso-directory:SearchGroups", "sso-directory:DescribeUser", "sso-directory:DescribeGroup", "sso:GetManagedApplicationInstance", "elasticmapreduce:GetStudioSessionMapping"`
Alle Benutzer und Gruppen auflisten, die einem Studio zugewiesen sind	`"elasticmapreduce:ListStudioSessionMappings"`

Operation	Berechtigungen
Aktualisieren Sie die Sitzungsrichtlinie, die einem Benutzer oder einer Gruppe zugewiesen ist, die einem Studio zugewiesen ist	`"sso-directory:SearchUsers", "sso-directory:SearchGroups", "sso-directory:DescribeUser", "sso-directory:DescribeGroup", "sso:GetManagedApplicationInstance", "elasticmapreduce:UpdateStudioSessionMapping"`
Einen Benutzer oder eine Gruppe aus einem Studio entfernen	`"elasticmapreduce:DeleteStudioSessionMapping", "sso-directory:SearchUsers", "sso-directory:SearchGroups", "sso-directory:DescribeUser", "sso-directory:DescribeGroup", "sso:ListDirectoryAssociations", "sso:GetProfile", "sso:GetManagedApplicationInstance" "sso:ListProfiles", "sso:DisassociateProfile"`

So erstellen Sie eine Richtlinie mit Administratorberechtigungen für EMR Studio

1. Folgen Sie den Anweisungen unter IAM-Richtlinien erstellen, um eine Richtlinie anhand eines der folgenden Beispiele zu erstellen. Welche Berechtigungen Sie benötigen, hängt von Ihrem Authentifizierungsmodus für EMR Studio ab.

   Fügen Sie Ihre eigenen Werte für diese Elemente ein:

   - Ersetzen Sie *<your-resource-ARN>*, um den Amazon-Ressourcennamen (ARN) des Objekts oder der Objekte anzugeben, für die die Anweisung für Ihre Anwendungsfälle gilt.
   - Ersetzen Sie *<region>* durch den Code des AWS-Region Ortes, an dem Sie das Studio erstellen möchten.
   - Ersetzen Sie *<aws-account_id>* durch die ID des AWS-Kontos für das Studio.
   - Ersetzen Sie *<EMRStudio-Service-Role>* und *<EMRStudio-User-Role>* durch die Namen Ihrer EMR-Studio-Servicerolle und EMR-Studio-Benutzerrolle.

Example Beispielrichtlinie: Administratorberechtigungen, wenn Sie den IAM-Authentifizierungsmodus verwenden

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:<region>:<aws-account-id>:studio/
*",
            "Action": [
                "elasticmapreduce:CreateStudio",
                "elasticmapreduce:DescribeStudio",
                "elasticmapreduce:DeleteStudio"
            ]
        },
        {
            "Effect": "Allow",
            "Resource": "<your-resource-ARN>",
            "Action": [
                "elasticmapreduce:ListStudios"
            ]
        },
        {
            "Effect": "Allow",
            "Resource": [
                "arn:aws:iam::<aws-account-id>:role/<EMRStudio-Service-Role>"
            ],
            "Action": "iam:PassRole"
        }
    ]
}
```

Example Beispielrichtlinie: Administratorberechtigungen, wenn Sie den IAM-Identity-Center-Authentifizierungsmodus verwenden

> **Note**
>
> IAM Identity Center und IAM Identity Center Directory APIs unterstützen nicht die Angabe eines ARN im Resourcen-Element einer IAM-Richtlinienanweisung. Um den

Zugriff auf IAM Identity Center und IAM Identity Center Directory zu ermöglichen, spezifizieren die folgenden Berechtigungen alle Ressourcen, „Resource“: „*“ für IAM-Identity-Center-Aktionen. Weitere Informationen finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für IAM Identity Center Directory.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:<region>:<aws-account-id>:studio/
*",
            "Action": [
                "elasticmapreduce:CreateStudio",
                "elasticmapreduce:DescribeStudio",
                "elasticmapreduce:DeleteStudio",
                "elasticmapreduce:CreateStudioSessionMapping",
                "elasticmapreduce:GetStudioSessionMapping",
                "elasticmapreduce:UpdateStudioSessionMapping",
                "elasticmapreduce:DeleteStudioSessionMapping"
            ]
        },
        {
            "Effect": "Allow",
            "Resource": "<your-resource-ARN>",
            "Action": [
                "elasticmapreduce:ListStudios",
                "elasticmapreduce:ListStudioSessionMappings"
            ]
        },
        {
            "Effect": "Allow",
            "Resource": [
                "arn:aws:iam::<aws-account-id>:role/<EMRStudio-Service-Role>",
                "arn:aws:iam::<aws-account-id>:role/<EMRStudio-User-Role>"
            ],
            "Action": "iam:PassRole"
        },
        {
            "Effect": "Allow",
            "Resource": "*",
```

```
            "Action": [
                "sso:CreateManagedApplicationInstance",
                "sso:GetManagedApplicationInstance",
                "sso:DeleteManagedApplicationInstance",
                "sso:AssociateProfile",
                "sso:DisassociateProfile",
                "sso:GetProfile",
                "sso:ListDirectoryAssociations",
                "sso:ListProfiles",
                "sso-directory:SearchUsers",
                "sso-directory:SearchGroups",
                "sso-directory:DescribeUser",
                "sso-directory:DescribeGroup"
            ]
        }
    ]
}
```

2. Hängen Sie die Richtlinie an Ihre IAM-Identität (Benutzer, Rolle oder Gruppe) an. Weitere Informationen finden Sie unter Hinzufügen und Entfernen von IAM-Identitätsberechtigungen.

Ein Amazon EMR Studio einrichten

Gehen Sie wie folgt vor, um ein Amazon EMR Studio einzurichten.

Bevor Sie beginnen

> **Note**
>
> Wenn Sie planen, EMR Studio mit Amazon EMR in EKS zu verwenden, empfehlen wir, zuerst Amazon EMR in EKS für EMR Studio einzurichten, bevor Sie ein Studio einrichten.

Bevor Sie ein EMR-Studio einrichten, stellen Sie sicher, dass Sie über die folgenden Elemente verfügen:

- Eine AWS-Konto Detaillierte Anweisungen finden Sie unter Einrichten von Amazon EMR.
- Berechtigungen zum Erstellen und Verwalten eines EMR Studios. Weitere Informationen finden Sie unter the section called “Administratorberechtigungen zum Erstellen eines EMR-Studios”.

- Ein Amazon-S3-Bucket, in dem EMR Studio die Workspaces und Notebookdateien in Ihrem Studio sichern kann. Anweisungen finden Sie unter Erstellen eines Buckets im Amazon Simple Storage Service (S3)-Benutzerhandbuch.
- Wenn Sie eine Verbindung zu einem Amazon EMR in EC2- oder Amazon EMR in EKS-Cluster herstellen oder Git-Repositorys verwenden möchten, benötigen Sie eine Amazon Virtual Private Cloud (VPC) für das Studio und maximal fünf Subnetze. Sie benötigen keine VPC, um EMR Studio mit EMR Serverless zu verwenden. Tipps zur Netzwerkkonfiguration finden Sie unter Bewährte Methoden für VPC und Subnetze.

So richten Sie ein EMR Studio ein

1. Einen Authentifizierungsmodus für Amazon EMR Studio auswählen
2. Erstellen Sie die folgenden Studio-Ressourcen.
   - Eine EMR-Studio-Servicerolle erstellen
   - EMR-Studio-Benutzerberechtigungen für Amazon EC2 oder Amazon EKS konfigurieren
   - (Optional) Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio.
3. Ein EMR Studio erstellen
4. Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu

Nachdem Sie diese Einrichtungs-Schritte abgeschlossen haben, fahren Sie mit Ein Amazon EMR Studio verwenden fort.

Einen Authentifizierungsmodus für Amazon EMR Studio auswählen

EMR Studio unterstützt zwei Authentifizierungsmodi: den IAM-Authentifizierungsmodus und den IAM-Identity-Center-Authentifizierungsmodus. Der IAM-Modus verwendet AWS Identity and Access Management (IAM), während der IAM-Identity-Center-Modus AWS IAM Identity Center verwendet. Wenn Sie ein EMR Studio erstellen, wählen Sie den Authentifizierungsmodus für alle Benutzer dieses Studios. Weitere Informationen zu diesen verschiedenen Authentifizierungsmodi finden Sie unter Authentifizierung und Benutzeranmeldung.

Verwenden Sie die folgende Tabelle, um einen Authentifizierungsmodus für EMR Studio auszuwählen.

Wenn Sie …	Wir empfehlen...
Bereits mit der IAM-Authentifizierung oder dem IAM-Verbund vertraut sind oder diese eingerich tet haben	IAM-Authentifizierungsmodus, welches die folgenden Vorteile bietet: • Ermöglicht ein Quick Setup für EMR Studio, wenn Sie bereits Identitäten wie Benutzer und Gruppen in IAM verwalten. • Funktioniert mit Identitätsanbietern, die mit OpenID Connect (OIDC) oder Security Assertion Markup Language 2.0 (SAML 2.0) kompatibel sind. • Unterstützt die Verwendung mehrerer Identitätsanbieter mit demselben AWS-Konto . • Erhältlich in einer Vielzahl von AWS-Regio nen. • Konform mit SOC 2.
Neu bei AWS oder Amazon EMR	Authentifizierungsmodus von IAM Identity Center, welches die folgenden Features bietet: • Unterstützt die einfache Zuweisung von AWS-Ressourcen durch Benutzer und Gruppen. • Funktioniert mit Microsoft-Active-Directory- und SAML-2.0-Identitätsanbietern. • Erleichtert die Einrichtung eines Verbunds mit mehreren Konten, sodass Sie den Verbund nicht für jedes AWS-Konto in Ihrer Organisation separat konfigurieren müssen.

IAM-Authentifizierungsmodus für Amazon EMR Studio einrichten

Im IAM-Authentifizierungsmodus können Sie entweder die IAM-Authentifizierung oder den IAM-Verbund verwenden. Mit der IAM-Authentifizierung können Sie IAM-Identitäten wie Benutzer,

Gruppen und Rollen in IAM verwalten. Sie gewähren Benutzern Zugriff auf ein Studio mit IAM-Berechtigungsrichtlinien und attributbasierter Zugriffskontrolle (ABAC). Mit dem IAM-Verbund können Sie Vertrauen zwischen einem externen Identitätsanbieter (IdP) aufbauen und AWS-Benutzeridentitäten über Ihren IdP verwalten.

> **Note**
>
> Wenn Sie IAM bereits verwenden, um den Zugriff auf AWS-Ressourcen zu steuern, oder wenn Sie Ihren Identitätsanbieter (IdP) bereits für IAM konfiguriert haben, finden Sie weitere Informationen unter Benutzerberechtigungen für den IAM-Authentifizierungsmodus, um Benutzerberechtigungen festzulegen, wenn Sie den IAM-Authentifizierungsmodus für EMR Studio verwenden.

Den IAM-Verbund für Amazon EMR Studio verwenden

Um den IAM-Verbund für EMR Studio zu verwenden, erstellen Sie eine Vertrauensbeziehung zwischen Ihren AWS-Konto und Ihrem Identitätsanbieter (IdP) und ermöglichen Verbundbenutzern den Zugriff auf AWS Management Console. Die Schritte, die Sie zum Aufbau dieser Vertrauensbeziehung ergreifen, hängen vom Verbundstandard Ihres IdP ab.

Im Allgemeinen führen Sie die folgenden Aufgaben aus, um den Verbund mit einem externen IdP zu konfigurieren. Vollständige Anweisungen finden Sie unter Aktivieren des Zugriffs von SAML-2.0-Verbundbenutzern auf AWS Management Console und Aktivieren des benutzerdefinierten Identity Broker-Zugriffs auf AWS Management Console im AWS Identity and Access Management-Benutzerhandbuch.

1. Sammeln Sie Informationen von Ihrem IdP. Dies bedeutet in der Regel die Generierung eines Metadatendokuments zur Validierung von SAML-Authentifizierungsanfragen von Ihrem IdP.
2. Erstellen Sie eine IAM-Entität eines Identitätsanbieters, um Informationen über Ihren IdP zu speichern. Anweisungen finden Sie unter IAM-Identitätsanbieter erstellen.
3. Erstellen Sie eine oder mehrere IAM-Rollen für Ihren IdP. EMR Studio weist einem Verbundbenutzer eine Rolle zu, wenn dieser sich anmeldet. Die Rolle ermöglicht es dem Identitätsanbieter, temporäre Sicherheitsanmeldeinformationen für den Zugriff auf AWS anzufordern. Anweisungen finden Sie unter Erstellen einer Rolle für einen Drittanbieter-Identitätsanbieter (Verbund). Die Berechtigungsrichtlinien, die Sie der Rolle zuweisen, bestimmen, was Verbundbenutzer in AWS und in einem EMR Studio tun können. Weitere Informationen finden Sie unter Benutzerberechtigungen für den IAM-Authentifizierungsmodus.

4. (Für SAML-Anbieter) Stellen Sie die SAML-Vertrauensstellung fertig, indem Sie den IdP mit Informationen zu AWS und zu den Rollen konfigurieren, die der Verbundbenutzer übernehmen soll. Dieser Konfigurationsprozess schafft Vertrauen zwischen Ihrem IdP und AWS. Weitere Informationen finden Sie unter Konfigurieren des SAML-2.0-Identitätsanbieters mit Vertrauensstellung für die vertrauende Seite und Hinzufügen von Ansprüchen.

So konfigurieren Sie ein EMR Studio als SAML-Anwendung in Ihrem IdP-Portal

Sie können ein bestimmtes EMR Studio mithilfe eines Deep-Links zum Studio als SAML-Anwendung konfigurieren. Auf diese Weise können sich Benutzer bei Ihrem IdP-Portal anmelden und ein bestimmtes Studio starten, anstatt durch die Amazon-EMR-Konsole zu navigieren.

- Verwenden Sie das folgende Format, um nach der SAML-Assertion-Überprüfung einen Deep-Link zu Ihrem EMR Studio als Landing-URL zu konfigurieren.

```
https://console.aws.amazon.com/emr/home?region=<aws-region>#studio/<your-studio-id>/start
```

Richten Sie den IAM-Identity-Center-Authentifizierungsmodus für Amazon EMR Studio ein

Um AWS IAM Identity Center für EMR Studio vorzubereiten, müssen Sie Ihre Identitätsquelle konfigurieren und Benutzer und Gruppen bereitstellen. Bei der Bereitstellung werden Benutzer- und Gruppeninformationen für die Verwendung durch IAM Identity Center und durch Anwendungen, die IAM Identity Center verwenden, zur Verfügung gestellt. Weitere Informationen finden Sie unter Benutzer- und Gruppenbereitstellung.

EMR Studio unterstützt die Verwendung der folgenden Identitätsanbieter für IAM Identity Center:

- AWS Managed Microsoft AD und selbstverwaltetes Active Directory – Weitere Informationen finden Sie unter Verbindung mit Ihrem Microsoft-AD-Verzeichnis herstellen.
- SAML-basierte Anbieter – Eine vollständige Liste finden Sie unter Unterstützte Identitätsanbieter.
- Das IAM-Identity-Center-Verzeichnis – Weitere Informationen finden Sie unter Identitäten im IAM Identity Center verwalten.

So richten Sie IAM Identity Center für EMR Studio ein

1. Um IAM Identity Center für EMR Studio einzurichten, benötigen Sie Folgendes:

- Ein Verwaltungskonto in Ihrer AWS-Organisation, wenn Sie mehrere Konten in Ihrer Organisation verwenden.

> **Note**
>
> Sie sollten Ihr Verwaltungskonto nur verwenden, um IAM Identity Center zu aktivieren und Benutzer und Gruppen bereitzustellen. Nachdem Sie IAM Identity Center eingerichtet haben, verwenden Sie ein Mitgliedskonto, um ein EMR Studio zu erstellen und Benutzer und Gruppen zuzuweisen. Weitere Informationen zur AWS-Terminologie finden Sie unter AWS Organizations-Terminologie und Konzepte.

- Wenn Sie IAM Identity Center vor dem 25. November 2019 aktiviert haben, müssen Sie möglicherweise Anwendungen aktivieren, die IAM Identity Center für die Konten in Ihrer AWS-Organisation verwenden. Weitere Informationen finden Sie unter Aktivieren von IAM-Identity-Center-integrierten Anwendungen in AWS-Konten.
- Stellen Sie sicher, dass die Voraussetzungen auf der Seite der Voraussetzungen für IAM Identity Center aufgeführt sind.

2. Folgen Sie den Anweisungen unter IAM Identity Center aktivieren, um IAM Identity Center in AWS-Region zu aktivieren, wo Sie das EMR Studio erstellen möchten.
3. Verbinden Sie IAM Identity Center mit Ihrem Identitätsanbieter und stellen Sie die Benutzer und Gruppen bereit, die Sie dem Studio zuweisen möchten.

Wenn Sie …	Vorgehensweise
Ein Microsoft-AD-Verzeichnis verwenden	1. Folgen Sie den Anweisungen unter Verbindung zu Ihrem Microsoft-AD-Verzeichnis herstellen, um Ihr selbstverwaltetes Active Directory oder AWS Managed Microsoft AD-Verzeichnis mithilfe von AWS Directory Service zu verbinden. 2. Um Benutzer und Gruppen für IAM Identity Center bereitzustellen, können Sie Identitätsdaten aus Ihrem Quell-AD mit IAM Identity Center synchronisieren. Sie können Identitäten aus Ihrem Quell-

Wenn Sie …	Vorgehensweise
	AD auf viele Arten synchronisieren. Eine Möglichkeit besteht darin, AD-Benutzer oder -Gruppen einem AWS-Konto in Ihrer Organisation zuzuweisen. Anweisungen finden Sie unter Single Sign-On. Die Synchronisation kann bis zu zwei Stunden dauern. Nach diesem Schritt werden synchronisierte Benutzer und Gruppen in Ihrem Identitätsspeicher angezeigt. **Note** Benutzer und Gruppen werden erst in Ihrem Identitätsspeicher angezeigt, wenn Sie Benutzer- und Gruppeninformationen synchronisieren oder Just-in-Time (JIT)-Benutzerbereitstellung verwenden. Weitere Informationen finden Sie unter Bereitstellung, wenn Benutzer von Active Directory kommen. 3. (Optional) Nachdem Sie AD-Benutzer und -Gruppen synchronisiert haben, können Sie ihnen den Zugriff auf Ihr AWS-Konto, das Sie im vorherigen Schritt konfiguriert haben, entziehen. Anweisungen finden Sie unter Benutzerzugriff entfernen.
Ein externer Identitätsanbieter	Folgen Sie den Anweisungen unter Verbindung zu Ihrem externen Identitätsanbieter herstellen.

Wenn Sie …	Vorgehensweise
IAM-Identity-Center-Verzeichnis	Wenn Sie Benutzer und Gruppen in IAM Identity Center erstellen, erfolgt die Bereitstellung automatisch. Weitere Informationen finden Sie unter Identitäten im IAM Identity Center verwalten.

Sie können jetzt Benutzer und Gruppen aus Ihrem Identity Store einem EMR Studio zuweisen. Detaillierte Anweisungen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Eine EMR-Studio-Servicerolle erstellen

Über die EMR-Studio-Servicerolle

Jedes EMR Studio verwendet eine IAM-Rolle mit Berechtigungen, die es dem Studio ermöglichen, mit anderen AWS-Services zu interagieren. Diese Servicerolle muss Berechtigungen beinhalten, die es EMR Studio ermöglichen, einen sicheren Netzwerkkanal zwischen Workspaces und Clustern einzurichten, Notebook-Dateien in Amazon S3 Control zu speichern und auf AWS Secrets Manager zuzugreifen, während ein Workspace mit einem Git-Repository verknüpft wird.

Verwenden Sie die Studio-Servicerolle (anstelle von Sitzungsrichtlinien), um alle Amazon-S3-Zugriffsberechtigungen für das Speichern von Notebookdateien und AWS Secrets Manager Zugriffsberechtigungen zu definieren.

So erstellen Sie eine Servicerolle für EMR Studio auf Amazon EC2 oder Amazon EKS

1. Folgen Sie den Anweisungen unter Eine Rolle erstellen, um Berechtigungen an einen Service zu delegieren, um die AWS-Servicerolle mithilfe der folgenden Vertrauensrichtlinie zu erstellen.

> **Important**
>
> Die folgende Vertrauensrichtlinie umfasst die Schlüssel `aws:SourceArn` und die `aws:SourceAccount` globalen Bedingungsschlüssel, um die Berechtigungen zu beschränken, die Sie EMR Studio auf bestimmte Ressourcen in Ihrem Konto gewähren. Auf diese Weise können Sie sich vor dem Problem des verwirrten Stellvertreters schützen.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "elasticmapreduce.amazonaws.com"
      },
      "Action": "sts:AssumeRole",
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "<account-id>"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:elasticmapreduce:<region>:<account-id>:*"
        }
      }
    }
  ]
}
```

2. Entfernen Sie die standardmäßigen Rollenberechtigungen. Fügen Sie dann die Berechtigungen aus der folgenden Beispiel-IAM-Berechtigungsrichtlinie hinzu. Alternativ können Sie eine benutzerdefinierte Richtlinie erstellen, die das Berechtigungen für EMR-Studio-Servicerollen verwendet.

   Falls zutreffend, ändern Sie `"Resource":"*"` in der folgenden Richtlinie, um den Amazon-Ressourcennamen (ARN) der Ressource oder Ressourcen anzugeben, für die die Erklärung für Ihre Anwendungsfälle gilt.

   Important

   - Der `ModifyNetworkInterfaceAttribute`-API-Zugriff muss aufgrund technischer Einschränkungen bei der tagbasierten Amazon-EC2-Zugriffskontrolle und der Art und Weise, wie EMR Studio `ModifyNetworkInterfaceAttribute` verwendet, unverändert in der folgenden Richtlinie bleiben.
   - Die folgenden Aussagen müssen unverändert bleiben, damit EMR Studio mit der Servicerolle funktioniert:

`AllowAddingEMRTagsDuringDefaultSecurityGroupCreation` und `AllowAddingTagsDuringEC2ENICreation`.

- Um die Beispielrichtlinie verwenden zu können, müssen Sie die folgenden Ressourcen mit dem Schlüssel "**`for-use-with-amazon-emr-managed-policies`**" und dem Wert "**`true`**" kennzeichnen.
  - Ihre Amazon Virtual Private Cloud (VPC) für EMR Studio.
  - Jedes Subnetz, das Sie mit dem Studio verwenden möchten.
  - Alle benutzerdefinierten EMR-Studio-Sicherheitsgruppen. Sie müssen alle Sicherheitsgruppen, die Sie während der Vorschauphase von EMR Studio erstellt haben, taggen, wenn Sie sie weiterhin verwenden möchten.
  - Geheimnisse in AWS Secrets Manager, die Studio-Benutzer nutzen, um Git-Repositorys mit einem Workspace zu verknüpfen.

  Sie können Tags auf Ressourcen anwenden, indem Sie die Registerkarte Tags auf dem entsprechenden Ressourcenbildschirm in verwenden. AWS Management Console

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowEMRReadOnlyActions",
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:ListInstances",
        "elasticmapreduce:DescribeCluster",
        "elasticmapreduce:ListSteps"
      ],
      "Resource": "*"
    },
    {
      "Sid": "AllowEC2ENIActionsWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterfacePermission",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": [
```

```
        "arn:aws:ec2:*:*:network-interface/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowEC2ENIAttributeAction",
      "Effect": "Allow",
      "Action": [
        "ec2:ModifyNetworkInterfaceAttribute"
      ],
      "Resource": [
        "arn:aws:ec2:*:*:instance/*",
        "arn:aws:ec2:*:*:network-interface/*",
        "arn:aws:ec2:*:*:security-group/*"
      ]
    },
    {
      "Sid": "AllowEC2SecurityGroupActionsWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:AuthorizeSecurityGroupEgress",
        "ec2:AuthorizeSecurityGroupIngress",
        "ec2:RevokeSecurityGroupEgress",
        "ec2:RevokeSecurityGroupIngress",
        "ec2:DeleteNetworkInterfacePermission"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowDefaultEC2SecurityGroupsCreationWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateSecurityGroup"
      ],
      "Resource": [
```

```
        "arn:aws:ec2:*:*:security-group/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowDefaultEC2SecurityGroupsCreationInVPCWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateSecurityGroup"
      ],
      "Resource": [
        "arn:aws:ec2:*:*:vpc/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowAddingEMRTagsDuringDefaultSecurityGroupCreation",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags"
      ],
      "Resource": "arn:aws:ec2:*:*:security-group/*",
      "Condition": {
        "StringEquals": {
          "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true",
          "ec2:CreateAction": "CreateSecurityGroup"
        }
      }
    },
    {
      "Sid": "AllowEC2ENICreationWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface"
      ],
      "Resource": [
```

```
        "arn:aws:ec2:*:*:network-interface/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowEC2ENICreationInSubnetAndSecurityGroupWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface"
      ],
      "Resource": [
        "arn:aws:ec2:*:*:subnet/*",
        "arn:aws:ec2:*:*:security-group/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowAddingTagsDuringEC2ENICreation",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateTags"
      ],
      "Resource": "arn:aws:ec2:*:*:network-interface/*",
      "Condition": {
        "StringEquals": {
          "ec2:CreateAction": "CreateNetworkInterface"
        }
      }
    },
    {
      "Sid": "AllowEC2ReadOnlyActions",
      "Effect": "Allow",
      "Action": [
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DescribeTags",
```

```
        "ec2:DescribeInstances",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcs"
      ],
      "Resource": "*"
    },
    {
      "Sid": "AllowSecretsManagerReadOnlyActionsWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "secretsmanager:GetSecretValue"
      ],
      "Resource": "arn:aws:secretsmanager:*:*:secret:*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
        }
      }
    },
    {
      "Sid": "AllowWorkspaceCollaboration",
      "Effect": "Allow",
      "Action": [
        "iam:GetUser",
        "iam:GetRole",
        "iam:ListUsers",
        "iam:ListRoles",
        "sso:GetManagedApplicationInstance",
        "sso-directory:SearchUsers"
      ],
      "Resource": "*"
    }
  ]
}
```

3. Erteilen Sie Ihrer Servicerolle Lese- und Schreibzugriff auf Ihren Amazon-S3-Standort für EMR Studio. Verwenden Sie die folgenden Mindestberechtigungen. Für weitere Informationen finden Sie unter Amazon S3: Gewährt Lese- und Schreibzugriff auf Objekte in einem S3-Bucket programmgesteuert und in der Konsole.

```
"s3:PutObject",
"s3:GetObject",
"s3:GetEncryptionConfiguration",
```

```
"s3:ListBucket",
"s3:DeleteObject"
```

Wenn Sie Ihren Amazon-S3-Bucket verschlüsseln, fügen Sie die folgenden Berechtigungen für AWS Key Management Service hinzu.

```
"kms:Decrypt",
"kms:GenerateDataKey",
"kms:ReEncryptFrom",
"kms:ReEncryptTo",
"kms:DescribeKey"
```

Minimale Servicerolle für EMR Serverless

Wenn Sie interaktive Workloads mit EMR Serverless über EMR-Studio-Notebooks ausführen möchten, verwenden Sie dieselbe Vertrauensrichtlinie, die Sie für die Einrichtung von EMR Studio im vorherigen Abschnitt So erstellen Sie eine Servicerolle für EMR Studio auf Amazon EC2 oder Amazon EKS verwendet haben.

Für Ihre IAM-Richtlinie verfügt die Mindestrichtlinie über die folgenden Berechtigungen. Aktualisieren Sie *bucket-name* mit dem Namen des Buckets, den Sie bei der Konfiguration von EMR Studio und Workspace verwenden möchten. EMR Studio verwendet das Bucket-Backup der Workspaces und Notebookdateien in Ihrem Studio.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ObjectActions",
            "Effect": "Allow",
            "Action": [
               "s3:PutObject",
               "s3:GetObject",
               "s3:DeleteObject"
            ],
            "Resource": ["arn:aws:s3:::bucket-name/*"]
        },
        {
            "Sid": "BucketActions",
            "Effect": "Allow",
            "Action": [
```

```
                "s3:ListBucket",
                "s3:GetEncryptionConfiguration"
            ],
            "Resource": ["arn:aws:s3:::bucket-name"]
        }
    ]
}
```

Wenn Sie beabsichtigen, einen verschlüsselten Amazon-S3-Bucket zu verwenden, fügen Sie Ihrer Richtlinie die folgenden Berechtigungen hinzu:

```
"kms:Decrypt",
"kms:GenerateDataKey",
"kms:ReEncryptFrom",
"kms:ReEncryptTo",
"kms:DescribeKey"
```

Berechtigungen für EMR-Studio-Servicerollen

In der folgenden Tabelle sind die Operationen aufgeführt, die EMR Studio mithilfe der Servicerolle ausführt, zusammen mit den IAM-Aktionen, die für jeden Vorgang erforderlich sind.

Operation	Aktionen

Richten Sie einen sicheren Netzwerkkanal zwischen einem Workspace und einem EMR-Cluster ein und führen Sie die erforderlichen Bereinigungsaktionen durch.	`"ec2:CreateNetworkInterface",`
	`"ec2:CreateNetworkInterfacePermission",`
	`"ec2:DeleteNetworkInterface",`
	`"ec2:DeleteNetworkInterfacePermission",`
	`"ec2:DescribeNetworkInterfaces",`
	`"ec2:ModifyNetworkInterfaceAttribute",`
	`"ec2:AuthorizeSecurityGroupEgress",`
	`"ec2:AuthorizeSecurityGroupIngress",`
	`"ec2:CreateSecurityGroup",`
	`"ec2:DescribeSecurityGroups",`
	`"ec2:RevokeSecurityGroupEgress",`
	`"ec2:DescribeTags",`
	`"ec2:DescribeInstances",`
	`"ec2:DescribeSubnets",`
	`"ec2:DescribeVpcs",`
	`"elasticmapreduce:ListInstances",`
	`"elasticmapreduce:DescribeCluster",`

Operation	Aktionen
	`"elasticmapreduce:ListSteps"`
Verwenden Sie die in gespeicherten Git-Anmeldeinformationen AWS Secrets Manager, um Git-Repositorys mit einem Workspace zu verknüpfen.	`"secretsmanager:GetSecretValue"`
Wenden Sie AWS-Tags auf die Netzwerkschnittstelle und die Standardsicherheitsgruppen an, die EMR Studio bei der Einrichtung des sicheren Netzwerkkanals erstellt. Weitere Informationen finden Sie unter Markieren von AWS-Ressourcen.	`"ec2:CreateTags"`

Greifen Sie auf Notebook-Dateien und Metadaten zu oder laden Sie sie in Amazon S3 hoch.	`"s3:PutObject",`
	`"s3:GetObject",`
	`"s3:GetEncryptionConfiguration",`
	`"s3:ListBucket",`
	`"s3:DeleteObject"`
	
	Wenn Sie einen verschlüsselten Amazon-S3-Bucket verwenden, schließen Sie die folgenden Berechtigungen ein.
	
	`"kms:Decrypt",`
	`"kms:GenerateDataKey",`
	`"kms:ReEncryptFrom",`
	`"kms:ReEncryptTo",`
	`"kms:DescribeKey"`

Operation	Aktionen
Aktivieren und konfigurieren Sie die Workspace-Zusammenarbeit.	`"iam:GetUser", "iam:GetRole", "iam:ListUsers", "iam:ListRoles", "sso:GetManagedApplicationInstance", "sso-directory:SearchUsers"`

EMR-Studio-Benutzerberechtigungen für Amazon EC2 oder Amazon EKS konfigurieren

Sie müssen Benutzerberechtigungsrichtlinien für Amazon EMR Studio konfigurieren, damit Sie detaillierte Benutzer- und Gruppenberechtigungen festlegen können. Informationen zur Funktionsweise von Benutzerberechtigungen in EMR Studio finden Sie unter Zugriffskontrolle unter Wie Amazon EMR Studio funktioniert.

> **Note**
>
> Die in diesem Abschnitt behandelten Berechtigungen erzwingen keine Datenzugriffskontrolle. Um den Zugriff auf Eingabe-Datensätze zu verwalten, sollten Sie Berechtigungen für die Cluster konfigurieren, die Ihr Studio verwendet. Weitere Informationen finden Sie unter Sicherheit in Amazon EMR.

Eine EMR-Studio-Benutzerrolle für den IAM-Identity-Center-Authentifizierungsmodus erstellen

Sie müssen eine EMR-Studio-Benutzerrolle erstellen, wenn Sie den IAM-Identity-Center-Authentifizierungsmodus verwenden.

So erstellen Sie eine Benutzerrolle für EMR Studio

1. Befolgen Sie die Anleitung zum Erstellen einer Rolle zum Delegieren von Berechtigungen an einen AWS-Service im AWS Identity and Access Management-Benutzerhandbuch zum Erstellen einer IAM-Rolle.

   Verwenden Sie beim Erstellen der Rolle die folgende Vertrauensbeziehungsrichtlinie.

```
{
  "Version": "2008-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "elasticmapreduce.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

2. Entfernen Sie die standardmäßigen Rollenberechtigungen und -richtlinien.
3. Hängen Sie Ihre EMR-Studio-Sitzungsrichtlinien an die Benutzerrolle an, bevor Sie einem Studio Benutzer und Gruppen zuweisen. Anweisungen zum Erstellen von Sitzungsrichtlinien finden Sie unter Berechtigungsrichtlinien für EMR-Studio-Benutzer erstellen.

Berechtigungsrichtlinien für EMR-Studio-Benutzer erstellen

Führen Sie die folgenden Schritte aus, um eine Berechtigungsrichtlinie für einen EMR Studio zu erstellen.

> **Note**
>
> Um Amazon-S3-Zugriffsberechtigungen für die Speicherung von Notebook-Dateien und AWS Secrets Manager-Zugriffsberechtigungen für das Lesen von Geheimnissen beim Verknüpfen von Workspaces mit Git-Repositories festzulegen, verwenden Sie die EMR Studio-Servicerolle.

1. Erstellen Sie eine oder mehrere IAM-Berechtigungsrichtlinien, die festlegen, welche Aktionen ein Benutzer in Ihrem Studio ausführen kann. Mit den Beispielrichtlinien auf dieser Seite können Sie beispielsweise drei separate Richtlinien für einfache, fortgeschrittene und fortgeschrittene Studio-Benutzer erstellen.

   In der AWS Identity and Access Management-Berechtigungen für EMR-Studio-Benutzer-Tabelle sind alle Studio-Operationen, die ein Benutzer möglicherweise ausführen kann, aufgeschlüsselt

und die IAM-Aktionen aufgeführt, die zur Ausführung dieses Vorgangs mindestens erforderlich sind. Anweisungen finden Sie unter Erstellen von IAM-Richtlinien.

Ihre Berechtigungsrichtlinie muss die folgenden Aussagen enthalten.

```
{
            "Sid": "AllowAddingTagsOnSecretsWithEMRStudioPrefix",
            "Effect": "Allow",
            "Action": "secretsmanager:TagResource",
            "Resource": "arn:aws:secretsmanager:*:*:secret:emr-studio-*"
},
{
            "Sid": "AllowPassingServiceRoleForWorkspaceCreation",
            "Action": "iam:PassRole",
            "Resource": [
                "arn:aws:iam::*:role/<your-emr-studio-service-role>"
            ],
            "Effect": "Allow"
}
```

Legen Sie die Eigentümerschaft für die Workspace-Zusammenarbeit fest

Mithilfe von Workspace Collaboration können mehrere Benutzer gleichzeitig im selben Workspace arbeiten. Sie kann über das Collaboration-Bedienfeld in der Workspace-Benutzeroberfläche konfiguriert werden. Um das Collaboration Panel sehen und verwenden zu können, muss ein Benutzer über die folgenden Berechtigungen verfügen. Jeder Benutzer mit diesen Berechtigungen kann das Panel Zusammenarbeit sehen und verwenden.

```
"elasticmapreduce:UpdateEditor",
"elasticmapreduce:PutWorkspaceAccess",
"elasticmapreduce:DeleteWorkspaceAccess",
"elasticmapreduce:ListWorkspaceAccessIdentities"
```

Um den Zugriff auf das Panel Zusammenarbeit einzuschränken, können Sie die tagbasierte Zugriffskontrolle verwenden. Wenn ein Benutzer einen Workspace erstellt, wendet EMR Studio ein Standard-Tag mit einem Schlüssel von `creatorUserId`, dessen Wert die ID des Benutzers ist, der den Workspace erstellt.

> **Note**
>
> EMR Studio hat das `creatorUserId`-Tag nicht zu Workspaces hinzugefügt, die vor dem 16. November 2021 erstellt wurden. Um einzuschränken, wer die Zusammenarbeit konfigurieren kann, empfehlen wir, das `creatorUserId`-Tag manuell zu Ihrem Workspace hinzuzufügen und dann die tagbasierte Zugriffskontrolle in Ihren Benutzerberechtigungsrichtlinien zu verwenden.

Die folgende Beispielanweisung ermöglicht es einem Benutzer, die Zusammenarbeit für jeden Workspace mit dem Tag-Schlüssel `creatorUserId` zu konfigurieren, dessen Wert der Benutzer-ID entspricht (angegeben durch die Richtlinienvariable `aws:userId`). Mit anderen Worten, die Anweisung ermöglicht es einem Benutzer, die Zusammenarbeit für die von ihm erstellten Workspaces zu konfigurieren. Weitere Informationen zu Richtlinienvariablen finden Sie unter IAM-Richtlinienelemente: Variablen und Tags.

```
{
    "Sid": "UserRolePermissionsForCollaboration",
    "Action": [
        "elasticmapreduce:UpdateEditor",
        "elasticmapreduce:PutWorkspaceAccess",
        "elasticmapreduce:DeleteWorkspaceAccess",
        "elasticmapreduce:ListWorkspaceAccessIdentities"
    ],
    "Resource": "*",
    "Effect": "Allow",
    "Condition": {
        "StringEquals": {
            "elasticmapreduce:ResourceTag/creatorUserId": "${aws:userid}"
        }
    }
}
```

2. Hängen Sie die Berechtigungsrichtlinie an Ihre IAM-Identität an.

   In der folgenden Tabelle wird zusammengefasst, an welche IAM-Identität Sie je nach Ihrem EMR-Studio-Authentifizierungsmodus eine Berechtigungsrichtlinie anhängen. Anweisungen zum Anfügen einer Richtlinie finden Sie unter.Hinzufügen und Entfernen von IAM-Identitätsberechtigungen.

Wenn Sie …	Fügen Sie die Richtlinie an …
IAM-Authentifizierung	Ihre IAM-Identitäten (Benutzer, Benutzergruppen oder Rollen). Sie können einem Benutzer in Ihrem AWS-Konto eine Berechtigungsrichtlinie zuweisen.
IAM-Verbund mit einem externen Identitätsanbieter (IdP)	Die IAM-Rolle oder Rollen, die Sie für Ihren externen IdP erstellen. Zum Beispiel ein IAM für den SAML-2.0-Verbund. EMR Studio verwendet die Berechtigungen, die Sie Ihren IAM-Rollen zuordnen, für Benutzer mit Verbundzugriff auf ein Studio.
IAM Identity Center	Ihre Amazon-EMR-Studio-Benutzerrolle.

Beispielbenutzerrichtlinien

Die folgende grundlegende Benutzerrichtlinie erlaubt die meisten EMR-Studio-Aktionen, erlaubt es einem Benutzer jedoch nicht, neue Amazon-EMR-Cluster zu erstellen.

Grundlegende Richtlinien

> **Important**
>
> Die Beispielrichtlinie beinhaltet nicht die `CreateStudioPresignedUrl`-Berechtigung, die Sie einem Benutzer gewähren müssen, wenn Sie den IAM-Authentifizierungsmodus verwenden. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Die Beispielrichtlinie enthält `Condition`-Elemente zur Durchsetzung der tagbasierten Zugriffskontrolle (TBAC), sodass Sie die Richtlinie mit der Beispielservicerolle für EMR Studio verwenden können. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.

```
{
   "Version":"2012-10-17",
```

```
    "Statement":[
       {
          "Sid":"AllowDefaultEC2SecurityGroupsCreationInVPCWithEMRTags",
          "Effect":"Allow",
          "Action":[
             "ec2:CreateSecurityGroup"
          ],
          "Resource":[
             "arn:aws:ec2:*:*:vpc/*"
          ],
          "Condition":{
             "StringEquals":{
                "aws:ResourceTag/for-use-with-amazon-emr-managed-policies":"true"
             }
          }
       },
       {
          "Sid":"AllowAddingEMRTagsDuringDefaultSecurityGroupCreation",
          "Effect":"Allow",
          "Action":[
             "ec2:CreateTags"
          ],
          "Resource":"arn:aws:ec2:*:*:security-group/*",
          "Condition":{
             "StringEquals":{
                "aws:RequestTag/for-use-with-amazon-emr-managed-policies":"true",
                "ec2:CreateAction":"CreateSecurityGroup"
             }
          }
       },
       {
          "Sid":"AllowSecretManagerListSecrets",
          "Action":[
             "secretsmanager:ListSecrets"
          ],
          "Resource":"*",
          "Effect":"Allow"
       },
       {
          "Sid":"AllowSecretCreationWithEMRTagsAndEMRStudioPrefix",
          "Effect":"Allow",
          "Action":"secretsmanager:CreateSecret",
          "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*",
          "Condition":{
```

```
            "StringEquals":{
               "aws:RequestTag/for-use-with-amazon-emr-managed-policies":"true"
            }
         }
      },
      {
         "Sid":"AllowAddingTagsOnSecretsWithEMRStudioPrefix",
         "Effect":"Allow",
         "Action":"secretsmanager:TagResource",
         "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*"
      },
      {
         "Sid":"AllowPassingServiceRoleForWorkspaceCreation",
         "Action":"iam:PassRole",
         "Resource":[
            "arn:aws:iam::*:role/<your-emr-studio-service-role>"
         ],
         "Effect":"Allow"
      },
      {
         "Sid":"AllowS3ListAndLocationPermissions",
         "Action":[
            "s3:ListAllMyBuckets",
            "s3:ListBucket",
            "s3:GetBucketLocation"
         ],
         "Resource":"arn:aws:s3:::*",
         "Effect":"Allow"
      },
      {
         "Sid":"AllowS3ReadOnlyAccessToLogs",
         "Action":[
            "s3:GetObject"
         ],
         "Resource":[
            "arn:aws:s3:::aws-logs-<aws-account-id>-<region>/elasticmapreduce/*"
         ],
         "Effect":"Allow"
      },
      {
         "Sid":"AllowConfigurationForWorkspaceCollaboration",
         "Action":[
            "elasticmapreduce:UpdateEditor",
            "elasticmapreduce:PutWorkspaceAccess",
```

```
            "elasticmapreduce:DeleteWorkspaceAccess",
            "elasticmapreduce:ListWorkspaceAccessIdentities"
         ],
         "Resource":"*",
         "Effect":"Allow",
         "Condition":{
            "StringEquals":{
               "elasticmapreduce:ResourceTag/creatorUserId":"${aws:userId}"
            }
         }
      },
      {
         "Sid":"DescribeNetwork",
         "Effect":"Allow",
         "Action":[
            "ec2:DescribeVpcs",
            "ec2:DescribeSubnets",
            "ec2:DescribeSecurityGroups"
         ],
         "Resource":"*"
      },
      {
         "Sid":"ListIAMRoles",
         "Effect":"Allow",
         "Action":[
            "iam:ListRoles"
         ],
         "Resource":"*"
      }
   ]
}
```

Die folgende Richtlinie für Zwischenbenutzer ermöglicht die meisten EMR-Studio-Aktionen und ermöglicht es einem Benutzer, mithilfe einer Clustervorlage neue Amazon-EMR-Cluster zu erstellen.

Zwischenrichtlinie

> **Important**
>
> Die Beispielrichtlinie beinhaltet nicht die `CreateStudioPresignedUrl`-Berechtigung, die Sie einem Benutzer gewähren müssen, wenn Sie den IAM-Authentifizierungsmodus

verwenden. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Die Beispielrichtlinie enthält `Condition`-Elemente zur Durchsetzung der tagbasierten Zugriffskontrolle (TBAC), sodass Sie die Richtlinie mit der Beispielservicerolle für EMR Studio verwenden können. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Sid":"AllowEMRBasicActions",
         "Action":[
            "elasticmapreduce:CreateEditor",
            "elasticmapreduce:DescribeEditor",
            "elasticmapreduce:ListEditors",
            "elasticmapreduce:StartEditor",
            "elasticmapreduce:StopEditor",
            "elasticmapreduce:DeleteEditor",
            "elasticmapreduce:OpenEditorInConsole",
            "elasticmapreduce:AttachEditor",
            "elasticmapreduce:DetachEditor",
            "elasticmapreduce:CreateRepository",
            "elasticmapreduce:DescribeRepository",
            "elasticmapreduce:DeleteRepository",
            "elasticmapreduce:ListRepositories",
            "elasticmapreduce:LinkRepository",
            "elasticmapreduce:UnlinkRepository",
            "elasticmapreduce:DescribeCluster",
            "elasticmapreduce:ListInstanceGroups",
            "elasticmapreduce:ListBootstrapActions",
            "elasticmapreduce:ListClusters",
            "elasticmapreduce:ListSteps",
            "elasticmapreduce:CreatePersistentAppUI",
            "elasticmapreduce:DescribePersistentAppUI",
            "elasticmapreduce:GetPersistentAppUIPresignedURL",
            "elasticmapreduce:GetOnClusterAppUIPresignedURL"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
```

```
      {
         "Sid":"AllowEMRContainersBasicActions",
         "Action":[
            "emr-containers:DescribeVirtualCluster",
            "emr-containers:ListVirtualClusters",
            "emr-containers:DescribeManagedEndpoint",
            "emr-containers:ListManagedEndpoints",
            "emr-containers:DescribeJobRun",
            "emr-containers:ListJobRuns"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
      {
          "Sid": "AllowRetrievingManagedEndpointCredentials",
          "Effect": "Allow",
          "Action": [
              "emr-containers:GetManagedEndpointSessionCredentials"
          ],
          "Resource": [
              "arn:aws:emr-containers:<region>:<account-id>:/virtualclusters/<virtual-
cluster-id>/endpoints/<managed-endpoint-id>"
          ],
          "Condition": {
              "StringEquals": {
                  "emr-containers:ExecutionRoleArn": [
                      "arn:aws:iam::<account-id>:role/<emr-on-eks-execution-role>"
                  ]
              }
          }
      },
      {
         "Sid":"AllowSecretManagerListSecrets",
         "Action":[
            "secretsmanager:ListSecrets"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
      {
         "Sid":"AllowSecretCreationWithEMRTagsAndEMRStudioPrefix",
         "Effect":"Allow",
         "Action":"secretsmanager:CreateSecret",
         "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*",
```

```
            "Condition":{
               "StringEquals":{
                  "aws:RequestTag/for-use-with-amazon-emr-managed-policies":"true"
               }
            }
         },
         {
            "Sid":"AllowAddingTagsOnSecretsWithEMRStudioPrefix",
            "Effect":"Allow",
            "Action":"secretsmanager:TagResource",
            "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*"
         },
         {
            "Sid":"AllowClusterTemplateRelatedIntermediateActions",
            "Action":[
               "servicecatalog:DescribeProduct",
               "servicecatalog:DescribeProductView",
               "servicecatalog:DescribeProvisioningParameters",
               "servicecatalog:ProvisionProduct",
               "servicecatalog:SearchProducts",
               "servicecatalog:UpdateProvisionedProduct",
               "servicecatalog:ListProvisioningArtifacts",
               "servicecatalog:ListLaunchPaths",
               "servicecatalog:DescribeRecord",
               "cloudformation:DescribeStackResources"
            ],
            "Resource":"*",
            "Effect":"Allow"
         },
         {
            "Sid":"AllowPassingServiceRoleForWorkspaceCreation",
            "Action":"iam:PassRole",
            "Resource":[
               "arn:aws:iam::*:role/<your-emr-studio-service-role>"
            ],
            "Effect":"Allow"
         },
         {
            "Sid":"AllowS3ListAndLocationPermissions",
            "Action":[
               "s3:ListAllMyBuckets",
               "s3:ListBucket",
               "s3:GetBucketLocation"
            ],
```

```
            "Resource":"arn:aws:s3:::*",
            "Effect":"Allow"
        },
        {
            "Sid":"AllowS3ReadOnlyAccessToLogs",
            "Action":[
               "s3:GetObject"
            ],
            "Resource":[
               "arn:aws:s3:::aws-logs-<aws-account-id>-<region>/elasticmapreduce/*"
            ],
            "Effect":"Allow"
        },
        {
            "Sid":"AllowConfigurationForWorkspaceCollaboration",
            "Action":[
               "elasticmapreduce:UpdateEditor",
               "elasticmapreduce:PutWorkspaceAccess",
               "elasticmapreduce:DeleteWorkspaceAccess",
               "elasticmapreduce:ListWorkspaceAccessIdentities"
            ],
            "Resource":"*",
            "Effect":"Allow",
            "Condition":{
               "StringEquals":{
                  "elasticmapreduce:ResourceTag/creatorUserId":"${aws:userId}"
               }
            }
        },
        {
            "Sid":"DescribeNetwork",
            "Effect":"Allow",
            "Action":[
               "ec2:DescribeVpcs",
               "ec2:DescribeSubnets",
               "ec2:DescribeSecurityGroups"
            ],
            "Resource":"*"
        },
        {
            "Sid":"ListIAMRoles",
            "Effect":"Allow",
            "Action":[
               "iam:ListRoles"
```

```
         ],
         "Resource":"*"
      },
      {
         "Sid": "AllowServerlessActions",
         "Action": [
            "emr-serverless:CreateApplication",
            "emr-serverless:UpdateApplication",
            "emr-serverless:DeleteApplication",
            "emr-serverless:ListApplications",
            "emr-serverless:GetApplication",
            "emr-serverless:StartApplication",
            "emr-serverless:StopApplication",
            "emr-serverless:StartJobRun",
            "emr-serverless:CancelJobRun",
            "emr-serverless:ListJobRuns",
            "emr-serverless:GetJobRun",
            "emr-serverless:GetDashboardForJobRun",
            "emr-serverless:AccessInteractiveEndpoints"
         ],
         "Resource": "*",
         "Effect": "Allow"
        },
        {
           "Sid": "AllowPassingRuntimeRoleForRunningServerlessJob",
           "Action": "iam:PassRole",
           "Resource": "arn:aws:iam::*:role/serverless-runtime-role",
           "Effect": "Allow"
        }
   ]
}
```

Die folgende erweiterte Benutzerrichtlinie erlaubt alle EMR-Studio-Aktionen und ermöglicht es einem Benutzer, mithilfe einer Cluster-Vorlage oder durch Bereitstellung einer Cluster-Konfiguration neue Amazon-EMR-Cluster zu erstellen.

Erweiterte Richtlinien

> **Important**
>
> Die Beispielrichtlinie beinhaltet nicht die `CreateStudioPresignedUrl`-Berechtigung, die Sie einem Benutzer gewähren müssen, wenn Sie den IAM-Authentifizierungsmodus

verwenden. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Die Beispielrichtlinie enthält `Condition`-Elemente zur Durchsetzung der tagbasierten Zugriffskontrolle (TBAC), sodass Sie die Richtlinie mit der Beispielservicerolle für EMR Studio verwenden können. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Sid":"AllowEMRBasicActions",
         "Action":[
            "elasticmapreduce:CreateEditor",
            "elasticmapreduce:DescribeEditor",
            "elasticmapreduce:ListEditors",
            "elasticmapreduce:StartEditor",
            "elasticmapreduce:StopEditor",
            "elasticmapreduce:DeleteEditor",
            "elasticmapreduce:OpenEditorInConsole",
            "elasticmapreduce:AttachEditor",
            "elasticmapreduce:DetachEditor",
            "elasticmapreduce:CreateRepository",
            "elasticmapreduce:DescribeRepository",
            "elasticmapreduce:DeleteRepository",
            "elasticmapreduce:ListRepositories",
            "elasticmapreduce:LinkRepository",
            "elasticmapreduce:UnlinkRepository",
            "elasticmapreduce:DescribeCluster",
            "elasticmapreduce:ListInstanceGroups",
            "elasticmapreduce:ListBootstrapActions",
            "elasticmapreduce:ListClusters",
            "elasticmapreduce:ListSteps",
            "elasticmapreduce:CreatePersistentAppUI",
            "elasticmapreduce:DescribePersistentAppUI",
            "elasticmapreduce:GetPersistentAppUIPresignedURL",
            "elasticmapreduce:GetOnClusterAppUIPresignedURL"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
```

```
      {
         "Sid":"AllowEMRContainersBasicActions",
         "Action":[
            "emr-containers:DescribeVirtualCluster",
            "emr-containers:ListVirtualClusters",
            "emr-containers:DescribeManagedEndpoint",
            "emr-containers:ListManagedEndpoints",
            "emr-containers:DescribeJobRun",
            "emr-containers:ListJobRuns"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
      {
          "Sid": "AllowRetrievingManagedEndpointCredentials",
          "Effect": "Allow",
          "Action": [
              "emr-containers:GetManagedEndpointSessionCredentials"
          ],
          "Resource": [
              "arn:aws:emr-containers:<region>:<account-id>:/virtualclusters/<virtual-
cluster-id>/endpoints/<managed-endpoint-id>"
          ],
          "Condition": {
              "StringEquals": {
                  "emr-containers:ExecutionRoleArn": [
                      "arn:aws:iam::<account-id>:role/<emr-on-eks-execution-role>"
                  ]
              }
          }
      },
      {
         "Sid":"AllowSecretManagerListSecrets",
         "Action":[
            "secretsmanager:ListSecrets"
         ],
         "Resource":"*",
         "Effect":"Allow"
      },
      {
         "Sid":"AllowSecretCreationWithEMRTagsAndEMRStudioPrefix",
         "Effect":"Allow",
         "Action":"secretsmanager:CreateSecret",
         "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*",
```

```
            "Condition":{
               "StringEquals":{
                  "aws:RequestTag/for-use-with-amazon-emr-managed-policies":"true"
               }
            }
         },
         {
            "Sid":"AllowAddingTagsOnSecretsWithEMRStudioPrefix",
            "Effect":"Allow",
            "Action":"secretsmanager:TagResource",
            "Resource":"arn:aws:secretsmanager:*:*:secret:emr-studio-*"
         },
         {
            "Sid":"AllowClusterTemplateRelatedIntermediateActions",
            "Action":[
               "servicecatalog:DescribeProduct",
               "servicecatalog:DescribeProductView",
               "servicecatalog:DescribeProvisioningParameters",
               "servicecatalog:ProvisionProduct",
               "servicecatalog:SearchProducts",
               "servicecatalog:UpdateProvisionedProduct",
               "servicecatalog:ListProvisioningArtifacts",
               "servicecatalog:ListLaunchPaths",
               "servicecatalog:DescribeRecord",
               "cloudformation:DescribeStackResources"
            ],
            "Resource":"*",
            "Effect":"Allow"
         },
         {
            "Sid":"AllowEMRCreateClusterAdvancedActions",
            "Action":[
               "elasticmapreduce:RunJobFlow"
            ],
            "Resource":"*",
            "Effect":"Allow"
         },
         {
            "Sid":"AllowPassingServiceRoleForWorkspaceCreation",
            "Action":"iam:PassRole",
            "Resource":[
               "arn:aws:iam::*:role/<your-emr-studio-service-role>",
               "arn:aws:iam::*:role/EMR_DefaultRole_V2",
               "arn:aws:iam::*:role/EMR_EC2_DefaultRole"
```

```
        ],
        "Effect":"Allow"
    },
    {
        "Sid":"AllowS3ListAndLocationPermissions",
        "Action":[
            "s3:ListAllMyBuckets",
            "s3:ListBucket",
            "s3:GetBucketLocation"
        ],
        "Resource":"arn:aws:s3:::*",
        "Effect":"Allow"
    },
    {
        "Sid":"AllowS3ReadOnlyAccessToLogs",
        "Action":[
            "s3:GetObject"
        ],
        "Resource":[
            "arn:aws:s3:::aws-logs-<aws-account-id>-<region>/elasticmapreduce/*"
        ],
        "Effect":"Allow"
    },
    {
        "Sid":"AllowConfigurationForWorkspaceCollaboration",
        "Action":[
            "elasticmapreduce:UpdateEditor",
            "elasticmapreduce:PutWorkspaceAccess",
            "elasticmapreduce:DeleteWorkspaceAccess",
            "elasticmapreduce:ListWorkspaceAccessIdentities"
        ],
        "Resource":"*",
        "Effect":"Allow",
        "Condition":{
            "StringEquals":{
                "elasticmapreduce:ResourceTag/creatorUserId":"${aws:userId}"
            }
        }
    },
    {
        "Sid" : "SageMakerDataWranglerForEMRStudio",
        "Effect" : "Allow",
        "Action" : [
            "sagemaker:CreatePresignedDomainUrl",
```

```
            "sagemaker:DescribeDomain",
            "sagemaker:ListDomains",
            "sagemaker:ListUserProfiles"
         ],
         "Resource":"*"
      },
      {
         "Sid":"DescribeNetwork",
         "Effect":"Allow",
         "Action":[
            "ec2:DescribeVpcs",
            "ec2:DescribeSubnets",
            "ec2:DescribeSecurityGroups"
         ],
         "Resource":"*"
      },
      {
         "Sid":"ListIAMRoles",
         "Effect":"Allow",
         "Action":[
            "iam:ListRoles"
         ],
         "Resource":"*"
      },
      {
         "Sid": "AllowServerlessActions",
         "Action": [
            "emr-serverless:CreateApplication",
            "emr-serverless:UpdateApplication",
            "emr-serverless:DeleteApplication",
            "emr-serverless:ListApplications",
            "emr-serverless:GetApplication",
            "emr-serverless:StartApplication",
            "emr-serverless:StopApplication",
            "emr-serverless:StartJobRun",
            "emr-serverless:CancelJobRun",
            "emr-serverless:ListJobRuns",
            "emr-serverless:GetJobRun",
            "emr-serverless:GetDashboardForJobRun",
            "emr-serverless:AccessInteractiveEndpoints"
         ],
         "Resource": "*",
         "Effect": "Allow"
      },
```

```
      {
         "Sid": "AllowPassingRuntimeRoleForRunningServerlessJob",
         "Action": "iam:PassRole",
         "Resource": "arn:aws:iam::*:role/serverless-runtime-role",
         "Effect": "Allow"
      }
   ]
}
```

Die folgende Benutzerrichtlinie enthält die Mindestbenutzerberechtigungen, die für die Verwendung einer interaktiven EMR-Serverless-Anwendung mit EMR Studio Workspaces erforderlich sind.

Interaktive EMR-Serverless-Richtlinie

Ersetzen Sie in dieser Beispielrichtlinie, die Benutzerberechtigungen für interaktive EMR Serverless-Anwendungen mit EMR Studio enthält, die Platzhalter für *serverless-runtime-role* und *EMR-Studio-Servicerolle* durch Ihre richtige EMR-Studio-Servicerolle und EMR-Serverless-Laufzeitrolle.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowServerlessActions",
            "Action": [
                "emr-serverless:CreateApplication",
                "emr-serverless:UpdateApplication",
                "emr-serverless:DeleteApplication",
                "emr-serverless:ListApplications",
                "emr-serverless:GetApplication",
                "emr-serverless:StartApplication",
                "emr-serverless:StopApplication",
                "emr-serverless:StartJobRun",
                "emr-serverless:CancelJobRun",
                "emr-serverless:ListJobRuns",
                "emr-serverless:GetJobRun",
                "emr-serverless:GetDashboardForJobRun",
                "emr-serverless:AccessInteractiveEndpoints"
            ],
            "Resource": "*",
            "Effect": "Allow"
        },
        {
```

```
            "Sid": "AllowEMRBasicActions",
            "Action": [
                "elasticmapreduce:CreateEditor",
                "elasticmapreduce:DescribeEditor",
                "elasticmapreduce:ListEditors",
                "elasticmapreduce:UpdateStudio",
                "elasticmapreduce:StartEditor",
                "elasticmapreduce:StopEditor",
                "elasticmapreduce:DeleteEditor",
                "elasticmapreduce:OpenEditorInConsole",
                "elasticmapreduce:AttachEditor",
                "elasticmapreduce:DetachEditor",
                "elasticmapreduce:CreateStudio",
                "elasticmapreduce:DescribeStudio",
                "elasticmapreduce:DeleteStudio",
                "elasticmapreduce:ListStudios",
                "elasticmapreduce:CreateStudioPresignedUrl"
            ],
            "Resource": "*",
            "Effect": "Allow"
        },
        {
            "Sid": "AllowPassingRuntimeRoleForRunningEMRServerlessJob",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::*:role/serverless-runtime-role",
            "Effect": "Allow"
        },
        {
            "Sid": "AllowPassingServiceRoleForWorkspaceCreation",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::*:role/emr-studio-service-role",
            "Effect": "Allow"
        },
        {
            "Sid": "AllowS3ListAndGetPermissions",
            "Action": [
                "s3:ListAllMyBuckets",
                "s3:ListBucket",
                "s3:GetBucketLocation",
                "s3:GetObject"
            ],
            "Resource": "arn:aws:s3:::*",
            "Effect": "Allow"
        },
```

```
        {
            "Sid":"DescribeNetwork",
            "Effect":"Allow",
            "Action":[
                "ec2:DescribeVpcs",
                "ec2:DescribeSubnets",
                "ec2:DescribeSecurityGroups"
            ],
            "Resource":"*"
        },
        {
            "Sid": "ListIAMRoles",
            "Effect": "Allow",
            "Action": [
                "iam:ListRoles"
            ],
            "Resource": "*"
        }
    ]
}
```

AWS Identity and Access Management-Berechtigungen für EMR-Studio-Benutzer

Die folgende Tabelle enthält jeden Amazon-EMR-Studio-Vorgang, den ein Benutzer ausführen könnte, und listet die mindestens erforderlichen IAM-Aktionen auf, um diesen Vorgang auszuführen. Sie erlauben diese Aktionen in Ihren IAM-Berechtigungsrichtlinien (wenn Sie die IAM-Authentifizierung verwenden) oder in Ihren Sitzungsrichtlinien (wenn Sie die IAM-Identity-Center-Authentifizierung verwenden) für EMR Studio.

In der Tabelle werden auch die Operationen angezeigt, die in den einzelnen Beispielberechtigungsrichtlinien für EMR Studio zulässig sind. Weitere Informationen zu Beispiel-Berechtigungsrichtlinien finden Sie unter Berechtigungsrichtlinien für EMR-Studio-Benutzer erstellen.

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Arbeitsbereiche erstellen und löschen	Ja	Ja	Ja	`"elasticmapreduce:CreateEditor", "elasticmapreduce:DescribeEditor",`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
				`"elasticmapreduce:ListEditors", "elasticmapreduce:DeleteEditor"`
Rufen Sie das Panel Zusammenarbeit auf, aktivieren Sie die Workspace-Zusammenarbeit und fügen Sie Mitarbeiter hinzu. Weitere Informationen finden Sie unter Legen Sie die Eigentümerschaft für die Workspace-Zusammenarbeit fest.	Ja	Ja	Ja	`"elasticmapreduce:UpdateEditor", "elasticmapreduce:PutWorkspaceAccess", "elasticmapreduce:DeleteWorkspaceAccess", "elasticmapreduce:ListWorkspaceAccessIdentities"`
Sehen Sie sich beim Erstellen eines neuen EMR-Clusters eine Liste der Amazon S3 Control-Speicher-Buckets in demselben Konto wie Studio an und greifen Sie auf Container-Logs zu, wenn Sie eine Web-UI zum Debuggen von Anwendungen verwenden	Ja	Ja	Ja	`"s3:ListAllMyBuckets", "s3:ListBucket", "s3:GetBucketLocation", "s3:GetObject"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Auf Workspaces zugreifen	Ja	Ja	Ja	`"elasticmapreduce:DescribeEditor", "elasticmapreduce:ListEditors", "elasticmapreduce:StartEditor", "elasticmapreduce:StopEditor", "elasticmapreduce:OpenEditorInConsole"`
Vorhandene Amazon-EMR-Cluster, die mit dem Workspace verknüpft sind, anhängen oder trennen	Ja	Ja	Ja	`"elasticmapreduce:AttachEditor", "elasticmapreduce:DetachEditor", "elasticmapreduce:ListClusters", "elasticmapreduce:DescribeCluster", "elasticmapreduce:ListInstanceGroups", "elasticmapreduce:ListBootstrapActions"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Amazon EMR in EKS-Clustern anfügen oder trennen	Ja	Ja	Ja	`"elasticmapreduce:AttachEditor", "elasticmapreduce:DetachEditor", "emr-containers:ListVirtualClusters", "emr-containers:DescribeVirtualCluster", "emr-containers:ListManagedEndpoints", "emr-containers:DescribeManagedEndpoint", "emr-containers:GetManagedEndpointSessionCredentials"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Serverless-EMR-Anwendungen, die dem Workspace zugeordnet sind, anhängen oder trennen	Nein	Ja	Ja	`"elasticmapreduce:AttachEditor", "elasticmapreduce:DetachEditor", "emr-serverless:GetApplication", "emr-serverless:StartApplication", "emr-serverless:ListApplications", "emr-serverless:GetDashboardForJobRun", "emr-serverless:AccessInteractiveEndpoints", "iam:PassRole"` Die `PassRole`-Berechtigung ist erforderlich, um die EMR-Serverless-Auftragsausführungs-Rolle zu übergeben. Weitere Informationen finden Sie unter Auftragslaufzeitrollen im Benutzerhandbuch für Amazon EMR Serverless.

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Amazon EMR in EC2-Aufträgen mit persistenten Anwendungsbenutzeroberflächen debuggen	Ja	Ja	Ja	`"elasticmapreduce:CreatePersistentAppUI", "elasticmapreduce:DescribePersistentAppUI", "elasticmapreduce:GetPersistentAppUIPresignedURL", "elasticmapreduce:ListClusters", "elasticmapreduce:ListSteps", "elasticmapreduce:DescribeCluster", "s3:ListBucket", "s3:GetObject"`
Amazon EMR in EC2-Aufträgen mit Benutzeroberflächen für Cluster-Anwendungen deuggen	Ja	Ja	Ja	`"elasticmapreduce:GetOnClusterAppUIPresignedURL"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Amazon EMR in EKS-Auftragsausführungen mit dem Spark History Server debuggen	Ja	Ja	Ja	`"elasticmapreduce:CreatePersistentAppUI", "elasticmapreduce:DescribePersistentAppUI", "elasticmapreduce:GetPersistentAppUIPresignedURL", "emr-containers:ListVirtualClusters", "emr-containers:DescribeVirtualCluster", "emr-containers:ListJobRuns", "emr-containers:DescribeJobRun", "s3:ListBucket", "s3:GetObject"`
Git-Repositorys erstellen und löschen	Ja	Ja	Ja	`"elasticmapreduce:CreateRepository", "elasticmapreduce:DeleteRepository", "elasticmapreduce:ListRepositories", "elasticmapreduce:DescribeRepository", "secretsmanager:CreateSecret", "secretsmanager:ListSecrets", "secretsmanager:TagResource"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Git-Repositorys verknüpfen und trennen	Ja	Ja	Ja	`"elasticmapreduce:LinkRepository", "elasticmapreduce:UnlinkRepository", "elasticmapreduce:ListRepositories", "elasticmapreduce:DescribeRepository"`
Neue Cluster aus vordefinierten Cluster-Vorlagen erstellen	Nein	Ja	Ja	`"servicecatalog:SearchProducts", "servicecatalog:DescribeProduct", "servicecatalog:DescribeProductView", "servicecatalog:DescribeProvisioningParameters", "servicecatalog:ProvisionProduct", "servicecatalog:UpdateProvisionedProduct", "servicecatalog:ListProvisioningArtifacts", "servicecatalog:DescribeRecord", "servicecatalog:ListLaunchPaths", "cloudformation:DescribeStackResources", "elasticmapreduce:ListClusters", "elasticmapreduce:DescribeCluster"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Neue Cluster durch die Bereitstellung einer Clusterkonfiguration erstellen	Nein	Nein	Ja	`"elasticmapreduce:RunJobFlow", "iam:PassRole", "elasticmapreduce:ListClusters", "elasticmapreduce:DescribeCluster"`
Weisen Sie einem Studio einen Benutzer zu, wenn Sie den IAM-Authentifizierungsmodus verwenden. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.	Nein	Nein	Nein	`"elasticmapreduce:CreateStudioPresignedUrl"`

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen

Beschreiben Sie Netzwerkobjekte.	Ja	Ja	Ja	{
				"Version": "2012-10-17",
				"Statement": [
				{
				"Sid": "DescribeNetwork",
				"Effect": "Allow",
				"Action": [
				"ec2:DescribeVpcs",
				"ec2:DescribeSubnets",
				"ec2:DescribeSecurityGroups"
				],
				"Resource": "*"
				}
				]
				}

Action	Basic	Intermediär	Advanced	Zugeordnete Aktionen
Listen Sie die IAM-Rollen auf.	Ja	Ja	Ja	`{ "Version": "2012-10-17", "Statement": [ { "Sid": "ListIAMRoles", "Effect": "Allow", "Action": [ "iam:ListRoles" ], "Resource": "*" } ] }`
Stellen Sie von Amazon SageMaker Studio aus eine Verbindung zu EMR Studio her und verwenden Sie die visuelle Oberfläche von Data Wrangler.	Nein	Nein	Ja	`"sagemaker:CreatePresignedDomainUrl", "sagemaker:DescribeDomain", "sagemaker:ListDomains", "sagemaker:ListUserProfiles"`

Ein EMR Studio erstellen

Sie können ein EMR Studio für Ihr Team mithilfe der Amazon-EMR-Konsole oder der AWS CLI erstellen. Das Erstellen einer Studio-Instance ist Teil der Einrichtung von Amazon EMR Studio.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

Voraussetzungen

Bevor Sie ein Studio erstellen, stellen Sie sicher, dass Sie die vorherigen Aufgaben in Ein Amazon EMR Studio einrichten abgeschlossen haben.

Um ein Studio mit AWS CLI zu erstellen, sollte die neueste Version installiert sein. Weitere Informationen finden Sie unter Installieren oder Aktualisierung auf die neueste Version von AWS CLI.

> **Important**
>
> Deaktivieren Sie Proxy-Management-Tools wie FoxyProxy oder SwitchyOmega im Browser, bevor Sie ein Studio erstellen. Aktive Proxys können zu einer Netzwerkfehler-Fehlermeldung führen, wenn Sie Studio erstellen wählen.

New console

So erstellen Sie ein EMR Studio mit der neuen Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR Studio die Option Erste Schritte aus. Sie können auf der Studio-Seite auch ein neues Studio erstellen.
3. Wählen Sie Studio erstellen, um die Seite Studio erstellen zu öffnen.
4. Geben Sie einen Studionamen und optional eine Beschreibung ein.
5. Wenn Sie die IAM-Authentifizierung für das Studio verwenden, können Sie Neues Tag hinzufügen wählen, um dem Studio ein oder mehrere Key-Value-Tags Ihrer Wahl hinzuzufügen. Sie verwenden Tags, um bestimmten Benutzern Zugriff auf das Studio zu gewähren. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Sie können auch Tags hinzufügen, um Studios zu verwalten, zu identifizieren, zu organisieren und zu filtern. Weitere Informationen finden Sie unter Markieren von AWS-Ressourcen.

6. Wählen Sie unter Netzwerk eine Amazon Virtual Private Cloud (VPC) für das Studio aus der Drop-down-Liste aus.
7. Wählen Sie unter Subnetze maximal fünf Subnetze in Ihrer VPC aus, die Sie dem Studio zuordnen möchten. Sie haben die Möglichkeit, weitere Subnetze hinzuzufügen, nachdem Sie das Studio erstellt haben.
8. Wählen Sie für Sicherheitsgruppen entweder die Standardsicherheitsgruppen oder benutzerdefinierte Sicherheitsgruppen aus. Weitere Informationen finden Sie unter Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio.

Wenn Sie folgendes auswählen …	Vorgehensweise
Die Standard-Sicherheitsgruppen von EMR Studio	Um die Git-basierte Repository-Verknüp fung für das Studio zu aktivieren, wählen Sie Cluster/Endpunkte und Git-Repository aktivieren. Wählen Sie andernfalls Cluster/ Endpunkte aktivieren.
Benutzerdefinierte Sicherheitsgruppen für Ihr Studio	• Wählen Sie unter Cluster-/Endpunkts icherheitsgruppe die Engine-Sicherheits gruppe aus, die Sie aus der Dropdownl iste konfiguriert haben. Ihr Studio verwendet diese Sicherheitsgruppe, um eingehenden Zugriff von verbundenen Workspaces aus zu ermöglichen. • Wählen Sie unter Workspace-Sicherhe itsgruppe die Workspace-Sicherhe itsgruppe aus, die Sie aus der Dropdownl iste konfiguriert haben. Ihr Studio verwendet diese Sicherheitsgruppe mit Workspaces, um ausgehenden Zugriff auf verbundene Amazon-EMR-Cluster und öffentlich gehostete Git-Repositorys zu ermöglichen.

9. Wählen Sie unter Authentifizierung einen Authentifizierungsmodus für das Studio und geben Sie die Informationen gemäß der folgenden Tabelle ein. Weitere Informationen zur Authentifizierung für EMR Studio finden Sie unter Einen Authentifizierungsmodus für Amazon EMR Studio auswählen.

Wenn Sie …	Vorgehensweise
IAM-Authentifizierung oder -Verbund verwenden	Wählen Sie eine Anmeldemethode für das Studio. Wenn Sie möchten, dass sich Verbundbenutzer mit der Studio-URL und den Anmeldeinformationen für Ihren Identitätsanbieter (IdP) anmelden, wählen Sie Ihren IdP aus der Dropdownliste aus und geben Sie Ihre Anmelde-URL für Identitätsanbieter (IdP) und den Namen des RelayState-Parameters ein. Eine Liste der IdP-Authentifizierungs-URLs und RelayState-Namen finden Sie unter RelayState-Parameter und Authentifizierungs-URLs des Identitätsanbieters. Wählen Sie dann Ihre EMR-Studio-Servicerolle aus der Dropdownliste aus. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.
Authentifizierung von IAM Identity Center	Wählen Sie Ihre EMR-Studio-Servicerolle und Benutzerrolle aus. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen und Eine EMR-Studio-Benutzerrolle für den IAM-Identity-Center-Authentifizierungsmodus erstellen.

10. Wählen Sie unter Workspace-Speicher die Option S3 durchsuchen, um Ihren Amazon-S3-Bucket für die Sicherung von Workspaces und Notebookdateien auszuwählen.

> **Note**
>
> Ihre EMR-Studio-Servicerolle muss Lese- und Schreibberechtigungen für den Bucket entsprechen, den Sie auswählen.

11. Wählen Sie Studio erstellen, um den Vorgang abzuschließen, und navigieren Sie zur Studios-Seite. Ihr neues Studio wird in der Liste mit Details wie dem Studio-Namen, dem Erstellungsdatum und der Studio-Zugriffs-URL angezeigt.

Nachdem Sie ein Studio erstellt haben, folgen Sie den Anweisungen unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

Old console

So erstellen Sie ein EMR-Studio mit der alten Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie Studio erstellen, um die Seite Studio erstellen zu öffnen.
4. Geben Sie einen Studionamen und optional eine Beschreibung ein.
5. Wenn Sie die IAM-Authentifizierung für das Studio verwenden, können Sie Neues Tag hinzufügen wählen, um dem Studio ein oder mehrere Key-Value-Tags Ihrer Wahl hinzuzufügen. Sie verwenden Tags, um bestimmten Benutzern Zugriff auf das Studio zu gewähren. Weitere Informationen finden Sie unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

   Sie können auch Tags hinzufügen, um Studios zu verwalten, zu identifizieren, zu organisieren und zu filtern. Weitere Informationen finden Sie unter Markieren von AWS-Ressourcen.
6. Wählen Sie unter Netzwerk eine Amazon Virtual Private Cloud (VPC) für das Studio aus der Drop-down-Liste aus.
7. Wählen Sie unter Subnetze maximal fünf Subnetze in Ihrer VPC aus, die Sie dem Studio zuordnen möchten. Sie haben die Möglichkeit, weitere Subnetze hinzuzufügen, nachdem Sie das Studio erstellt haben.

8. Wählen Sie für Sicherheitsgruppen entweder die Standardsicherheitsgruppen oder benutzerdefinierte Sicherheitsgruppen aus. Weitere Informationen finden Sie unter Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio.

Wenn Sie folgendes auswählen …	Vorgehensweise
Die Standard-Sicherheitsgruppen von EMR Studio	Um die Git-basierte Repository-Verknüp fung für das Studio zu aktivieren, wählen Sie Cluster/Endpunkte und Git-Repository aktivieren. Wählen Sie andernfalls Cluster/ Endpunkte aktivieren.
Benutzerdefinierte Sicherheitsgruppen für Ihr Studio	• Wählen Sie unter Cluster-/Endpunkts icherheitsgruppe die Engine-Sicherheits gruppe aus, die Sie aus der Dropdownl iste konfiguriert haben. Ihr Studio verwendet diese Sicherheitsgruppe, um eingehenden Zugriff von verbundenen Workspaces aus zu ermöglichen. • Wählen Sie unter Workspace-Sicherhe itsgruppe die Workspace-Sicherhe itsgruppe aus, die Sie aus der Dropdownl iste konfiguriert haben. Ihr Studio verwendet diese Sicherheitsgruppe mit Workspaces, um ausgehenden Zugriff auf verbundene Amazon-EMR-Cluster und öffentlich gehostete Git-Repositorys zu ermöglichen.

9. Wählen Sie unter Authentifizierung einen Authentifizierungsmodus für das Studio und geben Sie die Informationen gemäß der folgenden Tabelle ein. Weitere Informationen zur Authentifizierung für EMR Studio finden Sie unter Einen Authentifizierungsmodus für Amazon EMR Studio auswählen.

Wenn Sie …	Vorgehensweise
IAM-Authentifizierung oder -Verbund verwenden	Wählen Sie eine Anmeldemethode für das Studio. Wenn Sie möchten, dass sich Verbundbenutzer mit der Studio-URL und den Anmeldeinformationen für Ihren Identitätsanbieter (IdP) anmelden, wählen Sie Ihren IdP aus der Dropdownliste aus und geben Sie Ihre Anmelde-URL für Identitätsanbieter (IdP) und den Namen des RelayState-Parameters ein. Eine Liste der IdP-Authentifizierungs-URLs und RelayState-Namen finden Sie unter RelayState-Parameter und Authentifizierungs-URLs des Identitätsanbieters. Wählen Sie dann Ihre EMR-Studio-Servicerolle aus der Dropdownliste aus. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.
Authentifizierung von IAM Identity Center	Wählen Sie Ihre EMR-Studio-Servicerolle und Benutzerrolle aus. Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen und Eine EMR-Studio-Benutzerrolle für den IAM-Identity-Center-Authentifizierungsmodus erstellen.

10. Wählen Sie unter Workspace-Speicher die Option S3 durchsuchen, um Ihren Amazon-S3-Bucket für die Sicherung von Workspaces und Notebookdateien auszuwählen.

> **Note**
>
> Ihre EMR-Studio-Servicerolle muss Lese- und Schreibberechtigungen für den Bucket entsprechen, den Sie auswählen.

11. Wählen Sie Studio erstellen, um den Vorgang abzuschließen, und navigieren Sie zur Studios-Seite. Ihr neues Studio wird in der Liste mit Details wie dem Studio-Namen, dem Erstellungsdatum und der Studio-Zugriffs-URL angezeigt.

Nachdem Sie ein Studio erstellt haben, folgen Sie den Anweisungen unter Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu.

CLI

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

Example CLI-Befehl zum Erstellen eines EMR Studios mit IAM-Authentifizierungsmodus

Der folgende AWS CLI-Beispielbefehl erstellt ein EMR Studio mit IAM-Authentifizierungsmodus. Wenn Sie die IAM-Authentifizierung oder den Verbund für das Studio verwenden, geben Sie kein `--user-role` an.

Damit sich Verbundbenutzer mit der Studio-URL und den Anmeldeinformationen für Ihren Identitätsanbieter (IdP) anmelden können, geben Sie Ihr `--idp-auth-url` und `--idp-relay-state-parameter-name` an. Eine Liste der IdP-Authentifizierungs-URLs und RelayState-Namen finden Sie unter RelayState-Parameter und Authentifizierungs-URLs des Identitätsanbieters.

```
aws emr create-studio \
--name <example-studio-name> \
--auth-mode IAM \
--vpc-id <example-vpc-id> \
--subnet-ids <subnet-id-1> <subnet-id-2>... <subnet-id-5>  \
```

```
--service-role <example-studio-service-role-name> \
--workspace-security-group-id <example-workspace-sg-id> \
--engine-security-group-id <example-engine-sg-id> \
--default-s3-location <example-s3-location> \
--idp-auth-url <https://EXAMPLE/login/> \
--idp-relay-state-parameter-name <example-RelayState>
```

Example CLI-Befehl zum Erstellen eines EMR Studios mit dem IAM-Identity-Center-Authentifizierungsmodus

Mit dem folgenden AWS CLI Beispielbefehl wird ein EMR Studio erstellt, das den IAM-Identity-Center-Authentifizierungsmodus verwendet. Wenn Sie die IAM-Identity-Center-Authentifizierung verwenden, müssen Sie eine `--user-role` angeben.

Weitere Informationen zum Authentifizierungsmodus von IAM Identy Center finden Sie unter Richten Sie den IAM-Identity-Center-Authentifizierungsmodus für Amazon EMR Studio ein.

```
aws emr create-studio \
--name <example-studio-name> \
--auth-mode SSO \
--vpc-id <example-vpc-id> \
--subnet-ids <subnet-id-1> <subnet-id-2>... <subnet-id-5>  \
--service-role <example-studio-service-role-name> \
--user-role <example-studio-user-role-name> \
--workspace-security-group-id <example-workspace-sg-id> \
--engine-security-group-id <example-engine-sg-id> \
--default-s3-location <example-s3-location>
```

Example CLI-Ausgabe für **`aws emr create-studio`**

Es folgt ein Beispiel für die Ausgabe, die nach dem Erstellen eines Studios erscheint.

```
{
    StudioId: "es-123XXXXXXXXX",
    Url: "https://es-123XXXXXXXXX.emrstudio-prod.us-east-1.amazonaws.com"
}
```

Weitere Informationen über den Befehl `create-studio` finden Sie unter AWS CLI-Befehlsreferenz.

RelayState-Parameter und Authentifizierungs-URLs des Identitätsanbieters

Wenn Sie den IAM-Verbund verwenden und möchten, dass sich Benutzer mit Ihrer Studio-URL und den Anmeldeinformationen für Ihren Identity Provider (IdP) anmelden, können Sie Ihre Identitätsanbieter (IDP)-Anmelde-URL und den RelayState-Parameternamen angeben, wenn Sie Ein EMR Studio erstellen

Die folgende Tabelle zeigt die Standardauthentifizierungs-URL und den RelayState-Parameternamen für einige beliebte Identitätsanbieter.

Identitätsanbieter	Parameter	Authentifizierungs-URL
Auth0	`RelayState`	`https://<sub_domain> .auth0.com/samlp/<app_id>`
Google-Konten	`RelayState`	`https://accounts.google.com/o/saml2/initsso?idpid= <idp_id>&spid=<sp_id>&forceauthn=false`
Microsoft Azure	`RelayState`	`https://myapps.microsoft.com/signin/ <app_name> /<app_id>?tenantId= <tenant_id>`
Okta	`RelayState`	`https://<sub_domain> .okta.com/app/<app_name> /<app_id>/sso/saml`
PingFederate	`TargetResource`	`https://<host>/idp/<idp_id>/startSSO.ping?PartnerSpId= <sp_id>`
PingOne	`TargetResource`	`https://sso.connect.pingidentity.com/sso/sp/initsso?saasid= <app_id>&idpid=<idp_id>`

EMR-Studio-Benutzer zuweisen und verwalten

Nachdem Sie ein EMR Studio erstellt haben, können Sie ihm Benutzer und Gruppen zuweisen. Die Methode, mit der Sie Benutzer zuweisen, aktualisieren und entfernen, hängt vom Studio-Authentifizierungsmodus ab.

- Wenn Sie den IAM-Authentifizierungsmodus verwenden, konfigurieren Sie die Benutzerzuweisung und die Berechtigungen von EMR Studio in IAM oder mit IAM und Ihrem Identitätsanbieter.
- Im IAM-Identity-Center-Authentifizierungsmodus verwenden Sie die Amazon-EMR-Verwaltungskonsole oder AWS CLI, um Benutzer zu verwalten.

Weitere Informationen zur Authentifizierung für Amazon EMR Studio finden Sie unter Einen Authentifizierungsmodus für Amazon EMR Studio auswählen.

Weisen Sie EMR Studio einen Benutzer oder eine Gruppe zu

IAM

Wenn SieIAM-Authentifizierungsmodus für Amazon EMR Studio einrichten verwenden, müssen Sie die `CreateStudioPresignedUrl`-Aktion in der IAM-Berechtigungsrichtlinie eines Benutzers zulassen und den Benutzer auf ein bestimmtes Studio beschränken. Sie können `CreateStudioPresignedUrl` in Ihre eigene Benutzerberechtigungen für den IAM-Authentifizierungsmodus aufnehmen oder eine separate Richtlinie verwenden.

Um einen Benutzer auf ein Studio (oder eine Gruppe von Studios) zu beschränken, können Sie die attributbasierte Zugriffskontrolle (ABAC) verwenden oder den Amazon-Ressourcennamen (ARN) eines Studios im `Resource` Element der Berechtigungsrichtlinie angeben.

Example Weisen Sie einem Studio mithilfe eines Studio-ARN einen Benutzer zu

Die folgende Beispielrichtlinie gewährt einem Benutzer Zugriff auf ein bestimmtes EMR Studio, indem die `CreateStudioPresignedUrl`-Aktion zugelassen und der Amazon-Ressourcenname (ARN) des Studios im `Resource`-Element angegeben wird.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowCreateStudioPresignedUrl",
```

```
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:CreateStudioPresignedUrl"
            ],
            "Resource": "arn:aws:elasticmapreduce:<region>:<account-
id>:studio/<studio-id>"
        }
    ]
}
```

Example Einem Studio mit ABAC einen Benutzer für die IAM-Authentifizierung zuweisen

Es gibt mehrere Möglichkeiten, attributbasierte Zugriffskontrolle (ABAC) für ein Studio zu konfigurieren. Sie können beispielsweise ein oder mehrere Tags an ein EMR Studio anhängen und dann eine IAM-Richtlinie erstellen, die die `CreateStudioPresignedUrl`-Aktion auf ein bestimmtes Studio oder eine Gruppe von Studios mit diesen Tags beschränkt.

Sie können Tags während oder nach der Erstellung von Studio hinzufügen. Verwenden Sie den Befehl AWS CLI`emr add-tags`, um Tags zu einem bestehenden Studio hinzuzufügen. Das folgende Beispiel fügt einem EMR Studio ein Tag mit dem Schlüssel-Wert-Paar `Team = Data Analytics` hinzu.

```
aws emr add-tags --resource-id <example-studio-id> --tags Team="Data Analytics"
```

Die folgende Beispiel-Berechtigungsrichtlinie ermöglicht die `CreateStudioPresignedUrl`-Aktion für EMR Studios mit dem Tag key-value pair `Team = DataAnalytics`. Weitere Informationen zur Verwendung von Tags zur Zugriffssteuerung finden Sie unter Zugriffskontrolle für Benutzer und Rollen mithilfe von Tags oder Zugriffskontrolle auf AWS-Ressourcen mithilfe von Tags.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowCreateStudioPresignedUrl",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:CreateStudioPresignedUrl"
            ],
            "Resource": "arn:aws:elasticmapreduce:<region>:<account-id>:studio/*",
            "Condition": {
```

```
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/Team": "Data Analytics"
                }
            }
        }
    ]
}
```

Example Weisen Sie einem Studio mithilfe des globalen Bedingungsschlüssels aws:SourceIdentity einen Benutzer zu

Wenn Sie den IAM-Verbund verwenden, können Sie den globalen Bedingungsschlüssel `aws:SourceIdentity` in einer Berechtigungsrichtlinie verwenden, um Benutzern Studio-Zugriff zu gewähren, wenn sie Ihre IAM-Rolle für den Verbund übernehmen.

Sie müssen zunächst Ihren Identitätsanbieter (IdP) so konfigurieren, dass er eine identifizierende Zeichenfolge zurückgibt, z. B. eine E-Mail-Adresse oder einen Benutzernamen, wenn sich ein Benutzer authentifiziert und Ihre IAM-Rolle für den Verbund übernimmt. IAM setzt den globalen Bedingungsschlüssel `aws:SourceIdentity` auf die identifizierende Zeichenfolge, die von Ihrem IdP zurückgegeben wurde.

Weitere Informationen finden Sie im Blogbeitrag Wie Sie die IAM-Rollenaktivität mit der Unternehmensidentität verknüpfen können im AWS-Sicherheits-Blog und im Eintrag aws:SourceIdentity in der Referenz zu den globalen Bedingungsschlüsseln.

Die folgende Beispielrichtlinie ermöglicht die `CreateStudioPresignedUrl` Aktion und gewährt Benutzern mit einer `aws:SourceIdentity`, die dem *<example-source-identity>* von *<example-studio-arn>* angegebenen Zugriff auf das EMR Studio entspricht.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "elasticmapreduce:CreateStudioPresignedUrl",
      "Resource": "<example-studio-arn>",
      "Condition": {
        "StringLike": {
          "aws:SourceIdentity": "<example-source-identity>"
        }
      }
```

```
    }
  ]
}
```

IAM Identity Center

Wenn Sie einem EMR Studio einen Benutzer oder eine Gruppe zuweisen, geben Sie eine Sitzungsrichtlinie an, die detaillierte Berechtigungen für diesen Benutzer oder diese Gruppe definiert, z. B. die Möglichkeit, einen neuen EMR-Cluster zu erstellen. Amazon EMR speichert diese Zuordnungen von Sitzungsrichtlinien. Sie können die Sitzungsrichtlinie eines Benutzers oder einer Gruppe nach der Zuweisung aktualisieren.

> **Note**
>
> Die endgültigen Berechtigungen für einen Benutzer oder eine Gruppe sind eine Schnittmenge der in Ihrer EMR-Studio-Benutzerrolle definierten Berechtigungen und den in der Sitzungsrichtlinie für diesen Benutzer oder diese Gruppe definierten Berechtigungen. Wenn ein Benutzer zu mehr als einer Gruppe gehört, die dem Studio zugewiesen ist, verwendet EMR Studio eine Kombination von Berechtigungen für diesen Benutzer.

So weisen Sie einem EMR Studio mithilfe der Amazon-EMR-Konsole Benutzer oder Gruppen zu

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie Ihren Studio-Namen aus der Studio-Liste oder wählen Sie das Studio aus und klicken Sie auf Details anzeigen, um die Studio-Detailseite zu öffnen.
4. Wählen Sie die Benutzer hinzufügen um die Suchtabelle Benutzer und Gruppen anzuzeigen.
5. Wählen Sie die Registerkarte Benutzer oder die Registerkarte Gruppen und geben Sie einen Suchbegriff in die Suchleiste ein, um einen Benutzer oder eine Gruppe zu finden.
6. Wählen Sie einen oder mehrere Benutzer oder Gruppen aus der Suchergebnisliste aus. Sie können zwischen der Registerkarte Benutzer und der Registerkarte Gruppen hin- und herwechseln.

7. Nachdem Sie Benutzer und Gruppen ausgewählt haben, die Sie dem Studio hinzufügen möchten, wählen Sie Hinzufügen. Sie sollten sehen, dass die Benutzer und Gruppen in der Studio-Benutzerliste angezeigt werden. Es kann einige Sekunden dauern, bis die Liste aktualisiert wird.
8. Folgen Sie den Anweisungen unter Aktualisieren Sie die Berechtigungen für einen Benutzer oder eine Gruppe, die einem Studio zugewiesen ist, um die Studio-Berechtigungen für einen Benutzer oder eine Gruppe zu verfeinern.

Wie Sie EMR Studio einen Benutzer oder eine Gruppe mit AWS CLI zuweisen

Fügen Sie Ihre eigenen Werte für die folgenden `create-studio-session-mapping`-Argumente ein. Weitere Informationen über den Befehl `create-studio-session-mapping` finden Sie unter AWS CLI-Befehlsreferenz.

- **`--studio-id`** – Die ID des Studios, dem Sie den Benutzer oder die Gruppe zuweisen möchten. Anleitungen zum Abrufen einer Studio-ID finden Sie unter Studio-Details anzeigen.
- **`--identity-name`** – Der Name des Benutzers oder der Gruppe aus dem Identitätsspeicher. Weitere Informationen finden Sie unter UserName und DisplayName für Gruppen in der API-Referenz zum Identitätsspeicher.
- **`--identity-type`** – Verwenden Sie entweder `USER` oder `GROUP`, um den Identitätstyp anzugeben.
- **`--session-policy-arn`** – Der Amazon-Ressourcenname (ARN) für die Sitzungsrichtlinie, die Sie mit dem Benutzer oder der Gruppe verknüpfen möchten. Zum Beispiel **`arn:aws:iam::`*`<aws-account-id>`*`:policy/`*`EMRStudio_Advanced_User_Policy`**. Weitere Informationen finden Sie unter Berechtigungsrichtlinien für EMR-Studio-Benutzer erstellen.

```
aws emr create-studio-session-mapping \
 --studio-id <example-studio-id> \
 --identity-name <example-identity-name> \
 --identity-type <USER-or-GROUP> \
 --session-policy-arn <example-session-policy-arn>
```

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

Verwenden Sie den `get-studio-session-mapping`-Befehl, um die neue Zuweisung zu überprüfen. Ersetzen Sie *<example-identity-name>* durch den IAM-Identity-Center-Namen des Benutzers oder der Gruppe, den Sie aktualisiert haben.

```
aws emr get-studio-session-mapping \
 --studio-id <example-studio-id> \
 --identity-type <USER-or-GROUP> \
 --identity-name <user-or-group-name> \
```

Aktualisieren Sie die Berechtigungen für einen Benutzer oder eine Gruppe, die einem Studio zugewiesen ist

IAM

Um Benutzer- oder Gruppenberechtigungen zu aktualisieren, wenn Sie den IAM-Authentifizierungsmodus verwenden, verwenden Sie IAM, um die IAM-Berechtigungsrichtlinien zu ändern, die Ihren IAM-Identitäten (Benutzern, Gruppen oder Rollen) zugeordnet sind.

Weitere Informationen finden Sie unter Benutzerberechtigungen für den IAM-Authentifizierungsmodus.

IAM Identity Center

So aktualisieren Sie die EMR-Studio-Berechtigungen für einen Benutzer oder eine Gruppe mithilfe der Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie Ihren Studio-Namen aus der Studio-Liste oder wählen Sie das Studio aus und klicken Sie auf Details anzeigen, um die Studio-Detailseite zu öffnen.

4. Suchen Sie in der Studio-Benutzerliste auf der Studio-Detailseite nach dem Benutzer oder der Gruppe, die Sie aktualisieren möchten. Sie können nach Namen oder Identitätstyp suchen.
5. Wählen Sie den Benutzer oder die Gruppe aus, den bzw. die Sie aktualisieren möchten, und wählen Sie Richtlinie zuweisen, um das Dialogfeld Sitzungsrichtlinie zu öffnen.
6. Wählen Sie eine Richtlinie aus, die auf den Benutzer oder die Gruppe angewendet werden soll, den Sie in Schritt 5 ausgewählt haben, und klicken Sie dann auf Richtlinie anwenden. In der Liste Studio-Benutzer sollte der Richtlinienname in der Spalte Sitzungsrichtlinie für den Benutzer oder die Gruppe angezeigt werden, den Sie aktualisiert haben.

Wie Sie die EMR-Studio-Berechtigungen für einen Benutzer oder eine Gruppe mit AWS CLI aktualisieren

Fügen Sie Ihre eigenen Werte für die folgenden `update-studio-session-mappings`-Argumente ein. Weitere Informationen über den Befehl `update-studio-session-mappings` finden Sie unter AWS CLI-Befehlsreferenz.

```
aws emr update-studio-session-mapping \
 --studio-id <example-studio-id> \
 --identity-name <name-of-user-or-group-to-update> \
 --session-policy-arn <new-session-policy-arn-to-apply> \
 --identity-type <USER-or-GROUP> \
```

Verwenden Sie den `get-studio-session-mapping`-Befehl, um die neue Zuweisung der Sitzungsrichtlinie zu überprüfen. Ersetzen Sie *<example-identity-name>* durch den IAM-Identity-Center-Namen des Benutzers oder der Gruppe, den Sie aktualisiert haben.

```
aws emr get-studio-session-mapping \
 --studio-id <example-studio-id> \
 --identity-type <USER-or-GROUP> \
 --identity-name <user-or-group-name> \
```

Einen Benutzer oder eine Gruppe aus einem Studio entfernen

IAM

Um einen Benutzer oder eine Gruppe aus einem EMR Studio zu entfernen, wenn Sie den IAM-Authentifizierungsmodus verwenden, müssen Sie dem Benutzer den Zugriff auf das Studio entziehen, indem Sie die IAM-Berechtigungsrichtlinie des Benutzers neu konfigurieren.

Gehen Sie in der folgenden Beispielrichtlinie davon aus, dass Sie über ein EMR Studio mit dem Tag-Schlüsselwertpaar `Team = Quality Assurance` verfügen. Gemäß der Richtlinie kann der Benutzer auf Studios zugreifen, die mit dem `Team`-Schlüssel gekennzeichnet sind, dessen Wert entweder `Data Analytics` oder `Quality Assurance` entspricht. Um den Benutzer aus dem Studio zu entfernen, das mit `Team = Quality Assurance` markiert ist, entfernen Sie `Quality Assurance` aus der Liste der Tag-Werte.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowCreateStudioPresignedUrl",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:CreateStudioPresignedUrl"
            ],
            "Resource": "arn:aws:elasticmapreduce:<region>:<account-id>:studio/*",
            "Condition": {
                "StringEquals": {
                    "emr:ResourceTag/Team": [
                        "Data Analytics",
                        "Quality Assurance"
                  ]
                }
            }
        }
    ]
}
```

IAM Identity Center

So entfernen Sie einen Benutzer oder eine Gruppe mithilfe der Konsole aus einem EMR Studio

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie Ihren Studio-Namen aus der Studio-Liste oder wählen Sie das Studio aus und klicken Sie auf Details anzeigen, um die Studio-Detailseite zu öffnen.
4. Suchen Sie in der Liste Studio-Benutzer auf der Studio-Detailseite nach dem Benutzer oder der Gruppe, die Sie aus dem Studio entfernen möchten. Sie können nach Namen oder Identitätstyp suchen.
5. Wählen Sie den Benutzer oder die Gruppe aus, die Sie löschen möchten, wählen Sie Löschen und bestätigen Sie das Löschen. Der Benutzer oder die Gruppe, den Sie gelöscht haben, verschwindet aus der Liste Studio-Benutzer.

Wie Sie einen Benutzer oder eine Gruppe aus einem EMR Studio mit der AWS CLI entfernen

Fügen Sie Ihre eigenen Werte für die folgenden `delete-studio-session-mapping`-Argumente ein. Weitere Informationen über den Befehl `delete-studio-session-mapping` finden Sie unter AWS CLI-Befehlsreferenz.

```
aws emr delete-studio-session-mapping \
 --studio-id <example-studio-id> \
 --identity-type <USER-or-GROUP> \
 --identity-name <name-of-user-or-group-to-delete> \
```

Ein Amazon EMR Studio verwalten

Dieser Abschnitt enthält Anweisungen, die Ihnen helfen, eine EMR-Studio-Ressource zu überwachen, zu aktualisieren oder zu löschen. Informationen zum Zuweisen von Benutzern oder zum Aktualisieren von Benutzerberechtigungen finden Sie unter EMR-Studio-Benutzer zuweisen und verwalten.

Studio-Details anzeigen

New console

So zeigen Sie Details zu einem EMR Studio mit der neuen Konsole an

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR Studio die Option Studios aus.
3. Wählen Sie das Studio aus der Studio-Liste aus, um die Studio-Detailseite zu öffnen. Die Studio-Detailseite enthält Informationen zu den Studio-Einstellungen, z. B. die Studio-Beschreibung, VPC und Subnetze.

Old console

So zeigen Sie Details zu einem EMR Studio mit der alten Konsole an

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie das Studio aus der Studio-Liste aus, um die Studio-Detailseite zu öffnen. Die Studio-Detailseite enthält Informationen zu den Studio-Einstellungen, z. B. die Studio-Beschreibung, VPC und Subnetze.

CLI

Um Details für ein EMR Studio anhand der Studio-ID abzurufen, verwenden Sie den AWS CLI

Verwenden Sie den folgenden Befehl `describe-studio` AWS CLI, um detaillierte Informationen zu einem bestimmten EMR Studio abzurufen. Weitere Informationen finden Sie in der AWS CLI-Befehlsreferenz.

```
aws emr describe-studio \
 --studio-id <id-of-studio-to-describe> \
```

Um eine Liste von EMR Studios abzurufen, verwenden Sie AWS CLI

Verwenden Sie den folgenden `list-studios` AWS CLI-Befehl. Weitere Informationen finden Sie in der AWS CLI-Befehlsreferenz.

```
aws emr list-studios
```

Es folgt ein Beispiel für einen Rückgabewert für den `list-studios`-Befehl im JSON-Format.

```
{
    "Studios": [
        {
            "AuthMode": "IAM",
            "VpcId": "vpc-b21XXXXX",
            "Name": "example-studio-name",
            "Url": "https://es-7HWP74SNGDXXXXXXXXXXXXXX.emrstudio-prod.us-
east-1.amazonaws.com",
            "CreationTime": 1605672582.781,
            "StudioId": "es-7HWP74SNGDXXXXXXXXXXXXXX",
            "Description": "example studio description"
        }
    ]
}
```

Amazon-EMR-Studio-Aktionen überwachen

EMR-Studio- und API-Aktivitäten anzeigen

EMR Studio ist mit AWS CloudTrail integriert, einem Service, der eine Aufzeichnung der von einem Benutzer, einer IAM Rolle oder einem AWS-Service in EMR Studio durchgeführten Aktionen liefert. CloudTrail erfasst alle API-Aufrufe für EMR Studio als Ereignisse. Sie können Ereignisse mit der CloudTrail-Konsole unter https://console.aws.amazon.com/cloudtrail/ ansehen.

EMR-Studio-Ereignisse liefern Informationen darüber, welcher Studio- oder IAM-Benutzer eine Anfrage stellt und um welche Art von Anfrage es sich handelt.

> **Note**
>
> Clusterinterne Aktionen wie das Ausführen von Notebook-Aufträgen werden AWS CloudTrail nicht ausgegeben.

Wenn Sie einen Trail erstellen, können Sie die kontinuierliche Bereitstellung von EMR Studio CloudTrail-Ereignissen an einen Amazon-S3-Bucket aktivieren. Weitere Informationen finden Sie im AWS CloudTrail-Benutzerhandbuch.

Beispiel für ein CloudTrail-Ereignis: Ein Benutzer ruft die DescribeStudio-API auf

Das Folgende ist ein AWS CloudTrail-Beispielereignis, das erstellt wird, wenn ein Benutzer die `admin`-DescribeStudio-API aufruft. CloudTrail zeichnet den Benutzernamen als `admin` auf.

> **Note**
>
> Um Studio-Details zu schützen, schließt das EMR-Studio-API-Ereignis für DescribeStudio einen Wert für `responseElements` aus.


```
{
   "eventVersion":"1.08",
   "userIdentity":{
      "type":"IAMUser",
      "principalId":"AIDXXXXXXXXXXXXXXXXX",
      "arn":"arn:aws:iam::653XXXXXXXX:user/admin",
      "accountId":"653XXXXXXXX",
      "accessKeyId":"AKIAIOSFODNN7EXAMPLE",
      "userName":"admin"
   },
   "eventTime":"2021-01-07T19:13:58Z",
   "eventSource":"elasticmapreduce.amazonaws.com",
   "eventName":"DescribeStudio",
   "awsRegion":"us-east-1",
   "sourceIPAddress":"72.XX.XXX.XX",
   "userAgent":"aws-cli/1.18.188 Python/3.8.5 Darwin/18.7.0 botocore/1.19.28",
   "requestParameters":{
      "studioId":"es-9O5XXXXXXXXXXXXXXXXXXX"
   },
   "responseElements":null,
   "requestID":"0fxxxxxx-xxxx-xxxx-xxxx-xxxxxxxxxxxx",
   "eventID":"b0xxxxxx-xxxx-xxxx-xxxx-xxxxxxxxxxxx",
   "readOnly":true,
   "eventType":"AwsApiCall",
   "managementEvent":true,
   "eventCategory":"Management",
   "recipientAccountId":"653XXXXXXXX"
}
```

Spark-Benutzer- und Jobaktivitäten anzeigen

Um die Spark-Jobaktivitäten von Amazon-EMR-Studio-Benutzern anzuzeigen, können Sie den Benutzerwechsel in einem Cluster konfigurieren. Beim Identitätswechsel wird jeder Spark-Job, der von einem Workspace aus eingereicht wird, dem Studio-Benutzer zugeordnet, der den Code ausgeführt hat.

Wenn der Benutzerwechsel aktiviert ist, erstellt Amazon EMR ein HDFS-Benutzerverzeichnis auf dem Primärknoten des Clusters für jeden Benutzer, der Code im Workspace ausführt. Wenn beispielsweise ein Benutzer `studio-user-1@example.com`-Code ausführt, können Sie eine Verbindung zum Primärknoten herstellen und sehen, dass `hadoop fs -ls /user` ein Verzeichnis für `studio-user-1@example.com` hat.

Um den Spark-Benutzerwechsel einzurichten, legen Sie die folgenden Eigenschaften in den folgenden Konfigurationsklassifizierungen fest:

- `core-site`
- `livy-conf`

```
[
    {
        "Classification": "core-site",
        "Properties": {
          "hadoop.proxyuser.livy.groups": "*",
          "hadoop.proxyuser.livy.hosts": "*"
        }
    },
    {
        "Classification": "livy-conf",
        "Properties": {
          "livy.impersonation.enabled": "true"
        }
    }
]
```

Informationen zum Anzeigen von Verlaufsserverseiten finden Sie unter Debuggen von Anwendungen und Aufträgen mit EMR Studio. Sie können auch mithilfe von SSH eine Verbindung zum Primärknoten des Clusters herstellen, um die Webschnittstellen der Anwendungen anzuzeigen. Weitere Informationen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Ein Amazon EMR Studio aktualisieren

Nachdem Sie ein EMR Studio erstellt haben, können Sie die folgenden Attribute mit dem AWS CLI aktualisieren:

- Name
- Beschreibung
- Standard-S3-Speicherort
- Subnetze

Um ein EMR Studio mit AWS CLI zu aktualisieren

Verwenden Sie den Befehl `update-studio` AWS CLI, um ein EMR Studio zu aktualisieren. Weitere Informationen finden Sie in der AWS CLI-Befehlsreferenz.

> **Note**
>
> Sie können ein Studio mit maximal 5 Subnetzen verknüpfen. Diese Subnetze müssen zur gleichen VPC gehören wie Studio. Die Liste der Subnetz-IDs, die Sie an den `update-studio` Befehl senden, kann neue Subnetz-IDs enthalten, muss aber auch alle Subnetz-IDs enthalten, die Sie dem Studio bereits zugeordnet haben. Sie können keine Subnetze aus einem Studio entfernen.

```
aws emr update-studio \
 --studio-id <example-studio-id-to-update> \
 --name <example-new-studio-name> \
 --subnet-ids <old-subnet-id-1 old-subnet-id-2 old-subnet-id-3 new-subnet-id> \
```

Um die Änderungen zu überprüfen, verwenden Sie den Befehl `describe-studio` AWS CLI und geben Sie Ihre Studio-ID an. Weitere Informationen finden Sie in der AWS CLI-Befehlsreferenz.

```
aws emr describe-studio \
 --studio-id <id-of-updated-studio> \
```

Löschen Sie ein Amazon EMR Studio und Workspaces

Wenn Sie ein Studio löschen, löscht EMR Studio alle IAM-Identity-Center-Benutzer- und Gruppenzuweisungen, die dem Studio zugeordnet sind.

> **Note**
>
> Wenn Sie ein Studio löschen, löscht Amazon EMR die mit diesem Studio verknüpften Workspaces nicht. Sie müssen die Workspaces in Ihrem Studio separat löschen.

WorkSpaces löschen

Console

Da es sich bei jedem EMR-Studio-Workspace um eine EMR-Notebook-Instance handelt, können Sie die Verwaltungskonsole für Amazon EMR verwenden, um Workspaces zu löschen. Sie können Workspaces mit der Amazon-EMR-Konsole löschen, bevor oder nachdem Sie Ihr Studio gelöscht haben.

Um einen Workspace mit der Amazon-EMR-Konsole zu löschen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Notebooks.
3. Wählen Sie die Arbeitsbereiche aus, die Sie löschen möchten.
4. Wählen Sie Löschen und nochmals Löschen aus, um den Vorgang zu bestätigen.
5. Folgen Sie den Anweisungen zum Löschen von Objekten im Konsolen-Benutzerhandbuch für Amazon Simple Storage Service, um die mit dem gelöschten Workspace verknüpften Notebookdateien aus Amazon S3 zu entfernen.

EMR Studio UI

From the Workspace UI

Löschen Sie einen Workspace und die zugehörigen Backup-Dateien aus EMR Studio

1. Melden Sie sich mit Ihrer Studio-Zugriffs-URL bei Ihrem EMR Studio an und wählen Sie in der linken Navigationsleiste Workspaces aus.
2. Suchen Sie in der Liste nach Ihrem Workspace und aktivieren Sie das Kontrollkästchen neben dessen Namen. Sie können mehrere Arbeitsbereiche zum gleichzeitigen Löschen auswählen.
3. Wählen Sie oben rechts in der Liste der Arbeitsbereiche die Option Löschen aus und bestätigen Sie, dass Sie die ausgewählten Arbeitsbereiche löschen möchten. Wählen Sie zur Bestätigung Delete.
4. Wenn Sie die Notebookdateien, die mit dem gelöschten Workspace verknüpft waren, aus Amazon S3 entfernen möchten, folgen Sie den Anweisungen zum Löschen von Objekten im Konsole-Benutzerhandbuch von Amazon Simple Storage Service. Wenn Sie das Studio nicht erstellt haben, wenden Sie sich an Ihren Studio-Administrator, um den Amazon-S3-Backup-Speicherort für den gelöschten Workspace zu ermitteln.

From the Workspaces list

Löschen Sie einen Workspace und die zugehörigen Backup-Dateien aus der Workspaces-Liste

1. Navigieren Sie in der Konsole zur Workspace-Liste.
2. Wählen Sie den Workspace, den Sie löschen möchten, aus der Liste aus und klicken Sie dann auf Aktionen.
3. Wählen Sie Delete (Löschen).
4. Wenn Sie die Notebookdateien, die mit dem gelöschten Workspace verknüpft waren, aus Amazon S3 entfernen möchten, folgen Sie den Anweisungen zum Löschen von Objekten im Konsole-Benutzerhandbuch von Amazon Simple Storage Service. Wenn Sie das Studio nicht erstellt haben, wenden Sie sich an Ihren Studio-Administrator, um den Amazon-S3-Backup-Speicherort für den gelöschten Workspace zu ermitteln.

Ein EMR Studio löschen

New console

So löschen Sie ein EMR Studio mit der neuen Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR Studio die Option Studios aus.
3. Wählen Sie das Studio aus der Studio-Liste mit dem Schalter links neben dem Studio-Namen aus. Wählen Sie Delete (Löschen).

Old console

So löschen Sie ein EMR Studio mit der alten Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home.
2. Wählen Sie in der linken Navigationsleiste EMR Studio aus.
3. Wählen Sie das Studio aus der Studio-Liste aus und klicken Sie auf Löschen.

CLI

So löschen Sie ein EMR Studio mit der AWS CLI

Verwenden Sie den Befehl `delete-studio` AWS CLI, um ein EMR-Studio zu löschen. Weitere Informationen finden Sie in der AWS CLI-Befehlsreferenz.

```
aws emr delete-studio --studio-id <id-of-studio-to-delete>
```

Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio

Informationen über die EMR-Studio-Sicherheitsgruppen

Amazon EMR Studio verwendet zwei Sicherheitsgruppen, um den Netzwerkverkehr zwischen Workspaces im Studio und einem verbundenen Amazon-EMR-Cluster, der auf Amazon EC2 läuft, zu kontrollieren:

- Eine Engine-Sicherheitsgruppe, die Port 18888 verwendet, um mit einem verbundenen Amazon-EMR-Cluster zu kommunizieren, der auf Amazon EC2 läuft.
- Eine Workspace-Sicherheitsgruppe, die den Workspaces in einem Studio zugeordnet ist. Diese Sicherheitsgruppe umfasst eine ausgehende HTTPS-Regel, die es dem Workspace ermöglicht, Datenverkehr ins Internet weiterzuleiten, und muss ausgehenden Datenverkehr ins Internet an Port 443 zulassen, um die Verknüpfung von Git-Repositorys mit einem Workspace zu ermöglichen.

EMR Studio verwendet diese Sicherheitsgruppen zusätzlich zu allen Sicherheitsgruppen, die einem an einen Workspace angeschlossenen EMR-Cluster zugeordnet sind.

Sie müssen diese Sicherheitsgruppen erstellen, wenn Sie das verwenden, um ein AWS CLI Studio zu erstellen.

> **Note**
>
> Sie können die Sicherheitsgruppen für EMR Studio mit Regeln anpassen, die auf Ihre Umgebung zugeschnitten sind. Sie müssen jedoch die auf dieser Seite aufgeführten Regeln einbeziehen. Ihre Workspace-Sicherheitsgruppe kann keinen eingehenden Datenverkehr zulassen, und die Engine-Sicherheitsgruppe muss eingehenden Datenverkehr von der Workspace-Sicherheitsgruppe zulassen.

Die standardmäßigen EMR-Studio-Sicherheitsgruppen verwenden

Wenn Sie die Amazon-EMR-Konsole verwenden, können Sie die folgenden Standardsicherheitsgruppen auswählen. Die Standardsicherheitsgruppen werden von EMR Studio in Ihrem Namen erstellt und enthalten die Mindestregeln für eingehende und ausgehende Nachrichten für Workspaces in einem EMR Studio.

- `DefaultEngineSecurityGroup`
- `DefaultWorkspaceSecurityGroupGit` oder `DefaultWorkspaceSecurityGroupWithoutGit`

Voraussetzungen

Um die Sicherheitsgruppen für EMR Studio zu erstellen, benötigen Sie eine Amazon Virtual Private Cloud (VPC) für das Studio. Sie wählen diese VPC aus, wenn Sie die Sicherheitsgruppen erstellen. Dies sollte die gleiche VPC sein, die Sie beim Erstellen des Studios angeben. Wenn Sie Amazon

EMR in EKS mit EMR Studio verwenden möchten, wählen Sie die VPC für Ihre Amazon-EKS-Cluster-Workerknoten aus.

Anweisungen

Folgen Sie den Anweisungen unter Erstellen einer Sicherheitsgruppe im Amazon-EC2-Benutzerhandbuch für Linux-Instances, um eine Engine-Sicherheitsgruppe und eine Workspace-Sicherheitsgruppe in Ihrer VPC zu erstellen. Die Sicherheitsgruppen müssen die in den folgenden Tabellen zusammengefassten Regeln enthalten.

Wenn Sie Sicherheitsgruppen für EMR Studio erstellen, notieren Sie sich die IDs für beide. Sie geben jede Sicherheitsgruppe anhand ihrer ID an, wenn Sie ein Studio erstellen.

Engine-Sicherheitsgruppe

EMR Studio verwendet Port 18888 für die Kommunikation mit einem angeschlossenen Cluster.

Regeln für eingehenden Datenverkehr

Typ	Protokoll	Port	Ziel	Beschreibung
TCP	TCP	18888	Ihre EMR Studio Workspace -Sicherhe itsgruppe.	Lassen Sie Datenverk ehr von allen Ressourcen in der Workspace-Sicherhe itsgruppe für EMR Studio zu.

WorkSpaces-Sicherheitsgruppe

Diese Sicherheitsgruppe ist den Workspaces in einem EMR Studio zugeordnet.

Regeln für ausgehenden Datenverkehr

Typ	Protokoll	Port	Ziel	Beschreibung
TCP	TCP	18888	Ihre EMR-Studio-Engine-Sicherhei tsgruppe.	Erlauben Sie Datenverkehr zu allen Ressourcen in der Engine-Sicherheits

Typ	Protokoll	Port	Ziel	Beschreibung
				gruppe für EMR Studio.
HTTPS	TCP	443	0.0.0.0/0	Erlaube Datenverkehr im Internet, um öffentlich gehostete Git-Repositorys mit Workspaces zu verknüpfen.

AWS CloudFormation-Vorlagen für Amazon EMR Studio erstellen

Informationen über die EMR-Studio-Clustervorlagen

Sie können AWS CloudFormation-Vorlagen erstellen, um EMR-Studio-Benutzern zu helfen, neue Amazon-EMR-Cluster in einem Workspace zu starten. CloudFormation-Vorlagen sind formatierte Textdateien in JSON oder YAML. In einer Vorlage beschreiben Sie einen Stapel von AWS-Ressourcen und teilen CloudFormation mit, wie diese Ressourcen für Sie bereitgestellt werden sollen. Für EMR Studio können Sie eine oder mehrere Vorlagen erstellen, die einen Amazon-EMR-Cluster beschreiben.

Sie organisieren Ihre Vorlagen in AWS Service Catalog. AWS Service Catalog ermöglicht es Ihnen, häufig bereitgestellte IT-Services, sogenannte Produkte, in AWS zu erstellen und zu verwalten. Sie sammeln Ihre Vorlagen als Produkte in einem Portfolio, das Sie mit Ihren EMR-Studio-Benutzern teilen. Nachdem Sie Cluster-Vorlagen erstellt haben, können Studio-Benutzer mit einer Ihrer Vorlagen einen neuen Cluster für einen Workspace starten. Benutzer müssen über die Berechtigung zum Erstellen neuer Cluster aus Vorlagen verfügen. Sie können Benutzerberechtigungen in Ihren EMR-Studio-Berechtigungsrichtlinien festlegen.

Weitere Informationen zu CloudFormation-Vorlagen finden Sie unter Vorlagen im AWS CloudFormation-Benutzerhandbuch. Weitere Informationen zu AWS Service Catalog finden Sie unter Was ist AWS Service Catalog?

Das folgende Video veranschaulicht, wie Sie Cluster-Vorlagen in AWS Service Catalog für EMR Studio einrichten. Weitere Informationen finden Sie auch im Blogbeitrag Aufbau einer Self-Service-Umgebung für jeden Geschäftsbereich mithilfe von Amazon EMR und Service Catalog.

Optionale Vorlageparameter

Sie können zusätzliche Optionen in den `Parameters` Abschnitt Ihrer Vorlage aufnehmen. Mit Parametern können Studio-Benutzer benutzerdefinierte Werte für einen Cluster eingeben oder auswählen. Sie könnten beispielsweise einen Parameter hinzufügen, mit dem Benutzer eine bestimmte Amazon-EMR-Version auswählen können. Weitere Informationen finden Sie unter Parameter im AWS CloudFormation-Benutzerhandbuch.

Der folgende `Parameters`-Beispielabschnitt definiert zusätzliche Eingabeparameter wie `ClusterName`, `EmrRelease`-Version und `ClusterInstanceType`.

```
Parameters:
  ClusterName:
    Type: "String"
    Default: "Cluster_Name_Placeholder"
  EmrRelease:
    Type: "String"
    Default: "emr-6.2.0"
    AllowedValues:
    - "emr-6.2.0"
    - "emr-5.32.0"
  ClusterInstanceType:
    Type: "String"
    Default: "m5.xlarge"
    AllowedValues:
    - "m5.xlarge"
    - "m5.2xlarge"
```

Wenn Sie Parameter hinzufügen, werden Studio-Benutzern nach der Auswahl einer Clustervorlage zusätzliche Formularoptionen angezeigt. Die folgende Abbildung zeigt zusätzliche Formularoptionen für EmrRelease-Version, ClusterName und InstanceType.

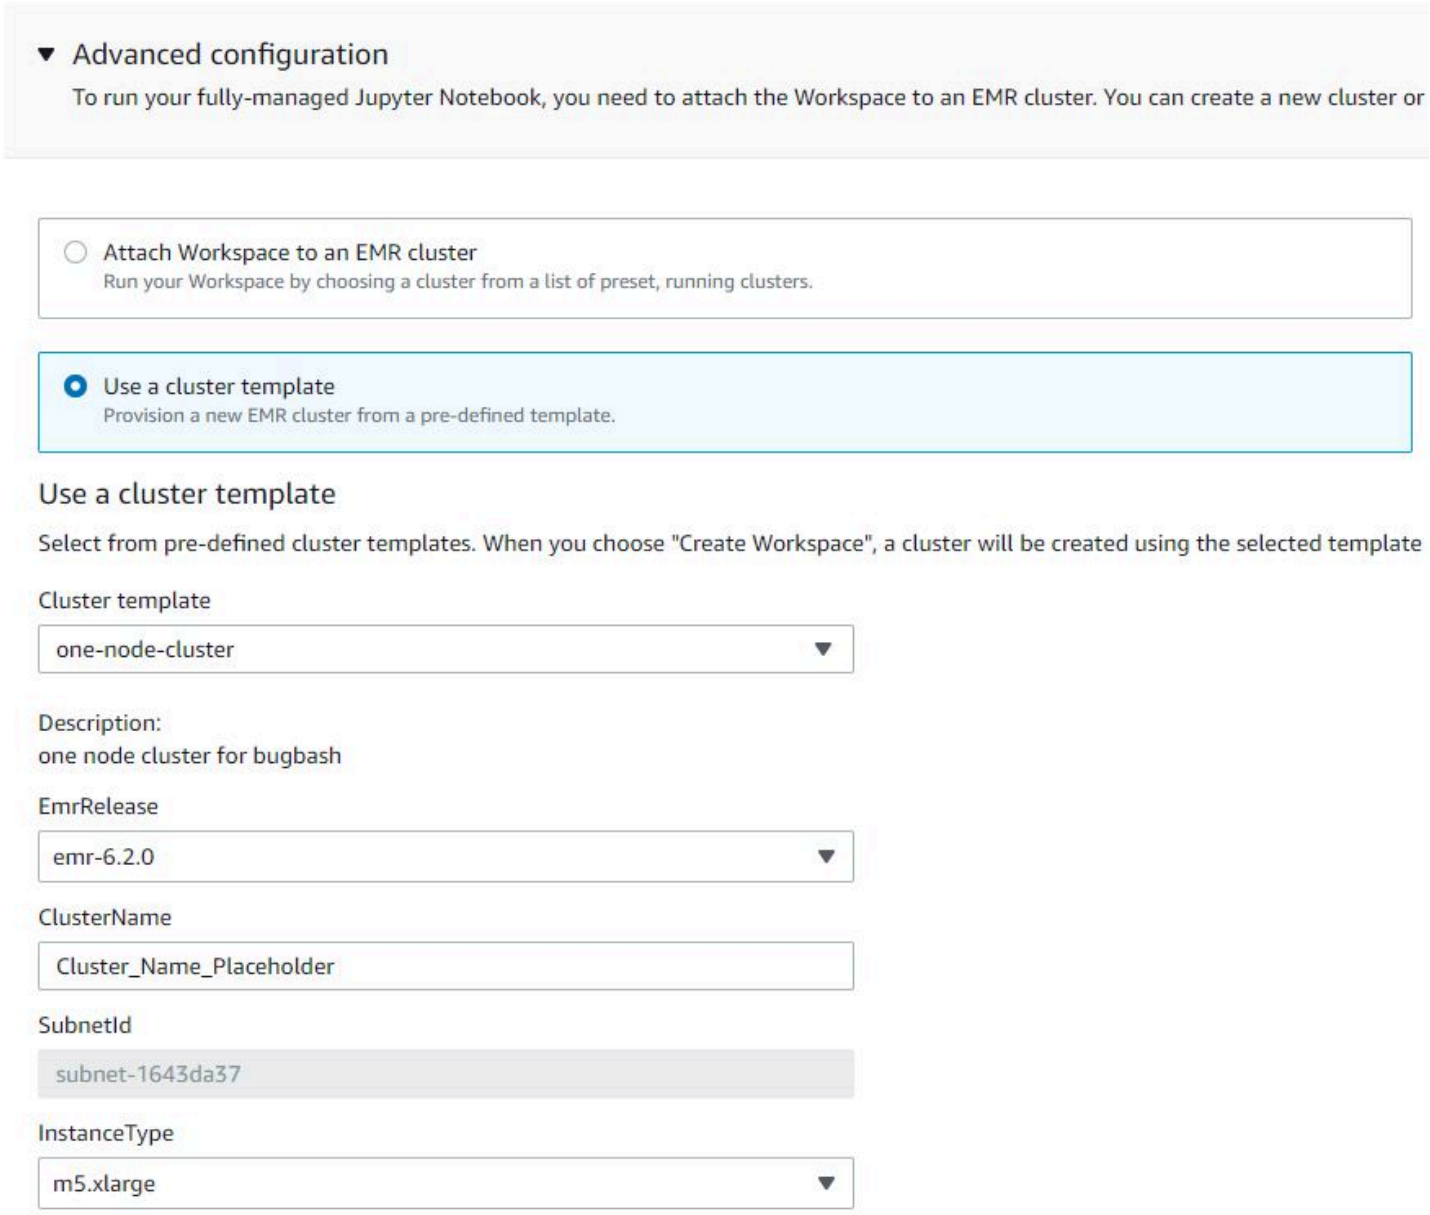

Voraussetzungen

Bevor Sie eine Clustervorlage erstellen, stellen Sie sicher, dass Sie über IAM-Berechtigungen für den Zugriff auf die Administratorkonsolenansicht von Service Catalog verfügen. Sie benötigen außerdem die erforderlichen IAM-Berechtigungen, um die administrativen Aufgaben von Service Catalog auszuführen. Weitere Informationen finden Sie unter Service-Catalog-Administratoren Berechtigungen erteilen.

Anweisungen

So erstellen Sie EMR-Clustervorlagen mithilfe von Service Catalog

1. Erstellen Sie eine oder mehrere CloudFormation-Vorlagen. Wo Sie Ihre Vorlagen speichern, liegt bei Ihnen. Da es sich bei Vorlagen um formatierte Textdateien handelt, können Sie sie auf Amazon S3 hochladen oder in Ihrem lokalen Dateisystem speichern. Weitere Informationen zu CloudFormation-Vorlagen finden Sie unter Vorlagen im AWS CloudFormation-Benutzerhandbuch.

   Verwenden Sie die folgenden Regeln, um Ihre Vorlagen zu benennen, oder vergleichen Sie Ihre Namen mit dem Muster `[a-zA-Z0-9][a-zA-Z0-9._-]*`.

   - Vorlagennamen müssen mit einer Ziffer oder einem Buchstaben beginnen.
   - Vorlagennamen dürfen nur aus Buchstaben, Ziffern, Punkten (.), Unterstrichen (_) und Bindestrichen (-) bestehen.

   Jede Cluster-Vorlage, die Sie erstellen, muss die folgenden Optionen enthalten:

   Eingabeparameter

   - ClusterName – Ein Name für den Cluster, der Benutzern hilft, ihn nach der Bereitstellung zu identifizieren.

   Ausgabe

   - `ClusterId` – Die ID des neu bereitgestellten EMR-Clusters.

   Im Folgenden finden Sie eine AWS CloudFormation-Beispielvorlage im YAML-Format für einen Cluster mit zwei Knoten. Die Beispielvorlage enthält die erforderlichen Vorlagenoptionen und definiert zusätzliche Eingabeparameter für `EmrRelease` und `ClusterInstanceType`.

```
awsTemplateFormatVersion: 2010-09-09

Parameters:
  ClusterName:
    Type: "String"
    Default: "Example_Two_Node_Cluster"
  EmrRelease:
```

```
    Type: "String"
    Default: "emr-6.2.0"
    AllowedValues:
    - "emr-6.2.0"
    - "emr-5.32.0"
  ClusterInstanceType:
    Type: "String"
    Default: "m5.xlarge"
    AllowedValues:
    - "m5.xlarge"
    - "m5.2xlarge"

Resources:
  EmrCluster:
    Type: AWS::EMR::Cluster
    Properties:
      Applications:
      - Name: Spark
      - Name: Livy
      - Name: JupyterEnterpriseGateway
      - Name: Hive
      EbsRootVolumeSize: '10'
      Name: !Ref ClusterName
      JobFlowRole: EMR_EC2_DefaultRole
      ServiceRole: EMR_DefaultRole_V2
      ReleaseLabel: !Ref EmrRelease
      VisibleToAllUsers: true
      LogUri:
        Fn::Sub: 's3://aws-logs-${AWS::AccountId}-${AWS::Region}/elasticmapreduce/'
      Instances:
        TerminationProtected: false
        Ec2SubnetId: 'subnet-ab12345c'
        MasterInstanceGroup:
          InstanceCount: 1
          InstanceType: !Ref ClusterInstanceType
        CoreInstanceGroup:
          InstanceCount: 1
          InstanceType: !Ref ClusterInstanceType
          Market: ON_DEMAND
          Name: Core

Outputs:
  ClusterId:
    Value:
```

```
      Ref: EmrCluster
    Description: The ID of the  EMR cluster
```

2. Erstellen Sie ein Portfolio für Ihre Cluster-Vorlagen in demselben AWS-Konto wie Ihr Studio.

   a. Öffnen Sie die AWS Service Catalog-Konsole unter https://console.aws.amazon.com/servicecatalog/.
   b. Wählen Sie im linken Navigationsmenü Portfolios.
   c. Geben Sie auf der Seite Portfolio erstellen die erforderlichen Informationen ein.
   d. Wählen Sie Erstellen. AWS Service Catalog erstellt das Portfolio und zeigt die Portfoliodetails an.

3. Führen Sie die folgenden Schritte aus, um Ihre Cluster-Vorlagen als AWS Service Catalog-Produkte hinzuzufügen.

   a. Navigieren Sie in der AWS Service Catalog-Managementkonsole unter Administration zur Seite Produkte.
   b. Wählen Sie Neues Produkt hochladen.
   c. Geben Sie einen Produktnamen und einen Eigentümer ein.
   d. Geben Sie Ihre Vorlagendatei unter Versionsdetails an.
   e. Wähle Überprüfen, um deine Produkteinstellungen zu überprüfen, und wähle dann Produkt erstellen.

4. Führen Sie die folgenden Schritte aus, um Ihre Produkte zu Ihrem Portfolio hinzuzufügen.

   a. Navigieren Sie in der AWS Service Catalog-Managementkonsole unter Administration zur Seite Produkte.
   b. Wählen Sie Ihr Produkt aus, klicken Sie auf Aktionen und anschließend auf Produkt zum Portfolio hinzufügen.
   c. Wählen Sie Ihr Portfolio aus und klicken Sie dann auf Produkt zum Portfolio hinzufügen.

5. Legen Sie eine Beschränkung für die Markteinführung deiner Produkte fest. Eine Startbeschränkung ist eine IAM-Rolle, die Benutzerberechtigungen für die Markteinführung eines Produkts festlegt. Sie können Ihre Startbeschränkungen anpassen, müssen jedoch Berechtigungen für die Verwendung von CloudFormation, Amazon EMR und AWS Service Catalog zulassen. Weitere Informationen und Anweisungen finden Sie unter Startbeschränkungen für den Service Catalog.

6. Wenden Sie Ihre Markteinführungsbeschränkung auf jedes Produkt in Ihrem Portfolio an. Sie müssen die Markteinführungsbeschränkung auf jedes Produkt einzeln anwenden.

a. Wählen Sie Ihr Portfolio auf der Portfolio-Seite in der AWS Service Catalog-Managementkonsole aus.

b. Wählen Sie die Registerkarte Constraints (Einschränkungen) und dann Create constraint (Einschränkung erstellen).

c. Wählen Sie Ihr Produkt aus und wählen Sie unter Einschränkungstyp die Option Starten aus. Klicken Sie auf Weiter.

d. Wählen Sie Ihre Startbeschränkungsrolle im Abschnitt Startbeschränkung aus, und wählen Sie dann Erstellen.

7. Gewähren Sie Zugriff auf Ihr Portfolio.

a. Wählen Sie Ihr Portfolio auf der Portfolio-Seite in der AWS Service Catalog-Managementkonsole aus.

b. Erweitern Sie den Tab Gruppen, Rollen und Benutzer und wählen Sie Gruppen, Rollen, Benutzer hinzufügen aus.

c. Suchen Sie auf der Registerkarte Rollen nach Ihrer EMR-Studio-IAM-Rolle, wählen Sie Ihre Rolle aus und klicken Sie auf Zugriff hinzufügen.

Wenn Sie …	Zugriff gewähren auf …
IAM-Authentifizierung	Ihre nativen Benutzer
den IAM-Verbund	Ihre IAM-Rolle für den Verbund
den IAM-Identity-Center-Verbund	Ihre EMR-Studio-Benutzerrolle

Zugriff und Berechtigungen für Git-basierte Repositorys einrichten

EMR Studio unterstützt die folgenden Git-basierten Services:

- AWS CodeCommit
- GitHub
- Bitbucket
- GitLab

Damit EMR-Studio-Benutzer ein Git-Repository mit einem Workspace verknüpfen können, richten Sie die folgenden Zugriffs- und Berechtigungsanforderungen ein. Sie können auch Git-basierte Repositorys konfigurieren, die Sie in einem privaten Netzwerk hosten, indem Sie den Anweisungen unter Ein privat gehostetes Git-Repository für EMR Studio konfigurieren folgen.

Cluster-Internetzugang

Sowohl Amazon-EMR-Cluster, die auf Amazon EC2 ausgeführt werden, als auch Amazon EMR auf EKS-Clustern, die mit Studio Workspaces verbunden sind, müssen sich in einem privaten Subnetz befinden, das ein Network Address Translation (NAT) -Gateway verwendet, oder sie müssen in der Lage sein, über ein Virtual Private Gateway auf das Internet zuzugreifen. Weitere Informationen finden Sie unter Optionen für Amazon-VPC.

Die Sicherheitsgruppen, die Sie mit EMR Studio verwenden, müssen auch eine ausgehende Regel enthalten, die es Workspaces ermöglicht, Datenverkehr von einem angeschlossenen EMR-Cluster ins Internet weiterzuleiten. Weitere Informationen finden Sie unter Definieren Sie Sicherheitsgruppen zur Steuerung des Netzwerkverkehrs in EMR Studio.

> **Important**
>
> Wenn die Netzwerkschnittstelle in einem öffentlichem Subnetz befindet, kann sie nicht über ein Internet-Gateway (IGW) mit dem Internet kommunizieren.

Berechtigungen für AWS Secrets Manager

Um EMR-Studio-Benutzern den Zugriff auf Git-Repositorys mit in AWS Secrets Manager gespeicherten Geheimnissen zu ermöglichen, fügen Sie der Servicerolle für EMR Studio eine Berechtigungsrichtlinie hinzu, die den Vorgang `secretsmanager:GetSecretValue` ermöglicht.

Informationen zum Verknüpfen von Git-basierten Repositorys mit Workspaces finden Sie unter Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen.

Ein privat gehostetes Git-Repository für EMR Studio konfigurieren

Verwenden Sie die folgenden Anweisungen, um privat gehostete Repositorys für Amazon EMR Studio zu konfigurieren. Sie müssen eine Konfigurationsdatei mit Informationen zu Ihren DNS- und Git-Servern bereitstellen. EMR Studio verwendet diese Informationen, um Workspaces zu konfigurieren, die den Datenverkehr an Ihre selbstverwalteten Repositorys weiterleiten können.

> **Note**
>
> Wenn Sie `DnsServerIpV4` konfigurieren, verwendet EMR Studio Ihren DNS-Server, um sowohl Ihren `GitServerDnsName` als auch Ihren Amazon-EMR-Endpunkt aufzulösen, z. B. `elasticmapreduce.us-east-1.amazonaws.com` Um einen Endpunkt für Amazon EMR einzurichten, stellen Sie über die VPC, die Sie mit Ihrem Studio verwenden, eine Verbindung zu Ihrem Endpunkt her. Dadurch wird sichergestellt, dass der Amazon-EMR-Endpunkt zu einer privaten IP aufgelöst wird. Weitere Informationen finden Sie unter Herstellen einer Verbindung mit Amazon EMR über einen Schnittstellen-VPC-Endpunkt.

Voraussetzungen

Bevor Sie ein privat gehostetes Git-Repository für EMR Studio konfigurieren, benötigen Sie einen Amazon-S3-Speicherort, an dem EMR Studio die Workspaces und Notebook-Dateien im Studio sichern kann. Verwenden Sie denselben S3-Bucket, den Sie beim Erstellen eines Studios angegeben haben.

Wie Sie ein oder mehrere privat gehostete Git-Repositorys für EMR Studio zu konfigurieren

1. Erstellen Sie eine Konfigurationsdatei mithilfe der folgenden Vorlage. Geben Sie für jeden Git-Server, den Sie in Ihrer Konfiguration angeben möchten, die folgenden Werte an:

   - **`DnsServerIpV4`** – Die IPv4-Adresse Ihres DNS-Servers. Wenn Sie Werte für sowohl `DnsServerIpV4` als auch für `GitServerIpV4List` angeben, hat der Wert für `DnsServerIpV4` Vorrang und EMR Studio verwendet `DnsServerIpV4`, um Ihr `GitServerDnsName` zu lösen.

     > **Note**
     >
     > Um privat gehostete Git-Repositorys verwenden zu können, muss Ihr DNS-Server eingehenden Zugriff von EMR Studio zulassen. Wir bitten Sie dringend, Ihren DNS-Server vor anderen, unbefugten Zugriffen zu schützen.

   - **`GitServerDnsName`** – Der DNS-Name Ihres Git-Servers. Zum Beispiel `"git.example.com"`.
   - **`GitServerIpV4List`** – Eine Liste von IPv4-Adressen, die zu Ihren Git-Servern gehören.

```
[
    {
        "Type": "PrivatelyHostedGitConfig",
        "Value": [
            {
                "DnsServerIpV4": "<10.24.34.xxx>",
                "GitServerDnsName": "<enterprise.git.com>",
                "GitServerIpV4List": [
                    "<xxx.xxx.xxx.xxx>",
                    "<xxx.xxx.xxx.xxx>"
                ]
            },
            {
                "DnsServerIpV4": "<10.24.34.xxx>",
                "GitServerDnsName": "<git.example.com>",
                "GitServerIpV4List": [
                    "<xxx.xxx.xxx.xxx>",
                    "<xxx.xxx.xxx.xxx>"
                ]
            }
        ]
    }
]
```

2. Speichern Sie Ihre Konfigurationsdatei unter `configuration.json`.
3. Laden Sie die Konfigurationsdatei in Ihren Amazon-S3-Speicherort in einem Ordner mit dem `life-cycle-configuration`-Namen hoch. Wenn Ihr Standard-S3-Speicherort beispielsweise `s3://`*`DOC-EXAMPLE-BUCKET`*`/studios` lautet, befindet sich Ihre Konfigurationsdatei in `s3://`*`DOC-EXAMPLE-BUCKET`*`/studios/`**`life-cycle-configuration/configuration.json`**.

> **Important**
>
> Wir bitten Sie dringend, den Zugriff auf Ihren `life-cycle-configuration`-Ordner auf Studio-Administratoren und Ihre EMR-Studio-Servicerolle zu beschränken und `configuration.json` vor unbefugtem Zugriff zu schützen. Anweisungen finden Sie unter Steuern des Zugriffs auf einen Bucket mit Benutzerrichtlinien oder Bewährte Sicherheitsmethoden für Amazon S3.

Anweisungen zum Hochladen finden Sie unter Erstellen eines Ordners und Hochladen von Objekten im Benutzerhandbuch für Amazon Simple Storage Service. Um Ihre Konfiguration auf einen vorhandenen Workspace anzuwenden, schließen Sie den Workspace und starten Sie ihn neu, nachdem Sie Ihre Konfigurationsdatei auf Amazon S3 hochgeladen haben.

Spark-Aufträge in EMR Studio optimieren

Wenn Sie einen Spark-Job mit EMR Studio ausführen, können Sie einige Schritte unternehmen, um sicherzustellen, dass Sie Ihre Amazon-EMR-Clusterressourcen optimieren.

Ihre Livy-Sitzung verlängern

Wenn Sie Apache Livy zusammen mit Spark auf Ihrem Amazon-EMR-Cluster verwenden, empfehlen wir Ihnen, Ihr Livy-Sitzungs-Timeout zu erhöhen, indem Sie einen der folgenden Schritte ausführen:

- Wenn Sie einen Amazon-EMR-Cluster erstellen, legen Sie diese Konfigurationsklassifizierung im Feld Konfiguration eingeben fest.

```
[
    {
        "Classification": "livy-conf",
        "Properties": {
          "livy.server.session.timeout": "8h"
        }
    }
]
```

- Stellen Sie für einen bereits laufenden EMR-Cluster eine Verbindung zu Ihrem Cluster mit `ssh` her und legen Sie die `livy-conf` Konfigurationsklassifizierung unter `/etc/livy/conf/livy.conf` fest.

```
[
    {
        "Classification": "livy-conf",
        "Properties": {
          "livy.server.session.timeout": "8h"
        }
    }
]
```

Möglicherweise müssen Sie Livy neu starten, nachdem Sie die Konfiguration geändert haben.

- Wenn Sie nicht möchten, dass es bei Ihrer Livy-Sitzung zu einem Timeout kommt, setzen Sie die Eigenschaft `livy.server.session.timeout-check` auf `false` in `/etc/livy/conf/livy.conf`.

Spark im Cluster-Modus ausführen

Im Clustermodus wird der Spark-Treiber auf einem Core-Knoten statt auf dem Primärknoten ausgeführt, wodurch die Ressourcennutzung auf dem Primärknoten verbessert wird.

Um Ihre Spark-Anwendung im Cluster-Modus statt im Standard-Client-Modus auszuführen, wählen Sie Cluster-Modus, wenn Sie bei der Konfiguration Ihres Spark-Schritts in Ihrem neuen Amazon-EMR-Cluster den Bereitstellungsmodus festlegen. Weitere Informationen finden Sie unter Übersicht über den Clustermodus in der Apache-Spark-Dokumentation.

Den Spark-Treiberspeicher erhöhen

Um den Speicher des Spark-Treibers zu erhöhen, konfigurieren Sie Ihre Spark-Sitzung mit dem `%%configure` magischen Befehl in Ihrem EMR-Notebook, wie im folgenden Beispiel.

```
%%configure -f
{"driverMemory": "6000M"}
```

Ein Amazon EMR Studio verwenden

Dieser Abschnitt enthält Themen, die Ihnen bei der Konfiguration und Interaktion mit einem Amazon EMR Studio helfen.

Das folgende Video enthält praktische Informationen wie das Erstellen eines neuen Workspace und das Starten eines neuen Amazon-EMR-Clusters mit einer Cluster-Vorlage. Das Video zeigt auch ein Beispiel-Notebook.

In diesem Abschnitt finden Sie die folgenden Themen, die Ihnen beim Arbeiten in EMR Studio helfen:

- Informationen über Workspace-Grundlagen
- Konfigurieren Sie die Zusammenarbeit im Workspace
- Einen EMR-Studio-Workspace mit einer Laufzeit-Rolle ausführen
- Führen Sie Workspace-Notebooks programmgesteuert aus

- Durchsuchen Sie Daten mit SQL Explorer
- Einen Computer an einen EMR Studio Workspace anhängen
- Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen
- Debuggen von Anwendungen und Aufträgen mit EMR Studio
- Kernel und Bibliotheken in einem EMR Studio Workspace installieren
- Verbessern Sie die Kernel mit Befehlen magic
- Verwenden Sie mehrsprachige Notebooks mit Spark-Kerneln

Informationen über Workspace-Grundlagen

Wenn Sie ein EMR Studio verwenden, können Sie verschiedene Workspaces erstellen und konfigurieren, um Notebooks zu organisieren und auszuführen. In diesem Abschnitt wird das Erstellen von und das Arbeiten mit Workspaces behandelt. Eine konzeptionelle Übersicht über die Workspaces finden Sie unter Wie Amazon EMR Studio funktioniert.

In diesem Abschnitt finden Sie die folgenden Themen, die Ihnen beim Verwenden von EMR Studio Workspaces helfen:

- Einen EMR Studio Workspace erstellen
- Einen WorkSpace starten
- Machen Sie sich mit der Workspace-Benutzeroberfläche vertraut
- Erkunden Sie Notebookbeispiele
- Workspace-Inhalt speichern
- Löschen Sie einen Workspace und Notebookdateien
- Informationen über Workspace-Status
- Beheben von Workspace-Verbindungsproblemen

Einen EMR Studio Workspace erstellen

Sie können EMR Studio Workspaces erstellen, um Notebookcode mithilfe der-EMR Studio-Oberfläche auszuführen.

So erstellen Sie einen Workspace in einem EMR Studio

1. Melden Sie sich bei EMR Studio an.

2. Wählen Sie Workspace erstellen.
3. Geben Sie Workspace-Name und Beschreibung ein. Wenn Sie einen Workspace benennen, können Sie ihn auf der Seite Workspaces leichter identifizieren.
4. Wenn Sie in Echtzeit mit anderen Studio-Benutzern in diesem Workspace zusammenarbeiten möchten, aktivieren Sie die Workspace-Zusammenarbeit. Sie können Mitarbeiter konfigurieren, nachdem Sie den Workspace gestartet haben.
5. Wenn Sie einen Cluster an einen Workspace anhängen möchten, erweitern Sie den Abschnitt Erweiterte Konfiguration. Wenn Sie möchten, können Sie später einen Cluster anhängen. Weitere Informationen finden Sie unter Einen Computer an einen EMR Studio Workspace anhängen.

   > **Note**
   >
   > Um einen neuen Cluster bereitzustellen, benötigen Sie Zugriffsberechtigungen von Ihrem Administrator.

   Wählen Sie eine der Clusteroptionen für den Workspace und hängen Sie den Cluster an. Weitere Informationen zum Bereitstellen eines Clusters beim Erstellen eines Workspace finden Sie unter Einen neuen EMR-Cluster erstellen und an einen EMR Studio Workspace anhängen.
6. Wählen Sie unten rechts auf der Seite die Option Workspace erstellen aus.

Nachdem Sie einen Workspace erstellt haben, öffnet EMR Studio die Workspaces-Seite. Oben auf der Seite wird ein grünes Erfolgsbanner angezeigt und Sie können den neu erstellten Workspace in der Liste finden.

Standardmäßig wird ein Workspace geteilt und kann von allen Studio-Benutzern gesehen werden. Es kann jedoch jeweils nur ein Benutzer einen Workspace öffnen und darin arbeiten. Um gleichzeitig mit anderen Benutzern zu arbeiten, können Sie Konfigurieren Sie die Zusammenarbeit im Workspace

Einen WorkSpace starten

Um mit der Arbeit mit Notebookdateien zu beginnen, starten Sie einen Workspace, um auf den Notebook-Editor zuzugreifen. Auf der Seite Workspaces in einem Studio werden alle Workspaces aufgeführt, auf die Sie Zugriff haben, mit Details wie Name, Status, Erstellungszeit und Letzte Änderung.

> **Note**
>
> Wenn Sie EMR-Notebooks in der alten Amazon-EMR-Konsole hatten, finden Sie diese in der neuen Konsole als EMR Studio Workspaces. EMR Notebooks-Benutzer benötigen zusätzliche IAM-Rollenberechtigungen, um auf Workspaces zuzugreifen oder diese zu erstellen. Wenn Sie kürzlich ein Notebook in der alten Konsole erstellt haben, müssen Sie möglicherweise die Workspaces-Liste aktualisieren, damit es in der neuen Konsole angezeigt wird. Weitere Informationen zum Übergang finden Sie unter Amazon EMR Notebooks sind in der neuen Konsole als Amazon EMR Studio Workspaces verfügbar und Was ist neu an der Konsole?

So starten Sie einen Workspace zum Bearbeiten und Ausführen von Notebooks

1. Suchen Sie auf der Workspaces-Seite Ihres Studios nach dem Workspace. Sie können die Liste nach Schlüsselwort oder Spaltenwert filtern.
2. Wählen Sie den Workspace-Namen, um den Workspace in einer neuen Browser-Registerkarte zu starten. Es kann einige Minuten dauern, bis der Workspace geöffnet wird, wenn er inaktiv ist. Wählen Sie alternativ die Zeile für den Workspace aus und wählen Sie dann Workspace starten aus. Sie können aus den folgenden Startoptionen auswählen:

   - Schnellstart – Starten Sie Ihren Workspace schnell mit den Standardoptionen. Wählen Sie Schnellstart, wenn Sie Cluster an den Workspace in JupyterLab anhängen möchten.
   - Mit Optionen starten – Starten Sie Ihren Workspace mit benutzerdefinierten Optionen. Sie können wählen, ob Sie entweder in Jupyter oder JupyterLab starten, Ihren Workspace mit einem EMR-Cluster verbinden und Ihre Sicherheitsgruppen auswählen möchten.

   > **Note**
   >
   > Es kann jeweils nur ein Benutzer einen Workspace öffnen und darin arbeiten. Wenn Sie einen Workspace auswählen, der bereits verwendet wird, zeigt EMR Studio eine Benachrichtigung an, wenn Sie versuchen, ihn zu öffnen. In der Spalte Benutzer auf der Workspaces-Seite wird der Benutzer angezeigt, der im Workspace arbeitet.

Machen Sie sich mit der Workspace-Benutzeroberfläche vertraut

Die Benutzeroberfläche von EMR Studio Workspace basiert auf der JupyterLab-Oberfläche mit Symbolen bezeichneten Registerkarten in der linken Seitenleiste. Wenn Sie den Mauszeiger über einem Symbol halten, wird ein Tooltip mit dem Namen der Registerkarte angezeigt. Wählen Sie in der linken Seitenleiste Registerkarten aus, um auf die folgenden Bereiche zuzugreifen.

- Dateibrowser – Zeigt die Dateien und Verzeichnisse im Workspace sowie die Dateien und Verzeichnisse der verknüpften Git-Repositorys an.
- Ausführen von Kernels und Terminals – Listet alle Kernel und Terminals auf, die im Workspace laufen. Weitere Informationen finden Sie im Abschnitt Kernel und Terminals verwalten in der offiziellen JupyterLab-Dokumentation.
- Git – Stellt eine grafische Benutzeroberfläche für die Ausführung von Befehlen in den Git-Repositorys bereit, die an den Workspace angehängt sind. Dieses Panel ist eine JupyterLab-Erweiterung namens jupyterlab-git. Weitere Informationen finden Sie unter jupyterlab-git.
- EMR-Cluster – Ermöglicht das Anhängen eines Clusters an den Workspace oder das Trennen eines Clusters vom Workspace, um Notebookcode auszuführen. Das EMR-Cluster-Konfigurationsfenster bietet auch erweiterte Konfigurationsoptionen, mit denen Sie einen neuen Cluster erstellen und an den Workspace anhängen können. Weitere Informationen finden Sie unter Einen neuen EMR-Cluster erstellen und an einen EMR Studio Workspace anhängen.
- Amazon EMR Git Repository – Hilft Ihnen, den Workspace mit bis zu drei Git-Repositorys zu verknüpfen. Weitere Informationen und Anweisungen finden Sie in Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen.
- Notebook-Beispiele – Enthält eine Liste mit Notebookbeispielen, die Sie im Workspace speichern können. Sie können auf die Beispiele auch zugreifen, indem Sie auf der Launcher-Seite des Workspace die Option Notebook-Beispiele auswählen.
- Befehle – Bietet eine tastaturgesteuerte Möglichkeit, nach JupyterLab-Befehlen zu suchen und diese auszuführen. Weitere Informationen finden Sie auf der Seite zur Befehlspalette in der JupyterLab-Dokumentation.
- Notebook-Tools – Ermöglicht die Auswahl und Einstellung von Optionen wie Zellfolientyp und Metadaten. Die Option Notebook-Tools wird in der linken Seitenleiste angezeigt, nachdem Sie eine Notebookdatei geöffnet haben.
- Registerkarten öffnen – Listet die geöffneten Dokumente und Aktivitäten im Haupt-Workspace auf, sodass Sie zu einer geöffneten Registerkarte springen können. Weitere Informationen finden Sie auf der Seite Registerkarten und Einzeldokumentmodus in der JupyterLab-Dokumentation.

- Zusammenarbeit – Ermöglicht es Ihnen, die Zusammenarbeit im Workspace zu aktivieren oder zu deaktivieren und Mitarbeiter zu verwalten. Sie benötigen die nötigen Berechtigungen, um das Panel Zusammenarbeit anzeigen zu können. Weitere Informationen finden Sie unter Legen Sie die Eigentümerschaft für die Workspace-Zusammenarbeit fest.

Erkunden Sie Notebookbeispiele

Jeder EMR Studio Workspace enthält eine Reihe von Notebookbeispielen, mit denen Sie die Features von EMR Studio erkunden können. Um ein Notebook-Beispiel zu bearbeiten oder auszuführen, können Sie es im Workspace speichern.

Um ein Notebookbeispiel in einem Workspace zu speichern

1. Wählen Sie in der linken Seitenleiste den Tab Notebook-Beispiele, um den Bereich Notebook-Beispiele zu öffnen. Sie können auf die Beispiele auch zugreifen, indem Sie auf der Launcher-Seite des Workspace die Option Notebook-Beispiele auswählen.
2. Wählen Sie ein Notebookbeispiel aus, um es im Hauptarbeitsbereich als Vorschau anzuzeigen. Das Beispiel ist schreibgeschützt.
3. Um das Notebookbeispiel im Workspace zu speichern, wählen Sie In Workspace speichern. EMR Studio speichert das Beispiel in Ihrem Stammverzeichnis. Nachdem Sie ein Notebook-Beispiel im Workspace gespeichert haben, können Sie es umbenennen, bearbeiten und ausführen.

Weitere Informationen zu den Beispielnotebooks finden Sie im EMR Studio Notebook GitHub-Repository für Beispiele.

Workspace-Inhalt speichern

Wenn Sie im Notebook-Editor eines Workspace arbeiten, speichert EMR Studio den Inhalt der Notebookzellen und gibt ihn für Sie an dem Amazon-S3-Speicherort aus, der mit dem Studio verknüpft ist. Bei diesem Backup-Vorgang bleibt die Arbeit zwischen den Sitzungen erhalten.

Sie können ein Notebook auch speichern, indem Sie auf der Registerkarte Notebook öffnen STRG+S drücken oder eine der Speicheroptionen unter Datei verwenden.

Eine weitere Möglichkeit, die Notebookdateien in einem Workspace zu sichern, besteht darin, den Workspace mit einem Git-basierten Repository zu verknüpfen und Ihre Änderungen mit dem Remote-Repository zu synchronisieren. Auf diese Weise können Sie auch Notizbücher

speichern und mit Teammitgliedern teilen, die einen anderen Workspace oder Studio verwenden. Detaillierte Anweisungen finden Sie unter Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen.

Löschen Sie einen Workspace und Notebookdateien

Wenn Sie eine Notebookdatei aus einem EMR Studio-Arbeitsbereich löschen, löschen Sie die Datei aus dem Dateibrowser, und EMR Studio entfernt ihre Sicherungskopie in Amazon S3. Sie müssen keine weiteren Schritte unternehmen, um Speichergebühren zu vermeiden, wenn Sie eine Datei aus einem Workspace löschen.

Wenn Sie einen gesamten Workspace löschen, verbleiben die zugehörigen Notebookdateien und -ordner am Amazon-S3-Speicherort. Für die Dateien fallen weiterhin Speichergebühren an. Um Speichergebühren zu vermeiden, entfernen Sie alle gesicherten Dateien und Ordner, die mit Ihrem gelöschten Workspace verknüpft sind, aus Amazon S3.

So löschen Sie eine Notebook-Datei aus einem EMR Studio Workspace

1. Wählen Sie in der linken Seitenleiste des Workspace den Bereich Dateibrowser aus.
2. Wählen Sie die Datei oder den Ordner aus, die Sie löschen möchten. Klicken Sie mit der rechten Maustaste auf die ausgewählten Dateien oder Ordner und wählen Sie Löschen. Die Datei verschwindet aus der Liste. EMR Studio entfernt die Datei oder den Ordner für Sie aus Amazon S3.

From the Workspace UI

Löschen Sie einen Workspace und die zugehörigen Backup-Dateien aus EMR Studio

1. Melden Sie sich mit Ihrer Studio-Zugriffs-URL bei Ihrem EMR Studio an und wählen Sie in der linken Navigationsleiste Workspaces aus.
2. Suchen Sie in der Liste nach Ihrem Workspace und aktivieren Sie das Kontrollkästchen neben dessen Namen. Sie können mehrere Arbeitsbereiche zum gleichzeitigen Löschen auswählen.
3. Wählen Sie oben rechts in der Liste der Arbeitsbereiche die Option Löschen aus und bestätigen Sie, dass Sie die ausgewählten Arbeitsbereiche löschen möchten. Wählen Sie zur Bestätigung Delete.
4. Wenn Sie die Notebookdateien, die mit dem gelöschten Workspace verknüpft waren, aus Amazon S3 entfernen möchten, folgen Sie den Anweisungen zum Löschen von Objekten im

Konsole-Benutzerhandbuch von Amazon Simple Storage Service. Wenn Sie das Studio nicht erstellt haben, wenden Sie sich an Ihren Studio-Administrator, um den Amazon-S3-Backup-Speicherort für den gelöschten Workspace zu ermitteln.

From the Workspaces list

Löschen Sie einen Workspace und die zugehörigen Backup-Dateien aus der Workspaces-Liste

1. Navigieren Sie in der Konsole zur Workspace-Liste.
2. Wählen Sie den Workspace, den Sie löschen möchten, aus der Liste aus und klicken Sie dann auf Aktionen.
3. Wählen Sie Delete (Löschen).
4. Wenn Sie die Notebookdateien, die mit dem gelöschten Workspace verknüpft waren, aus Amazon S3 entfernen möchten, folgen Sie den Anweisungen zum Löschen von Objekten im Konsole-Benutzerhandbuch von Amazon Simple Storage Service. Wenn Sie das Studio nicht erstellt haben, wenden Sie sich an Ihren Studio-Administrator, um den Amazon-S3-Backup-Speicherort für den gelöschten Workspace zu ermitteln.

Informationen über Workspace-Status

Nachdem Sie einen EMR-Studio-Workspace erstellt haben, wird er als Zeile in der Workspaces-Liste in Ihrem Studio mit seinem Namen, Status, Erstellungszeit und dem Zeitstempel der letzten Änderung angezeigt. Die folgende Tabelle beschreibt den Workspace-Status.

Status	Description
Wird gestartet	Der Workspace wird vorbereitet, ist aber noch nicht einsatzbereit. Sie können einen Workspace nicht öffnen, wenn er den Status „Wird gestartet“ hat.
Bereit	Sie können den Workspace öffnen, um den Notebook-Editor zu verwenden, aber Sie müssen den Workspace an einen EMR-Cluster anhängen, bevor Sie Notebookcode ausführen können.

Status	Description
Anfügen	Der Workspace wird an einen Cluster angehängt.
Attached (Angefügt)	Der Workspace ist an einen EMR-Clust er angeschlossen und bereit, damit Sie Notebookcode schreiben und ausführen können. Wenn der Status eines Workspaces nicht Angefügt lautet, müssen Sie ihn an einen Cluster anhängen, bevor Sie Notebook-Code ausführen können.
Inaktiv	Der Workspace wurde gestoppt. Um einen inaktiven Workspace zu reaktivieren, wählen Sie ihn aus der Liste Workspaces aus. Wenn Sie den Workspace auswählen, ändert sich der Status von Inaktiv zu Beginnt zu Bereit.
Wird angehalten	Der Workspace wird heruntergefahren und auf Inaktiv gesetzt. Wenn Sie einen Workspace beenden, beendet er alle entsprech enden Notebook-Kernel. EMR Studio stoppt Notebooks, die lange Zeit inaktiv waren.
Wird gelöscht	Wenn Sie einen Workspace löschen, markiert EMR Studio ihn zum Löschen und startet den Löschvorgang. Nach Abschluss des Löschvorg angs verschwindet der Workspace aus der Liste. Wenn Sie einen Workspace löschen, verbleiben seine Notebookdateien im Amazon-S3-Speicherort.

Beheben von Workspace-Verbindungsproblemen

Um Probleme mit der Workspace-Konnektivität zu lösen, können Sie einen Workspace beenden und neu starten. Wenn Sie einen Workspace neu starten, startet EMR Studio den Workspace in einer anderen Availability Zone oder einem anderen Subnetz, das mit Ihrem Studio verknüpft ist.

So beenden Sie einen EMR Studio Workspace und starten ihn neu

1. Schließen Sie den Workspace in Ihrem Browser.
2. Navigieren Sie in der Konsole zur Workspace-Liste.
3. Wählen Sie Ihren Workspace aus der Liste aus und klicken Sie auf Aktionen.
4. Wählen Sie Stopp und warten Sie, bis sich der Workspace-Status von Stopp auf Inaktiv ändert.
5. Wählen Sie erneut Aktionen und dann Start, um den Workspace neu zu starten.
6. Warten Sie, bis sich der Workspace-Status von Beginnt auf Bereit ändert, und wählen Sie dann den Workspace-Namen, um ihn in einer neuen Browser-Registerkarte erneut zu öffnen.

Konfigurieren Sie die Zusammenarbeit im Workspace

Mit Workspace-Zusammenarbeit können Sie Notebook-Code gleichzeitig mit anderen Mitgliedern Ihres Teams schreiben und ausführen. Wenn Sie an derselben Notebookdatei arbeiten, sehen Sie die Änderungen, die Ihre Mitarbeiter vornehmen. Sie können die Zusammenarbeit aktivieren, wenn Sie einen Workspace erstellen, oder die Zusammenarbeit in einem vorhandenen Workspace ein- und ausschalten.

> **Note**
>
> Die Zusammenarbeit mit EMR Studio Workspace wird mit interaktiven EMR-Serverless-Anwendungen nicht unterstützt.

Voraussetzungen

Bevor Sie die Zusammenarbeit für einen Workspace konfigurieren, stellen Sie sicher, dass Sie die folgenden Aufgaben abgeschlossen haben:

- Stellen Sie sicher, dass Ihr EMR-Studio-Administrator Ihnen die erforderlichen Berechtigungen erteilt hat. Die folgende Beispielanweisung ermöglicht es einem Benutzer, die Zusammenarbeit

für jeden Workspace mit dem Tag-Schlüssel `creatorUserId` zu konfigurieren, dessen Wert der Benutzer-ID entspricht (angegeben durch die Richtlinienvariable `aws:userId`).

```
{
    "Sid": "UserRolePermissionsForCollaboration",
    "Action": [
        "elasticmapreduce:UpdateEditor",
        "elasticmapreduce:PutWorkspaceAccess",
        "elasticmapreduce:DeleteWorkspaceAccess",
        "elasticmapreduce:ListWorkspaceAccessIdentities"
    ],
    "Resource": "*",
    "Effect": "Allow",
    "Condition": {
        "StringEquals": {
            "elasticmapreduce:ResourceTag/creatorUserId": "${aws:userid}"
        }
    }
}
```

- Stellen Sie sicher, dass die mit Ihrem EMR Studio verknüpfte Servicerolle über die erforderlichen Berechtigungen verfügt, um die Workspace-Zusammenarbeit zu aktivieren und zu konfigurieren, wie in der folgenden Beispielanweisung dargestellt.

```
{
    "Sid": "AllowWorkspaceCollaboration",
    "Effect": "Allow",
    "Action": [
        "iam:GetUser",
        "iam:GetRole",
        "iam:ListUsers",
        "iam:ListRoles",
        "sso:GetManagedApplicationInstance",
        "sso-directory:SearchUsers"
    ],
    "Resource": "*"
}
```

Weitere Informationen finden Sie unter Eine EMR-Studio-Servicerolle erstellen.

Um die Workspace-Zusammenarbeit zu aktivieren und Mitarbeiter hinzuzufügen

1. Wähle in deinem Workspace im Launcher-Bildschirm oder unten im linken Bereich das Zusammenarbeit-Symbol aus.

   > **Note**
   >
   > Das Panel Zusammenarbeit wird Ihnen nur angezeigt, wenn Ihr Studio-Administrator Ihnen die Erlaubnis erteilt hat, die Zusammenarbeit für den Workspace zu konfigurieren. Weitere Informationen finden Sie unter Legen Sie die Eigentümerschaft für die Workspace-Zusammenarbeit fest.

2. Vergewissern Sie sich, dass der Schalter Workspace-Zusammenarbeit zulassen aktiviert ist. Wenn Sie die Zusammenarbeit aktivieren, können nur Sie und die von Ihnen hinzugefügten Mitarbeiter den Workspace in der Liste auf der Studio-Workspaces-Seite sehen.
3. Geben Sie einen Namen für den Mitarbeiter ein. In Ihrem Workspace können maximal fünf Mitarbeiter enthalten sein, einschließlich Ihnen. Ein Mitarbeiter kann jeder Benutzer sein, der Zugriff auf Ihr EMR Studio hat. Wenn Sie keinen Mitarbeiter angeben, ist der Workspace ein privater Workspace, auf den nur Sie zugreifen können.

   In der folgenden Tabelle sind die zutreffenden Werte für Mitarbeiter angegeben, die je nach Identitätstyp des Inhabers eingegeben werden müssen.

   > **Note**
   >
   > Ein Inhaber kann nur Mitarbeiter mit demselben Identitätstyp einladen. Beispielsweise kann ein Benutzer nur andere Benutzer hinzufügen, und ein IAM-Identity-Center-Benutzer kann nur andere IAM-Identity-Center-Benutzer hinzufügen.

Authentifizierungsmodus	Wert, der für den Namen des Mitarbeiters eingegeben werden soll
IAM-Authentifizierung	Ein Benutzername. Dies ist der Name, den ein Benutzer sieht, wenn er bei der AWS Management Console angemeldet ist.

Authentifizierungsmodus	Wert, der für den Namen des Mitarbeiters eingegeben werden soll
den IAM-Verbund	Der Name einer IAM-Rolle und ein optionaler Sitzungsname. Um alle Verbundbenutzer hinzuzufügen, die dieselbe IAM-Rolle annehmen, geben Sie den Namen einer IAM-Rolle für den Verbund an. Um einen einzelnen Benutzer als Mitarbeiter hinzuzufügen, geben Sie eine Rolle und einen Sitzungsnamen an. Zum Beispiel `MyRoleName:MySessionName` .
SSO	Ein IAM-Identity-Center-Benutzername wie `user@example.com`.

4. Wählen Sie Add (Hinzufügen) aus. Der Mitarbeiter kann den Workspace jetzt auf seiner EMR-Studio-Workspaces-Seite sehen und den Workspace starten, um ihn in Echtzeit mit Ihnen zu verwenden.

> **Note**
>
> Wenn Sie die Workspace-Zusammenarbeit deaktivieren, kehrt der Workspace in seinen gemeinsamen Status zurück und kann von allen Studio-Benutzern eingesehen werden. Im geteilten Status kann jeweils nur ein Studio-Benutzer den Workspace öffnen und darin arbeiten.

Einen EMR-Studio-Workspace mit einer Laufzeit-Rolle ausführen

> **Note**
>
> Die auf dieser Seite beschriebene Laufzeit-Rollenfunktionalität gilt nur für Amazon EMR, das auf Amazon EC2 ausgeführt wird, und bezieht sich nicht auf die Laufzeit-Rollenfunktionalität in interaktiven EMR-Serverless-Anwendungen. Weitere Informationen zur Verwendung

von Laufzeit-Rollen in EMR Serverless finden Sie unter Auftrags-Laufzeit-Rollen im Benutzerhandbuch zu Amazon EMR Serverless.

Eine Laufzeit-Rolle ist eine AWS Identity and Access Management (IAM)-Rolle, die Sie angeben können, wenn Sie einen Job oder eine Abfrage an einen Amazon-EMR-Cluster senden. Der Auftrag oder die Abfrage, die Sie an Ihren EMR-Cluster senden, verwendet die Laufzeit-Rolle, um auf AWS-Ressourcen wie Objekte in Amazon S3 zuzugreifen.

Wenn Sie einen EMR-Studio-Workspace an einen EMR-Cluster anhängen, der Amazon EMR 6.11 oder höher verwendet, können Sie eine Laufzeit-Rolle für den Auftrag oder die Abfrage auswählen, die Sie einreichen, um sie beim Zugriff auf AWS-Ressourcen zu verwenden. Wenn der EMR-Cluster jedoch keine Laufzeit-Rollen unterstützt, übernimmt der EMR-Cluster die Rolle nicht, wenn er auf AWS-Ressourcen zugreift.

Bevor Sie eine Laufzeit-Rolle mit einem Amazon-EMR-Studio-Workspace verwenden können, muss ein Administrator Benutzerberechtigungen konfigurieren, sodass der Studio-Benutzer die `elasticmapreduce:GetClusterSessionCredentials`-API für die Laufzeit-Rolle aufrufen kann. Starten Sie dann einen neuen Cluster mit einer Laufzeit-Rolle, die Sie mit Ihrem Amazon EMR Studio Workspace verwenden können.

Auf dieser Seite

- Konfigurieren Sie Benutzerberechtigungen für die Laufzeit-Rolle
- Starten Sie einen neuen Cluster mit einer Laufzeit-Rolle
- Verwenden Sie den EMR-Cluster mit einer Laufzeit-Rolle in Workspaces
- Überlegungen

Konfigurieren Sie Benutzerberechtigungen für die Laufzeit-Rolle

Konfigurieren Sie Benutzerberechtigungen, sodass der Studio-Benutzer die `elasticmapreduce:GetClusterSessionCredentials`-API für die Laufzeit-Rolle aufrufen kann, die der Benutzer verwenden möchte. Sie müssen auch the section called “Studio-Benutzerberechtigungen (EC2, EKS)” konfigurieren, bevor der Benutzer Studio verwenden kann.

> **Warning**
>
> Um diese Berechtigung zu erteilen, erstellen Sie eine auf dem `elasticmapreduce:ExecutionRoleArn` Kontextschlüssel basierende Bedingung, wenn Sie einem Aufrufer Zugriff auf den Aufruf der `GetClusterSessionCredentials`-APIs gewähren. Das folgende Beispiel veranschaulicht die Vorgehensweise hierfür.

```
{
      "Sid": "AllowSpecificExecRoleArn",
      "Effect": "Allow",
      "Action": [
          "elasticmapreduce:GetClusterSessionCredentials"
      ],
      "Resource": "*",
      "Condition": {
          "StringEquals": {
              "elasticmapreduce:ExecutionRoleArn": [
                  "arn:aws:iam::111122223333:role/test-emr-demo1",
                  "arn:aws:iam::111122223333:role/test-emr-demo2"
              ]
          }
      }
  }
```

Das folgende Beispiel zeigt, wie einem IAM-Prinzipal die Verwendung einer IAM-Rolle mit dem Namen `test-emr-demo3`-Laufzeit-Rolle ermöglicht wird. Darüber hinaus kann der Versicherungsnehmer nur mit der Cluster-ID `j-123456789` auf Amazon-EMR-Cluster zugreifen.

```
{
    "Sid":"AllowSpecificExecRoleArn",
    "Effect":"Allow",
    "Action":[
        "elasticmapreduce:GetClusterSessionCredentials"
    ],
    "Resource": [
          "arn:aws:elasticmapreduce:<region>:111122223333:cluster/j-123456789"
     ],
    "Condition":{
        "StringEquals":{
            "elasticmapreduce:ExecutionRoleArn":[
```

```
                "arn:aws:iam::111122223333:role/test-emr-demo3"
            ]
        }
    }
}
```

Im folgenden Beispiel kann ein IAM-Prinzipal jede IAM-Rolle, deren Name mit der Zeichenfolge `test-emr-demo4` beginnt, als Laufzeitrolle verwenden. Darüber hinaus kann der Versicherungsnehmer nur auf Amazon-EMR-Cluster zugreifen, die mit dem Schlüssel-Wert-Paar `tagKey: tagValue` gekennzeichnet sind.

```
{
    "Sid":"AllowSpecificExecRoleArn",
    "Effect":"Allow",
    "Action":[
        "elasticmapreduce:GetClusterSessionCredentials"
    ],
    "Resource": "*",
    "Condition":{
        "StringEquals":{
             "elasticmapreduce:ResourceTag/tagKey": "tagValue"
        },
        "StringLike":{
            "elasticmapreduce:ExecutionRoleArn":[
                "arn:aws:iam::111122223333:role/test-emr-demo4*"
            ]
        }
    }
}
```

Starten Sie einen neuen Cluster mit einer Laufzeit-Rolle

Nachdem Sie über die erforderlichen Berechtigungen verfügen, starten Sie einen neuen Cluster mit einer Laufzeit-Rolle, die Sie mit Ihrem Amazon EMR Studio Workspace verwenden können.

Wenn Sie bereits einen neuen Cluster mit einer Laufzeit-Rolle gestartet haben, können Sie mit dem Abschnitt the section called “Verwenden Sie den Cluster mit Ihrem Workspace” fortfahren.

1. Erfüllen Sie zunächst die Voraussetzungen im Abschnitt Schritte für Laufzeit-Rollen für Amazon EMR.

2. Starten Sie dann einen Cluster mit den folgenden Einstellungen, um Laufzeit-Rollen mit Amazon EMR Studio Workspaces zu verwenden. Anweisungen zum Start Ihres Clusters finden Sie unter Angabe einer Sicherheitskonfiguration für einen Cluster.

   - Wählen Sie für Release die Option emr-6.11.0 oder höher aus.
   - Wählen Sie Spark, Livy und Jupyter Enterprise Gateway als Ihre Cluster-Anwendungen aus.
   - Verwenden Sie die Sicherheitskonfiguration, die Sie im vorherigen Schritt erstellt haben.
   - Optional können Sie Lake Formation für Ihren EMR-Cluster aktivieren. Weitere Informationen finden Sie unter Wie Amazon EMR mit Lake Formation funktioniert.

Nachdem Sie Ihren Cluster gestartet haben, können Sie den rollenfähigen Laufzeit-Cluster mit einem EMR Studio Workspace verwenden.

> **Note**
>
> Der ExecutionRoleArn-Wert wird derzeit vom API-Vorgang StartNotebookExecution nicht unterstützt, obwohl der Wert `ExecutionEngineConfig.Type` `EMR` ist.

Verwenden Sie den EMR-Cluster mit einer Laufzeit-Rolle in Workspaces

Sobald Sie Ihren Cluster eingerichtet und gestartet haben, können Sie den rollenfähigen Laufzeit-Cluster mit Ihrem EMR Studio Workspace verwenden.

1. Erstellen Sie einen neuen Workspace oder starten Sie einen vorhandenen Workspace. Weitere Informationen finden Sie unter Einen EMR Studio Workspace erstellen.
2. Wählen Sie in der linken Seitenleiste Ihres geöffneten Workspace die Registerkarte EMR-Cluster, erweitern Sie den Abschnitt Compute-Typ und wählen Sie Ihren Cluster aus dem Menü EMR-Cluster in EC2 und die Laufzeit-Rolle aus dem Laufzeit-Rollenmenü aus.

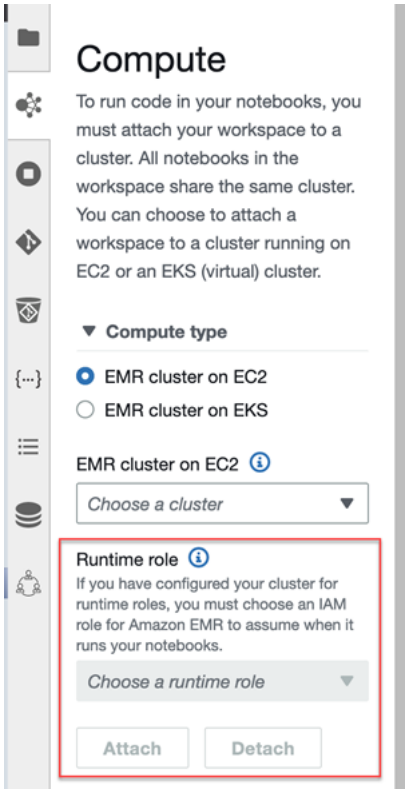

3. Wählen Sie Anhängen, um den Cluster mit der Laufzeit-Rolle an Ihren Workspace anzuhängen.

Überlegungen

Beachten Sie die folgenden Überlegungen, wenn Sie einen rollenfähigen Laufzeit-Cluster mit Ihrem Amazon EMR Studio Workspace verwenden:

- Sie können eine Laufzeit-Rolle nur auswählen, wenn Sie einen EMR Studio Workspace an einen EMR-Cluster anhängen, der Amazon-EMR-Version 6.11 oder höher verwendet.
- Die auf dieser Seite beschriebene Laufzeit-Rollenfunktionalität wird nur unterstützt, wenn Amazon EMR auf Amazon EC2 ausgeführt wird, und sie wird nicht von Serverless-interaktiven EMR-Anwendungen unterstützt. Weitere Informationen zu Laufzeit-Rollen für EMR Serverless finden Sie unter Auftrags-Laufzeit-Rollen im Benutzerhandbuch zu Amazon EMR Serverless.
- Sie müssen zwar zusätzliche Berechtigungen konfigurieren, bevor Sie eine Laufzeit-Rolle angeben können, wenn Sie einen Job an einen Cluster senden, aber Sie benötigen keine zusätzlichen Berechtigungen, um auf die von einem EMR Studio Workspace generierten Dateien zuzugreifen. Die Berechtigungen für solche Dateien sind dieselben wie für Dateien, die aus Clustern ohne Laufzeit-Rollen generiert wurden.

- Sie können SQL Explorer nicht in einem EMR Studio Workspace mit einem Cluster verwenden, der über eine Laufzeit-Rolle verfügt. Amazon EMR deaktiviert SQL Explorer in der Benutzeroberfläche, wenn ein Workspace an einen EMR-Cluster mit Laufzeit-Rolle angehängt ist.
- Sie können den Kollaborationsmodus nicht in einem EMR-Studio-Workspace mit einem Cluster verwenden, der über eine Laufzeit-Rolle verfügt. Amazon EMR deaktiviert die Funktionen für die Zusammenarbeit in Workspace, wenn ein Workspace an einen EMR-Cluster mit aktivierter Laufzeit-Rolle angehängt ist. Der Workspace bleibt nur für den Benutzer zugänglich, der den Workspace angehängt hat.
- Möglicherweise wird die Warnung Die Seite ist möglicherweise nicht sicher! angezeigt von der Spark-Benutzeroberfläche für einen Laufzeit-Cluster mit aktivierter Rolle. In diesem Fall umgehen Sie die Warnung, um weiterhin die Spark-Benutzeroberfläche zu sehen.

Führen Sie Workspace-Notebooks programmgesteuert aus

> **Note**
>
> Die programmatische Ausführung von Notebooks wird mit interaktiven Amazon-EMR-Serverless-Anwendungen nicht unterstützt.

Sie können Ihre Amazon EMR Studio Workspace-Notebooks programmgesteuert mit einem Skript oder auf AWS CLI ausführen. Informationen zum programmgesteuerten Ausführen Ihres Notebooks finden Sie unter Beispielbefehle zum programmgesteuerten Ausführen von EMR-Notebooks.

Durchsuchen Sie Daten mit SQL Explorer

> **Note**
>
> SQL Explorer für EMR Studio wird mit interaktiven Amazon-EMR-Serverless-Anwendungen nicht unterstützt.

In diesem Thema finden Sie Informationen, die Ihnen bei den ersten Schritten mit dem SQL Explorer in Amazon EMR Studio helfen. SQL Explorer ist ein einseitiges Tool in Ihrem Workspace, das Ihnen hilft, die Datenquellen im Datenkatalog Ihres EMR-Clusters zu verstehen. Sie können SQL Explorer verwenden, um Ihre Daten zu durchsuchen, SQL-Abfragen zum Abrufen von Daten auszuführen und Abfrageergebnisse herunterzuladen.

SQL Explorer unterstützt Presto. Bevor Sie SQL Explorer verwenden, stellen Sie sicher, dass Sie über einen Cluster verfügen, der Amazon-EMR-Version 5.34.0 oder höher oder Version 6.4.0 oder höher verwendet und Presto installiert hat. Der Amazon EMR Studio SQL Explorer unterstützt keine Presto-Cluster, die Sie mit Verschlüsselung während der Übertragung konfiguriert haben. Das liegt daran, dass Presto auf diesen Clustern im TLS-Modus ausgeführt wird.

Durchsuchen Sie den Datenkatalog Ihres Clusters

SQL Explorer bietet eine Katalogbrowser-Oberfläche, mit der Sie untersuchen und verstehen können, wie Ihre Daten organisiert sind. Sie können beispielsweise den Datenkatalogbrowser verwenden, um Tabellen- und Spaltennamen zu überprüfen, bevor Sie eine SQL-Abfrage schreiben.

Wie Sie Ihren Datenkatalog durchsuchen

1. Öffnen Sie SQL Explorer in Ihrem Workspace.
2. Stellen Sie sicher, dass Ihr Workspace mit einem EMR-Cluster verbunden ist, der auf EC2 läuft und Amazon-EMR-Version 6.4.0 oder höher mit installiertem Presto verwendet. Sie können einen vorhandenen Cluster auswählen oder einen neuen erstellen. Weitere Informationen finden Sie unter Einen Computer an einen EMR Studio Workspace anhängen.
3. Wählen Sie eine Datenbank aus der Drop-down-Liste aus, um sie zu durchsuchen.
4. Erweitern Sie eine Tabelle in Ihrer Datenbank, um die Spaltennamen der Tabelle zu sehen. Sie können in der Suchleiste auch ein Schlüsselwort eingeben, um die Tabellenergebnisse zu filtern.

Führen Sie eine SQL-Abfrage aus, um Daten abzurufen

Um Daten mit einer SQL-Abfrage abzurufen und die Ergebnisse herunterzuladen

1. Öffnen Sie SQL Explorer in Ihrem Workspace.
2. Stellen Sie sicher, dass Ihr Workspace an einen EMR-Cluster angeschlossen ist, der auf EC2 läuft und Presto und Spark installiert sind. Sie können einen vorhandenen Cluster auswählen oder einen neuen erstellen. Weitere Informationen finden Sie unter Einen Computer an einen EMR Studio Workspace anhängen.
3. Wählen Sie Editor öffnen, um eine neue Editor-Registerkarte in Ihrem Workspace zu öffnen.
4. Verfassen Sie Ihre SQL-Abfrage auf der Registerkarte „Editor“.
5. Wählen Sie Run (Ausführen) aus.

6. Sehen Sie sich Ihre Abfrageergebnisse unter Ergebnisvorschau an. SQL Explorer zeigt standardmäßig die ersten 100 Ergebnisse an. Sie können eine andere Anzahl von Ergebnissen für die Anzeige auswählen (bis zu 1 000), indem Sie das Dropdownmenü Vorschau der ersten 100 Abfrageergebnisse verwenden.
7. Wählen Sie Ergebnisse herunterladen, um Ihre Ergebnisse im CSV-Format herunterzuladen. Sie können bis zu 1 000 Ergebniszeilen herunterladen.

Einen Computer an einen EMR Studio Workspace anhängen

Amazon EMR Studio führt Notebook-Befehle mithilfe eines Kernels auf einem EMR-Cluster aus. Bevor Sie einen Kernel auswählen können, sollten Sie den Workspace an einen Cluster anhängen, der Amazon-EC2-Instances verwendet, an einen Amazon EMR in EKS-Cluster oder an eine EMR-Serverless-Anwendung. Mit EMR Studio können Sie Workspaces an neue oder bestehende Cluster anhängen und haben die Flexibilität, Cluster zu ändern, ohne den Workspace schließen zu müssen.

In diesem Abschnitt finden Sie die folgenden Themen, die Ihnen beim Arbeiten mit und beim Bereitstellen von Clustern für EMR Studio helfen:

- Einen Amazon-EC2-Cluster an einen EMR Studio Workspace anhängen
- Einen Amazon EMR in EKS-Cluster an einen EMR-Studio-Workspace anhängen
- Eine Amazon-EMR-Serverless-Anwendung an einen EMR Studio Workspace anhängen
- Einen neuen EMR-Cluster erstellen und an einen EMR Studio Workspace anhängen
- Trennen Sie einen Computer von einem EMR Studio Workspace

Einen Amazon-EC2-Cluster an einen EMR Studio Workspace anhängen

Sie können einen EMR-Cluster, der auf Amazon EC2 läuft, einem Workspace zuordnen, wenn Sie den Workspace erstellen, oder einen Cluster an einen vorhandenen Workspace anhängen. Wenn Sie einen neuen Cluster erstellen und anhängen möchten, lesen Sie Einen neuen EMR-Cluster erstellen und an einen EMR Studio Workspace anhängen.

On create

Beim Erstellen eines Workspace eine Verbindung zu einem Amazon-EMR-Compute-Cluster herstellen

1. Stellen Sie im Dialogfeld Workspace erstellen sicher, dass Sie bereits ein Subnetz für den neuen Workspace ausgewählt haben. Erweitern Sie den Abschnitt Erweiterte Konfiguration.
2. Stellen Sie im Dialogfeld Workspace erstellen sicher, dass Sie bereits ein Subnetz für den neuen Workspace ausgewählt haben. Erweitern Sie den Abschnitt Erweiterte Konfiguration.
3. Wählen Sie Workspace an einen EMR-Cluster anhängen.
4. Wählen Sie in der EMR-Cluster-Dropdown-Liste einen vorhandenen EMR-Cluster aus, der an den Workspace angehängt werden soll.

Nachdem Sie einen Cluster angehängt haben, beenden Sie die Erstellung des Workspace. Wenn Sie den neuen Workspace zum ersten Mal öffnen und den Bereich EMR-Cluster auswählen, sollte Ihr ausgewählter Cluster angehängt sein.

On launch

Stellen Sie eine Verbindung zu einem Amazon-EMR-Rechencluster her, wenn Sie den Workspace starten

1. Navigieren Sie zur Workspaces-Liste und wählen Sie die Zeile für den Workspace aus, den Sie starten möchten. Wählen Sie dann Workspace starten > Mit Optionen starten aus.
2. Wählen Sie einen EMR-Cluster aus, der an Ihren Workspace angehängt werden soll.

Nachdem Sie einen Cluster angehängt haben, beenden Sie die Erstellung des Workspace. Wenn Sie den neuen Workspace zum ersten Mal öffnen und den Bereich EMR-Cluster auswählen, sollte Ihr ausgewählter Cluster angehängt sein.

In JupyterLab

Einen Workspace an einen Amazon-EMR-Compute-Cluster in JupyterLab anhängen

1. Wählen Sie Ihren Workspace und dann Workspace starten > Schnellstart.
2. Öffnen Sie in JupyterLab der Cluster-Registerkarte in der linken Seitenleiste.
3. Wählen Sie die Dropdownliste EMR auf EC2-Cluster oder wählen Sie einen Amazon EMR in EKS-Cluster aus.

4. Wählen Sie Anfügen, um den Cluster an Ihren Workspace anzufügen.

   Nachdem Sie einen Cluster angehängt haben, beenden Sie die Erstellung des Workspace. Wenn Sie den neuen Workspace zum ersten Mal öffnen und den Bereich EMR-Cluster auswählen, sollte Ihr ausgewählter Cluster angehängt sein.

In the Workspace UI

Hängen Sie über die Workspace-Benutzeroberfläche einen Workspace an einen Amazon-EMR-Compute-Cluster an

1. Wählen Sie in dem Workspace, den Sie einem Cluster zuordnen möchten, in der linken Seitenleiste das EMR-Cluster-Symbol aus, um das Cluster-Bereich zu öffnen.
2. Erweitern Sie unter Clustertyp die Dropdownliste und wählen Sie EMR-Cluster auf EC2 aus.
3. Wählen Sie Cluster in der Dropdown-Liste aus. Möglicherweise müssen Sie zuerst einen vorhandenen Cluster trennen, um die Dropdownliste für die Clusterauswahl zu aktivieren.
4. Wählen Sie Attach (Anfügen) aus. Wenn der Cluster angehängt ist, sollte eine Erfolgsmeldung angezeigt werden.

Einen Amazon EMR in EKS-Cluster an einen EMR-Studio-Workspace anhängen

Zusätzlich zur Verwendung von Amazon-EMR-Clustern, die auf Amazon EC2 ausgeführt werden, können Sie einen Workspace an einen Amazon EMR on EKS-Cluster anhängen, um Notebook-Code auszuführen. Weitere Informationen zu Amazon EMR in EKS finden Sie unter Was ist Amazon EMR in EKS.

Bevor Sie einen Workspace mit einem Amazon EMR in EKS-Cluster verbinden können, muss Ihnen Ihr Studio-Administrator Zugriffsberechtigungen erteilen.

On create

So fügen Sie beim Erstellen eines Workspace einen Amazon EMR in EKS-Cluster an

1. Erweitern Sie im Dialogfeld Workspace erstellen den Abschnitt Erweiterte Konfiguration.
2. Wählen Sie Workspace an einen Amazon EMR in EKS-Cluster anfügen.
3. Wählen Sie unter Amazon EMR in EKS-Cluster einen Cluster aus der Dropdownliste aus.

4. Wählen Sie unter Endpunkt auswählen einen verwalteten Endpunkt aus, der an den Workspace angefügt werden soll. Ein verwalteter Endpunkt ist ein Gateway, über das EMR Studio mit dem von Ihnen ausgewählten Cluster kommunizieren kann.
5. Wählen Sie Workspace erstellen aus, um den Workspace-Erstellungsprozess abzuschließen und den ausgewählten Cluster anzuhängen.

Nachdem Sie einen Cluster angehängt haben, können Sie den Workspace-Erstellungsprozess abschließen. Wenn Sie den neuen Workspace zum ersten Mal öffnen und den Bereich EMR-Cluster auswählen, sollte Ihr ausgewählter Cluster angehängt sein.

In the Workspace UI

So hängen Sie über die Workspace-Benutzeroberfläche einen Amazon EMR an einen EKS-Cluster an

1. Wählen Sie in dem Workspace, den Sie einem Cluster zuordnen möchten, in der linken Seitenleiste das EMR-Cluster-Symbol aus, um das Cluster-Bereich zu öffnen.
2. Erweitern Sie die Dropdownliste Clustertyp und wählen Sie EMR-Cluster in EKS aus.
3. Wählen Sie unter EMR in EKS-Cluster einen Cluster aus der Dropdownliste aus.
4. Wählen Sie unter Endpunkt einen verwalteten Endpunkt aus, der an den Workspace angehängt werden soll. Ein verwalteter Endpunkt ist ein Gateway, über das EMR Studio mit dem von Ihnen ausgewählten Cluster kommunizieren kann.
5. Wählen Sie Attach (Anfügen) aus. Wenn der Cluster angehängt ist, sollte eine Erfolgsmeldung angezeigt werden.

Eine Amazon-EMR-Serverless-Anwendung an einen EMR Studio Workspace anhängen

Sie können einen Workspace an eine EMR-Serverless-Anwendung anhängen, um interaktive Workloads auszuführen. Weitere Informationen finden Sie unter Verwenden von Notebooks zur Ausführung interaktiver Workloads mit EMR Serverless über EMR Studio.

Example Einen Workspace an eine EMR-Serverless-Anwendung in JupyterLab anhängen

Bevor Sie einen Workspace mit einer EMR-Serverless-Anwendung verbinden können, muss Ihnen Ihr Kontoadministrator Zugriffsberechtigungen gewähren, wie unter Erforderliche Berechtigungen für interaktive Workloads beschrieben.

1. Navigieren Sie zu EMR Studio, wählen Sie Ihren Workspace aus und wählen Sie dann Workspace starten > Schnellstart aus.
2. Öffnen Sie in JupyterLab der Cluster-Registerkarte in der linken Seitenleiste.
3. Wählen Sie EMR Serverless als Rechenoption aus, wählen Sie dann eine EMR-Serverless-Anwendung und eine Laufzeit-Rolle aus.
4. Wählen Sie Anfügen, um den Cluster an Ihren Workspace anzufügen.

Wenn Sie jetzt diesen Workspace öffnen, sollten Sie sehen, dass Ihre ausgewählte Anwendung angefügt ist.

Einen neuen EMR-Cluster erstellen und an einen EMR Studio Workspace anhängen

Fortgeschrittene EMR-Studio-Benutzer können neue EMR-Cluster bereitstellen, die auf Amazon EC2 ausgeführt werden, um sie mit einem Workspace zu verwenden. Auf dem neuen Cluster sind standardmäßig alle Big-Data-Anwendungen installiert, die für EMR Studio erforderlich sind.

Um Cluster zu erstellen, muss Ihnen Ihr Studio-Administrator zunächst mithilfe einer Sitzungsrichtlinie die Erlaubnis erteilen. Weitere Informationen finden Sie unter Berechtigungsrichtlinien für EMR-Studio-Benutzer erstellen.

Sie können einen neuen Cluster im Dialogfeld Workspace erstellen oder im Bereich Cluster in der Workspace-Benutzeroberfläche erstellen. In beiden Fällen haben Sie zwei Möglichkeiten zum Erstellen eines Clusters:

1. Einen EMR-Cluster erstellen – Erstellen Sie einen EMR-Cluster, indem Sie den Amazon-EC2-Instance-Typ und die Anzahl wählen.
2. Eine Cluster-Vorlage verwenden – Stellen Sie einen Cluster bereit, indem Sie eine vordefinierte Cluster-Vorlage auswählen. Diese Option wird angezeigt, wenn Sie berechtigt sind, Clustervorlagen zu verwenden.

So erstellen Sie einen EMR-Cluster durch Bereitstellung einer Clusterkonfiguration

1. Wählen Sie einen Startpunkt aus.

Aufgabe	Vorgehensweise
Erstellen Sie den Cluster, wenn Sie einen Workspace mit dem Dialogfeld Workspace erstellen.	Erweitern Sie den Abschnitt Erweiterte Konfiguration im Dialogfeld Workspace erstellen und wählen Sie EMR-Cluster erstellen aus.
Erstellen Sie den Cluster über das EMR-Cluster-Panel in der Workspace-Benutzer oberfläche, nachdem Sie einen Workspace erstellt haben.	Wählen Sie in der linken Seitenleiste eines geöffneten Workspace die Registerkarte EMR-Cluster, erweitern Sie den Abschnitt Erweiterte Konfiguration und wählen Sie Cluster erstellen aus.

2. Geben Sie einen Clusternamen ein. Wenn Sie den Cluster benennen, können Sie ihn später in der Liste der EMR-Studio-Cluster leichter finden.
3. Wählen Sie für die Amazon-EMR-Version eine Amazon-EMR-Release-Version für den Cluster aus.
4. Wählen Sie für Instance den Typ und die Anzahl der Amazon-EC2-Instances für den Cluster aus. Weitere Informationen zur Auswahl von Instance-Typen finden Sie unter Amazon-EC2-Instances konfigurieren. Genau eine Instance wird als Primärknoten verwendet.
5. Wählen Sie ein Subnetz aus, in dem EMR Studio den neuen Cluster starten kann. Jede Subnetzoption wurde von Ihrem Studio-Administrator vorab genehmigt, und Ihr Workspace sollte in der Lage sein, eine Verbindung zu einem Cluster in einem beliebigen aufgelisteten Subnetz herzustellen.
6. Wählen Sie eine S3-URI für die Protokollspeicherung.
7. Wählen Sie EMR-Cluster erstellen aus, um den Cluster zu bereitzustellen. Wenn Sie das Dialogfeld Workspace erstellen verwenden, wählen Sie Workspace erstellen aus, um den Workspace zu erstellen und den Cluster bereitzustellen. Nachdem EMR Studio den neuen Cluster bereitgestellt hat, wird der Cluster an den Workspace angehängt.

So erstellen Sie einen Cluster mit einer Cluster-Vorlage

1. Wählen Sie einen Startpunkt aus.

Aufgabe	Vorgehensweise
Erstellen Sie den Cluster, wenn Sie einen Workspace mit dem Dialogfeld Workspace erstellen.	Erweitern Sie den Abschnitt Erweiterte Konfiguration im Dialogfeld Workspace erstellen und wählen Sie Cluster-Vorlage verwenden aus.
Erstellen Sie den Cluster über das EMR-Cluster-Panel in der Workspace-Benutzer oberfläche.	Wählen Sie in der linken Seitenleiste eines geöffneten Workspace die Registerkarte EMR-Cluster, erweitern Sie den Abschnitt Erweiterte Konfiguration und wählen Sie Cluster-Vorlage aus.

2. Wählen Sie eine Cluster-Vorlage aus der Dropdown-Liste aus. Jede verfügbare Clustervorlage enthält eine kurze Beschreibung, die Ihnen bei der Auswahl hilft.
3. Die von Ihnen gewählte Cluster-Vorlage kann zusätzliche Parameter wie die Amazon-EMR-Release-Version oder den Clusternamen enthalten. Sie können Werte auswählen oder einfügen oder die Standardwerte verwenden, die Ihr Administrator ausgewählt hat.
4. Wählen Sie ein Subnetz aus, in dem EMR Studio den neuen Cluster starten kann. Jede Subnetzoption wurde von Ihrem Studio-Administrator vorab genehmigt, und Ihr Workspace sollte in der Lage sein, eine Verbindung zu einem Cluster in einem beliebigen Subnetz herzustellen.
5. Wählen Sie Clustervorlage verwenden, um den Cluster bereitzustellen und an den Workspace anzuhängen. Es dauert einige Minuten, bis EMR Studio den Cluster erstellt. Wenn Sie das Dialogfeld Workspace erstellen verwenden, wählen Sie Workspace erstellen aus, um den Workspace zu erstellen und den Cluster bereitzustellen. Nachdem EMR Studio den neuen Cluster bereitgestellt hat, wird der Cluster an den Workspace angehängt.

Trennen Sie einen Computer von einem EMR Studio Workspace

Um den mit einem Workspace verbundenen Cluster auszutauschen, können Sie einen Cluster von der Workspace-Benutzeroberfläche trennen.

So trennen Sie einen Cluster von einem Workspace

1. Wählen Sie in dem Workspace, den Sie die Zuordnung zu einem Cluster aufheben möchten, in der linken Seitenleiste das EMR-Cluster-Symbol aus, um das Cluster-Bereich zu öffnen.

2. Wählen Sie unter Cluster auswählen die Option Trennen aus und warten Sie, bis EMR Studio den Cluster getrennt hat. Wenn der Cluster getrennt ist, sehen Sie eine Erfolgsmeldung.

So trennen Sie eine Serverless-EMR-Anwendung von einem EMR-Studio-Workspace

Um den mit einem Workspace verbundenen Compute auszutauschen, können Sie eine Anwendung von der Workspace-Benutzeroberfläche trennen.

1. Wählen Sie in dem Workspace, den Sie von einem Cluster trennen möchten, in der linken Seitenleiste das Amazon-EMR-Datenverarbeitungssymbol aus, um das Datenverarbeitungs-Panel zu öffnen.
2. Wählen Sie unter Compute auswählen die Option Trennen aus und warten Sie, bis EMR Studio die Anwendung getrennt hat. Wenn die Anwendung getrennt ist, sehen Sie eine Erfolgsmeldung.

Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen

Über Git-Repositorys für EMR Studio

Sie können einem EMR Studio Workspace maximal drei Git-Repositorys zuordnen. Standardmäßig können Sie in jedem Workspace aus einer Liste von Git-Repositorys wählen, die demselben AWS-Konto wie das Studio zugeordnet sind. Sie können auch ein neues Git-Repository als Ressource für einen Workspace erstellen.

Sie können Git-Befehle wie die folgenden mit einem Terminalbefehl ausführen, während Sie mit dem Primärknoten eines Clusters verbunden sind.

```
!git pull origin <branch-name>
```

Sie können aber auch die jupyterlab-git-Erweiterung verwenden. Öffnen Sie es in der linken Seitenleiste, indem Sie das Git-Symbol auswählen. Informationen zur jupyterlab-git-Erweiterung für JupyterLab finden Sie unter jupyterlab-git.

Voraussetzungen

- Um ein Git-Repository mit einem Workspace zu verknüpfen, muss Ihr Studio so konfiguriert sein, dass die Verknüpfung mit Git-Repositorys zulässig ist. Ihr Studio-Administrator sollte folgende Schritte unternehmen, um Zugriff und Berechtigungen für Git-basierte Repositorys einrichten.

- Wenn Sie ein CodeCommit-Repository verwenden, müssen Sie Git-Anmeldeinformationen und HTTPS verwenden. SSH-Schlüssel und HTTPS mit dem AWS Command Line Interface Credential Helper werden nicht unterstützt. CodeCommit unterstützt keine Personal Access Tokens (PATs). Weitere Informationen finden Sie unter Verwenden von IAM mit CodeCommit im IAM-Benutzerhandbuch und Setup für HTTPS-Benutzer mit Git-Anmeldeinformationen im AWS CodeCommit-Benutzerhandbuch.

Anweisungen

So verknüpfen Sie ein zugeordnetes Git-Repository mit einem Workspace

1. Öffnen Sie den Workspace, den Sie mit einem Repository verknüpfen möchten, in der Workspaces-Liste im Studio.
2. Wählen Sie in der linken Seitenleiste das Amazon-EMR-Git-Repository-Symbol, um das Git-Repository-Toolpanel zu öffnen.
3. Erweitern Sie unter Git-Repositorys die Drop-down-Liste und wählen Sie maximal drei Repositorys aus, die mit dem Workspace verknüpft werden sollen. EMR Studio registriert Ihre Auswahl und beginnt, jedes Repository zu verknüpfen.

Es kann einige Zeit dauern, bis der Verbindungsvorgang abgeschlossen ist. Sie können den Status für jedes Repository sehen, das Sie im Git-Repository-Toolpanel ausgewählt haben. Nachdem EMR Studio ein Repository mit einem Workspace verknüpft hat, sollten die Dateien, die zu diesem Repository gehören, im Dateibrowser-Bereich angezeigt werden.

Um einem Workspace ein neues Git-Repository als Ressource hinzuzufügen

1. Öffnen Sie den Workspace, den Sie mit einem Repository verknüpfen möchten, in der Workspaces-Liste im Studio.
2. Wählen Sie in der linken Seitenleiste das Amazon-EMR-Git-Repository-Symbol, um das Git-Repository-Toolpanel zu öffnen.
3. Wählen Sie Neues Git-Repository hinzufügen.
4. Geben Sie unter Repository-Name einen Namen ein, der für das Repository in EMR Studio verwendet werden soll. Namen dürfen nur alphanumerische Zeichen, Bindestriche oder Unterstriche enthalten.
5. Geben Sie für Git repository URL (Git-Repository-URL) die URL für das Repository ein. Wenn Sie ein CodeCommit-Repository verwenden, ist dies die URL, die kopiert wird, wenn Sie URL

klonen und dann HTTPS klonen auswählen. Zum Beispiel `https://git-codecommit.us-west-2.amazonaws.com/v1/repos/[MyCodeCommitRepoName]`.

6. Geben Sie für Branch den Namen eines vorhandenen Branches ein, den Sie auschecken möchten.
7. Wählen Sie Optionen für Git-Anmeldeinformationen gemäß den folgenden Richtlinien. EMR Studio greift mithilfe von Geheimnissen, die im Secrets Manager gespeichert sind, auf Ihre Git-Anmeldeinformationen zu.

> **Note**
>
> Wenn Sie ein GitHub-Repository verwenden, empfehlen wir Ihnen, zur Authentifizierung ein Personal Access Token (PAT) zu verwenden. Ab dem 13. August 2021 erfordert GitHub eine tokenbasierte Authentifizierung und akzeptiert bei der Authentifizierung von Git-Vorgängen keine Passwörter mehr. Weitere Informationen findest du im Beitrag Token-Authentifizierungsanforderungen für Git-Operationen im GitHub-Blog.

Option	Beschreibung
Erstellen eines neuen Secrets	Wählen Sie diese Option, um vorhandene Git-Anmeldeinformationen mit einem neuen Geheimnis zu verknüpfen, das in AWS Secrets Manager für Sie erstellt wird. Führen Sie basierend auf den Git-Anmeldeinformationen, die Sie für das Repository verwenden, einen der folgenden Schritte aus. Wenn Sie für den Zugriff auf das Repository einen Git-Benutzernamen mit Passwort verwenden, wählen Sie Benutzername und Passwort aus, geben Sie den Namen des Secrets ein, das in Secrets Manager verwendet werden soll, und geben Sie dann den Benutzernamen und das Passwort ein, die mit dem Secret verknüpft werden sollen. -ODER-

Option	Beschreibung
	Wenn Sie ein persönliches Zugriffstoken für den Zugriff auf das Repository verwenden , wählen Sie Persönliches Zugriffstoken (PAT) aus, geben Sie den Secret-Name ein, der in Secrets Manager verwendet werden soll, und geben Sie dann Ihr persönliches Zugriffstoken ein. Weitere Informationen finden Sie unter Erstellen eines persönlichen Zugriffstoken für die Befehlszeile für GitHub und Persönliche Zugriffstoken für Bitbucket. CodeCommit-Repositorys unterstützen diese Option nicht.
Verwenden eines öffentlichen Repository ohne Anmeldeinformationen	Wählen Sie diese Option, um auf ein öffentlic hes Repository zuzugreifen.
Verwenden eines vorhandenen AWS-Secrets	Wählen Sie diese Option, wenn Sie Ihre Anmeldeinformationen bereits als Secret in Secrets Manager gespeichert haben, und wählen Sie dann den Namen des Secrets in der Liste aus. Wenn Sie ein Secret auswählen, das mit einem Git-Benutzernamen und -Passwort verknüpft ist, muss das Secret das Format `{"gitUsername": " MyUserName ", "gitPassword": " MyPassword "}` aufweisen.

8. Wählen Sie Repository hinzufügen, um das neue Repository zu erstellen. Nachdem EMR Studio das neue Repository erstellt hat, wird eine Erfolgsmeldung angezeigt. Das neue Repository erscheint in der Dropdown-Liste unter Git-Repositorys.
9. Um das neue Repository mit deinem Workspace zu verknüpfen, wähle es aus der Drop-down-Liste unter Git-Repositorys aus.

Es kann einige Zeit dauern, bis der Verbindungsvorgang abgeschlossen ist. Nachdem EMR Studio das neue Repository mit dem Workspace verknüpft hat, sollte im Dateibrowser-Bereich ein neuer Ordner mit demselben Namen wie Ihr Repository angezeigt werden.

Um ein anderes verknüpftes Repository zu öffnen, navigieren Sie im Dateibrowser zu seinem Ordner.

Debuggen von Anwendungen und Aufträgen mit EMR Studio

Mit Amazon EMR Studio können Sie Datenanwendungsschnittstellen starten, um Anwendungen und Auftragsausführungen im Browser zu analysieren.

Sie können die persistenten Benutzeroberflächen außerhalb des Clusters für Amazon EMR, die auf EC2-Clustern ausgeführt werden, auch von der Amazon-EMR-Konsole aus starten. Weitere Informationen finden Sie unter Persistente Anwendungsbenutzeroberflächen anzeigen.

> **Note**
>
> Abhängig von Ihren Browsereinstellungen müssen Sie möglicherweise Popups aktivieren, damit die Benutzeroberfläche einer Anwendung geöffnet werden kann.

Informationen zum Konfigurieren und Verwenden der Anwendungsschnittstellen finden Sie unter YARN Timeline Server, Überwachung und Instrumentierung oder Tez-UI-Übersicht.

Debuggen von Amazon EMR, das in Amazon-EC2-Aufträgen ausgeführt wird

Workspace UI

Starten Sie eine Cluster-Benutzeroberfläche aus einer Notebook-Datei

Wenn Sie die Amazon-EMR-Release-Versionen 5.33.0 und höher verwenden, können Sie die Spark-Webbenutzeroberfläche (die Spark-Benutzeroberfläche oder den Spark History Server) von einem Notebook in Ihrem Workspace aus starten.

Benutzeroberflächen auf Clustern funktionieren mit den Kerneln PySpark, Spark oder SparkR. Die maximale sichtbare Dateigröße für Spark-Event- oder Container-Logs beträgt 10 MB. Wenn Ihre Protokolldateien 10 MB überschreiten, empfehlen wir Ihnen, zum Debuggen von Jobs den persistenten Spark History Server anstelle der Cluster-internen Spark-Benutzeroberfläche zu verwenden.

> **Important**
>
> Damit EMR Studio Benutzeroberflächen für Cluster-Anwendungen von einem Workspace aus starten kann, muss ein Cluster in der Lage sein, mit dem Amazon API Gateway zu kommunizieren. Sie müssen den EMR-Cluster so konfigurieren, dass ausgehender Netzwerkverkehr zu Amazon API Gateway zugelassen wird, und sicherstellen, dass Amazon API Gateway vom Cluster aus erreichbar ist.
> Die Spark-Benutzeroberfläche greift auf Container-Logs zu, indem sie Hostnamen auflöst. Wenn Sie einen benutzerdefinierten Domainnamen verwenden, müssen Sie sicherstellen, dass die Hostnamen Ihrer Clusterknoten von Amazon DNS oder dem von Ihnen angegebenen DNS-Server aufgelöst werden können. Stellen Sie dazu die Dynamic Host Configuration Protocol (DHCP)-Optionen für die Amazon Virtual Private Cloud (VPC) ein, die Ihrem Cluster zugeordnet ist. Weitere Informationen zu DHCP-Optionen finden Sie unter DHCP-Optionssätze im Amazon-Virtual-Private-Cloud-Benutzerhandbuch.

1. Öffnen Sie in Ihrem EMR Studio den Workspace, den Sie verwenden möchten, und stellen Sie sicher, dass er mit einem Amazon-EMR-Cluster verbunden ist, der auf EC2 ausgeführt wird. Detaillierte Anweisungen finden Sie unter Einen Computer an einen EMR Studio Workspace anhängen.
2. Öffnen Sie eine Notebook-Datei und verwenden Sie den PySpark-, Spark- oder SparkR-Kernel. Um einen Kernel auszuwählen, wählen Sie den Kernel-Namen oben rechts in der Notebook-Symbolleiste, um das Dialogfeld Kernel auswählen zu öffnen. Der Name erscheint als Kein Kernel! wenn kein Kernel ausgewählt wurde.
3. Führen Sie Ihren Notebook-Code aus. Folgendes wird als Ausgabe im Notebook angezeigt, wenn Sie den Spark-Kontext starten. Es kann einige Sekunden dauern, bis es angezeigt wird. Wenn Sie den Spark-Kontext gestartet haben, können Sie den `%%info`-Befehl ausführen, um jederzeit auf einen Link zur Spark-Benutzeroberfläche zuzugreifen.

> **Note**
>
> Wenn die Spark-UI-Links nicht funktionieren oder nach einigen Sekunden nicht angezeigt werden, erstellen Sie eine neue Notebook-Zelle und führen Sie den `%%info`-Befehl aus, um die Links neu zu generieren.

4. Um die Spark-Benutzeroberfläche zu starten, wählen Sie Link unter Spark-Benutzeroberfläche. Wenn Ihre Spark-Anwendung ausgeführt wird, wird die Spark-Benutzeroberfläche in einer neuen Registerkarte geöffnet. Wenn die Anwendung abgeschlossen ist, wird stattdessen der Spark History Server geöffnet.

   Nachdem Sie die Spark-Benutzeroberfläche gestartet haben, können Sie die URL im Browser ändern, um den YARN ResourceManager oder den Yarn Timeline Server zu öffnen. Fügen Sie nach `amazonaws.com` einen der folgenden Pfade hinzu.

Web-Benutzeroberfläche	Pfad	Beispiel für eine geänderte URL
YARN ResourceManager	/rm	https://*j-examplebby5ij* .emrappui-prod.*eu-west-1* .amazonaws.com/*rm*
Yarn-Timeline-Server	/yts	https://*j-examplebby5ij* .emrappui-prod.*eu-west-1* .amazonaws.com/*yts*
Spark History Server	/shs	https://*j-examplebby5ij* .emrappui-prod.*eu-west-1* .amazonaws.com/*shs*

Studio UI

Starten Sie den persistenten YARN Timeline Server, Spark History Server oder Tez UI über die EMR-Studio-Benutzeroberfläche

1. Wählen Sie in Ihrem EMR Studio links auf der Seite Amazon EMR in EC2 aus, um die Liste der Cluster von Amazon EMR in EC2 zu öffnen.
2. Filtern Sie die Clusterliste nach Name, Status oder ID, indem Sie Werte in das Suchfeld eingeben. Sie können auch nach Erstellungszeitraum suchen.
3. Wählen Sie einen Cluster aus und klicken Sie dann auf Anwendungsbenutzeroberflächen starten, um eine Anwendungsbenutzeroberfläche auszuwählen. Die Anwendungsbenutzeroberfläche wird in einer neuen Browser-Registerkarte geöffnet. Es kann einige Zeit dauern, bis sie geladen wird.

Debuggen Sie EMR Studio, das auf EMR Serverless läuft

Ähnlich wie Amazon EMR, das auf Amazon EC2 läuft, können Sie die Workspace-Benutzeroberfläche verwenden, um Ihre EMR-Serverless-Anwendungen zu analysieren. Wenn Sie Amazon-EMR-Versionen 6.14.0 und höher verwenden, können Sie von der Workspace-Benutzeroberfläche aus die Spark-Webbenutzeroberfläche (die Spark-Benutzeroberfläche oder den Spark History Server) von einem Notebook in Ihrem Workspace aus starten. Der Einfachheit halber stellen wir auch einen Link zum Treiberprotokoll zur Verfügung, über den Sie schnell auf die Spark-Treiberprotokolle zugreifen können.

Debuggen Sie Amazon EMR in EKS-Auftragsausführungen mit dem Spark History Server

Wenn Sie eine Auftragsausführung an einen Amazon EMR in EKS-Cluster senden, können Sie über den Spark History Server auf die Protokolle für diese Auftragsausführung zugreifen. Der Spark History Server bietet Tools zur Überwachung von Spark-Anwendungen, z. B. eine Liste von Scheduler-Phasen und -aufgaben, eine Zusammenfassung der RDD-Größen und der Speichernutzung sowie Umgebungsinformationen. Sie können den Spark History Server für Amazon EMR in EKS-Auftragsläufe auf folgende Weise starten:

- Wenn Sie einen Auftrag einreichen, der mit EMR Studio und einem von Amazon EMR auf EKS verwalteten Endpunkt ausgeführt wird, können Sie den Spark History Server von einer Notebook-Datei in Ihrem Workspace aus starten.

- Wenn Sie einen Auftrag einreichen, der mit dem AWS CLI- oder AWS-SDK für Amazon EMR in EKS ausgeführt wird, können Sie den Spark History Server über die EMR-Studio-Benutzeroberfläche starten.

Informationen zur Verwendung des Spark History Servers finden Sie unter Überwachung und Instrumentierung in der Apache-Spark-Dokumentation. Weitere Informationen zu Auftragsausführungen finden Sie unter Konzepte und Komponenten im Entwicklerhandbuch zu Amazon EMR in EKS.

So starten Sie den Spark History Server aus einer Notebook-Datei in Ihrem EMR Studio Workspace

1. Öffnen Sie einen Workspace, der mit einem Amazon EMR in EKS-Cluster verbunden ist.
2. Wählen Sie Ihre Notebook-Datei aus und öffnen Sie sie im Workspace.
3. Wählen Sie oben in der Notebook-Datei die Spark-Benutzeroberfläche, um den persistenten Spark-Geschichtsserver in einer neuen Registerkarte zu öffnen.

So starten Sie den Spark History Server über die EMR-Studio-Benutzeroberfläche

> **Note**
>
> In der Auftragsliste in der EMR-Studio-Benutzeroberfläche werden nur Auftragsausführungen angezeigt, die Sie mit dem AWS CLI- oder AWS-SDK für Amazon EMR in EKS einreichen.

1. Wählen Sie in Ihrem EMR Studio links auf der Seite Amazon EMR in EKS aus.
2. Suchen Sie nach dem virtuellen Amazon EMR in EKS-Cluster, mit dem Sie Ihre Auftragsausführung eingereicht haben. Sie können die Liste der Cluster nach Status oder ID filtern, indem Sie Werte in das Suchfeld eingeben.
3. Wählen Sie den Cluster aus, um seine Detailseite zu öffnen. Auf der Detailseite werden Informationen über den Cluster wie ID, Namespace und Status angezeigt. Auf der Seite wird auch eine Liste aller Auftragsausführungen angezeigt, die an diesen Cluster übermittelt wurden.
4. Wählen Sie auf der Cluster-Detailseite einen Auftrag aus, der debuggt werden soll.
5. Wählen Sie oben rechts in der Auftragsliste die Option Spark History Server starten, um die Anwendungsoberfläche in einer neuen Browser-Registerkarte zu öffnen.

Kernel und Bibliotheken in einem EMR Studio Workspace installieren

Jedes Amazon EMR Studio Workspace wird mit einer Reihe vorinstallierter Bibliotheken und Kernel ausgeliefert.

Kernel und Bibliotheken auf Clustern, die auf Amazon EC2 laufen

Sie können die Umgebung für EMR Studio auch auf folgende Weise anpassen, wenn Sie EMR-Cluster verwenden, die auf Amazon EC2 ausgeführt werden:

- Jupyter-Notebook-Kernel und Python-Bibliotheken auf einem Cluster-Primärknoten installieren – Wenn Sie Bibliotheken mit dieser Option installieren, teilen sich alle Workspaces, die demselben Cluster zugeordnet sind, diese Bibliotheken gemeinsam. Sie können Kernel oder Bibliotheken von einer Notebook-Zelle aus installieren oder während Sie über SSH mit dem Primärknoten eines Clusters verbunden sind.
- Verwenden Sie Bibliotheken für Notebooks – Wenn Workspace-Benutzer Bibliotheken von einer Notebook-Zelle aus installieren und verwenden, sind diese Bibliotheken nur für dieses Notebook verfügbar. Mit dieser Option können verschiedene Notebooks, die denselben Cluster verwenden, arbeiten, ohne sich Gedanken über widersprüchliche Bibliotheksversionen machen zu müssen.

EMR Studio Workspaces haben dieselbe grundlegende Architektur wie EMR Notebooks. Sie können Jupyter-Notebook-Kernel und Python-Bibliotheken mit EMR Studio genauso installieren und verwenden wie mit EMR Notebooks. Detaillierte Anweisungen finden Sie unter Installieren und Verwenden von Kerneln und Bibliotheken.

Kernel und Bibliotheken in Amazon EMR in EKS-Clustern

Amazon EMR in EKS-Clustern enthalten die Kernel PySpark und Python 3.7 mit einer Reihe vorinstallierter Bibliotheken. Amazon EMR in EKS unterstützt die Installation zusätzlicher Bibliotheken oder Cluster nicht.

Auf jedem Amazon EMR in EKS-Cluster sind die folgenden Python- und PySpark-Bibliotheken installiert:

- Python – boto3, cffi, future, ggplot, jupyter, kubernetes, matplotlib, numpy, pandas, plotly, pycryptodomex, py4j, requests, scikit-learn, scipy, seaborn
- PySpark – ggplot, jupyter, matplotlib, numpy, pandas, plotly, pycryptodomex, py4j, requests, scikit-learn, scipy, seaborn

Kernel und Bibliotheken für EMR-Serverless-Anwendungen

In jeder EMR-Serverless-Anwendung sind die folgenden Python- und PySpark-Bibliotheken installiert:

- Python – ggplot, matplotlib, numpy, pandas, plotly, bokeh, scikit-learn, scipy, seaborn
- PySpark – ggplot, matplotlib,numpy, pandas, plotly, bokeh, scikit-learn, scipy, seaborn

Verbessern Sie die Kernel mit Befehlen magic

Übersicht

EMR Studio und EMR Notebooks unterstützen magic-Befehle. Magic-Befehle oder magic sind Erweiterungen, die der IPython-Kernel bereitstellt, um Sie beim Ausführen und Analysieren von Daten zu unterstützen. IPython ist eine interaktive Shell-Umgebung, die mit Python erstellt wurde.

Amazon EMR unterstützt auch Sparkmagic, ein Paket, das Spark-bezogene Kernel (PySpark-, SparkR- und Scala-Kernel) mit spezifischen magic-Befehlen bereitstellt und Livy auf dem Cluster verwendet, um Spark-Aufträge zu senden.

Sie können magic-Befehle verwenden, solange Sie einen Python-Kernel in Ihrem EMR-Notebook haben. In ähnlicher Weise unterstützt jeder Spark-bezogene Kernel Sparkmagic-Befehle.

Magic-Befehle, auch magic genannt, gibt es in zwei Varianten:

- Zeile magic – Diese magic-Befehle werden durch ein einzelnes `%`-Präfix gekennzeichnet und funktionieren in einer einzigen Codezeile
- Zelle magic – Diese magic-Befehle sind mit einem doppelten `%%`-Präfix gekennzeichnet und funktionieren auf mehreren Codezeilen

Alle verfügbaren magic finden Sie unter Liste der magic- und Sparkmagic-Befehle.

Überlegungen und Einschränkungen

- EMR Serverless unterstützt die `%%sh`-Ausführung von `spark-submit` nicht. Die EMR Notebooks magic werden nicht unterstützt.
- Amazon EMR in EKS-Cluster unterstützten keine Sparkmagic-Befehle für EMR Studio. Das liegt daran, dass Spark-Kernel, die Sie mit verwalteten Endpunkten verwenden, in Kubernetes integriert

sind und von Sparkmagic und Livy nicht unterstützt werden. Sie können die Spark-Konfiguration als Workaround direkt im SparkContext-Objekt festlegen, wie das folgende Beispiel zeigt.

```
spark.conf.set("spark.driver.maxResultSize", '6g')
```

- Die folgenden magic-Befehle und Aktionen sind verboten von AWS:
  - `%alias`
  - `%alias_magic`
  - `%automagic`
  - `%macro`
  - Ändern von `proxy_user` mit `%configure`
  - Ändern von `KERNEL_USERNAME` mit `%env` oder `%set_env`

Liste der magic- und Sparkmagic-Befehle

Verwenden Sie die folgenden Befehle, um die verfügbaren magic-Befehle aufzulisten:

- `%lsmagic` listet alle derzeit verfügbaren magic-Funktionen auf.
- `%%help` listet die derzeit verfügbaren SPARK-bezogenen magic-Funktionen auf, die vom Sparkmagic-Paket bereitgestellt werden.

`%%configure` wird verwendet, um Spark zu konfigurieren

Einer der nützlichsten Sparkmagic-Befehle ist der `%%configure`-Befehl, der die Parameter für die Sitzungserstellung konfiguriert. Mithilfe von `conf`-Einstellungen können Sie jede Spark-Konfiguration konfigurieren, die in der Konfigurationsdokumentation für Apache Spark erwähnt wird.

Example Fügen Sie eine externe JAR-Datei aus dem Maven-Repository oder Amazon S3 zu EMR Notebooks hinzu

Sie können den folgenden Ansatz verwenden, um jedem SPARK-bezogenen Kernel, der von Sparkmagic unterstützt wird, eine Abhängigkeit von einer externen JAR-Datei hinzuzufügen.

```
%%configure -f
{"conf": {
    "spark.jars.packages": "com.jsuereth:scala-arm_2.11:2.0,ml.combust.bundle:bundle-
ml_2.11:0.13.0,com.databricks:dbutils-api_2.11:0.0.3",
```

```
    "spark.jars": "s3://DOC-EXAMPLE-BUCKET/my-jar.jar"
    }
}
```

Example : Konfigurieren von Hudi

Anschließend verwenden Sie den Notebook-Editor, um Ihr EMR Notebook für die Verwendung von Hudi zu konfigurieren.

```
%%configure
{ "conf": {
     "spark.jars": "hdfs://apps/hudi/lib/hudi-spark-bundle.jar,hdfs:///apps/hudi/lib/
spark-spark-avro.jar",
     "spark.serializer": "org.apache.spark.serializer.KryoSerializer",
     "spark.sql.hive.convertMetastoreParquet":"false"
     }
}
```

`%%sh` verwenden, um `spark-submit` auszuführen

Der `%%sh` magic führt Shell-Befehle in einem Unterprozess auf einer Instance Ihres verbundenen Clusters aus. In der Regel würden Sie einen der Spark-bezogenen Kernel verwenden, um Spark-Anwendungen auf Ihrem angeschlossenen Cluster auszuführen. Wenn Sie jedoch einen Python-Kernel verwenden möchten, um eine Spark-Anwendung einzureichen, können Sie Folgendes magic verwenden und den Bucket-Namen durch Ihren Bucket-Namen in Kleinbuchstaben ersetzen.

```
%%sh
spark-submit --master yarn --deploy-mode cluster s3://DOC-EXAMPLE-BUCKET/test.py
```

In diesem Beispiel benötigt der Cluster Zugriff auf den Speicherort von `s3://DOC-EXAMPLE-BUCKET/test.py`, andernfalls schlägt der Befehl fehl.

Sie können jeden Linux-Befehl mit `%%sh` magic verwenden. Wenn Sie Spark- oder YARN-Befehle ausführen möchten, verwenden Sie eine der folgenden Optionen, um einen `emr-notebook`-Hadoop-Benutzer zu erstellen und dem Benutzer Berechtigungen zur Ausführung der Befehle zu gewähren:

- Sie können einen neuen Benutzer explizit erstellen, indem Sie die folgenden Befehle ausführen.

  ```
  hadoop fs -mkdir /user/emr-notebook
  ```

```
hadoop fs -chown emr-notebook /user/emr-notebook
```

- Sie können den Benutzerwechsel in Livy aktivieren, wodurch der Benutzer automatisch erstellt wird. Weitere Informationen finden Sie unter Aktivieren des Identitätswechsels zur Überwachung von Spark-Benutzer- und -Aufgabenaktivitäten.

Wird zur Visualisierung von **`%%display`**-Spark-Datenrahmen verwendet

Sie können den verwenden, um einen `%%display`-magic-Spark-Datenrahmen zu visualisieren. Um diese magic zu verwenden, führen Sie den folgenden Befehl aus.

```
%%display df
```

Wählen Sie, ob Sie die Ergebnisse in einem Tabellenformat anzeigen möchten, wie das folgende Bild zeigt.

Type: Table Pie Scatter Line Area Bar

year	month	total_passengers	total_trips
2012-01-01	3	26866837	16146923
2011-01-01	3	26091246	16066350
2013-01-01	3	26965079	15749228
2011-01-01	10	26287953	15707756
2009-01-01	10	26202049	15604551
2012-01-01	5	26278817	15567525
2011-01-01	5	25508952	15554868
2010-01-01	9	25533166	15540209
2010-01-01	5	26002858	15481351
2012-01-01	4	25900645	15477914

Sie können sich auch dafür entscheiden, Ihre Daten mit fünf Arten von Diagrammen zu visualisieren. Zu Ihren Optionen gehören Kreis-, Streu-, Linien-, Flächen- und Balkendiagramme.

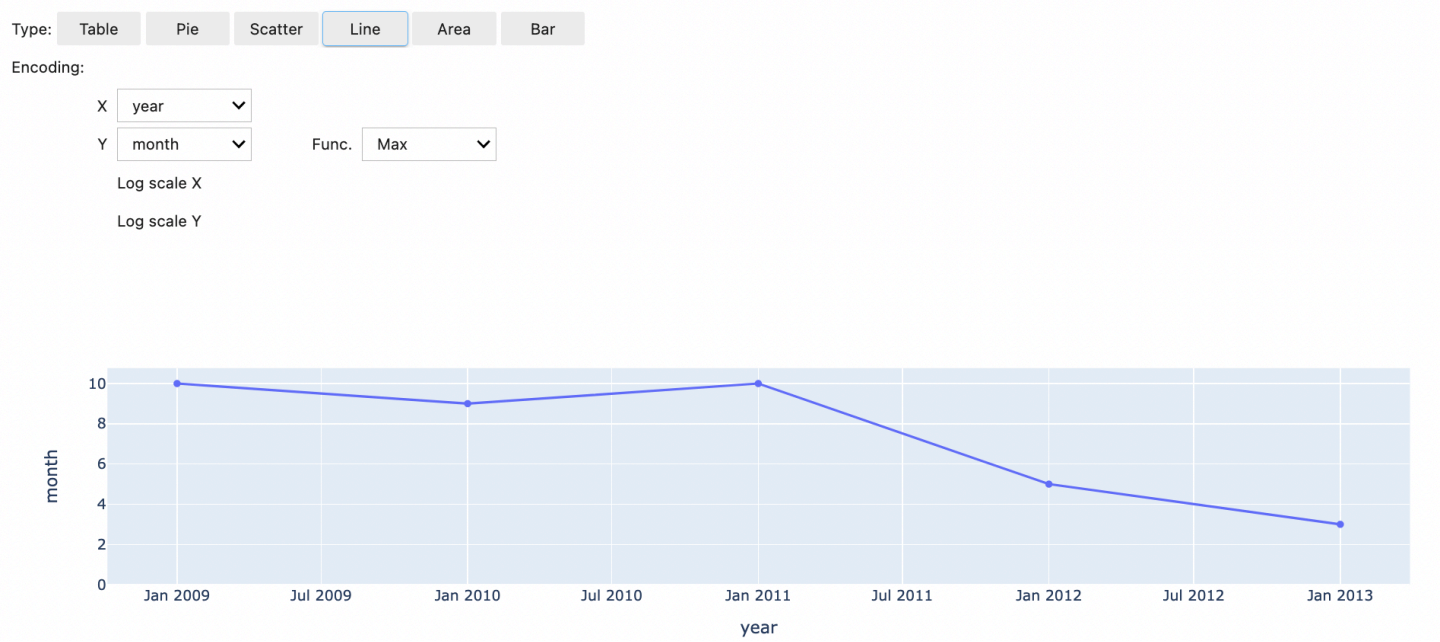

Verwenden von EMR Notebooks magic

Amazon EMR bietet die folgenden EMR Notebooks magic, die Sie mit Python3- und Spark-basierten Kerneln verwenden können:

- `%mount_workspace_dir` – Hängt Ihr Workspace-Verzeichnis in Ihren Cluster ein, sodass Sie Code aus anderen Dateien in Ihrem Workspace importieren und ausführen können

> **Note**
>
> Mit `%mount_workspace_dir` kann nur der Python-3-Kernel auf Ihre lokalen Dateisysteme zugreifen. Spark-Executoren haben mit diesem Kernel keinen Zugriff auf das bereitgestellte Verzeichnis.

- `%umount_workspace_dir` – Hängt Ihr Workspace-Verzeichnis von Ihrem Cluster ab
- `%generate_s3_download_url` – Generiert einen temporären Download-Link in Ihrer Notebook-Ausgabe für ein Amazon-S3-Objekt

Voraussetzungen

Bevor Sie EMR Notebooks magic installieren, führen Sie die folgenden Schritte aus:

- Stellen Sie sicher, dass Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil) Lesezugriff für Amazon S3 hat. Die `EMR_EC2_DefaultRole` mit der `AmazonElasticMapReduceforEC2Role` verwalteten Richtlinie erfüllt diese Anforderung. Wenn Sie eine benutzerdefinierte Rolle oder Richtlinie verwenden, stellen Sie sicher, dass sie über die erforderlichen S3-Berechtigungen verfügt.

  > **Note**
  >
  > EMR Notebooks magic werden auf einem Cluster als Notebook-Benutzer ausgeführt und verwenden das EC2-Instance-Profil, um mit Amazon S3 zu interagieren. Wenn Sie ein Workspace-Verzeichnis auf einem EMR-Cluster mounten, können alle Workspaces und EMR-Notebooks, die berechtigt sind, eine Verbindung zu diesem Cluster herzustellen, auf das bereitgestellte Verzeichnis zugreifen.
  > Verzeichnisse werden standardmäßig schreibgeschützt bereitgestellt. Während `s3fs-fuse` und `goofys` Lese-/Schreibzugriffe ermöglichen, empfehlen wir dringend, die Bereitstellungsparameter nicht zu ändern, um Verzeichnisse im Lese-/Schreibmodus bereitzustellen. Wenn Sie Schreibzugriff zulassen, werden alle am Verzeichnis vorgenommenen Änderungen in den S3-Bucket geschrieben. Um ein versehentliches Löschen oder Überschreiben zu vermeiden, können Sie die Versionsverwaltung für Ihren S3-Bucket aktivieren. Weitere Informationen finden Sie unter Verwenden der Versionsverwaltung in S3-Buckets.

- Führen Sie eines der folgenden Skripts auf Ihrem Cluster aus, um die Abhängigkeiten für EMR Notebooks magic zu installieren. Um ein Skript auszuführen, können Sie Benutzerdefinierte Bootstrap-Aktionen verwenden entweder den Anweisungen unter Befehle und Skripts auf einem Amazon-EMR-Cluster ausführen folgen, wenn Sie bereits über einen laufenden Cluster verfügen.

  Sie können wählen, welche Abhängigkeit installiert werden soll. Sowohl s3fs-fuse als auch goofys sind FUSE-Tools (Filesystem in Userspace), mit denen Sie einen Amazon-S3-Bucket als lokales Dateisystem auf einem Cluster mounten können. Das `s3fs`-Tool bietet eine ähnliche Benutzererfahrung wie POSIX. Das `goofys`-Tool ist eine gute Wahl, wenn Sie Leistung einem POSIX-kompatiblen Dateisystem vorziehen.

  ```
  #!/bin/sh

  # Install the s3fs dependency for EMR Notebooks magics sudo amazon-linux-extras
   install epel -y
  sudo yum install s3fs-fuse -y
  ```

ODER

```
#!/bin/sh

# Install the goofys dependency for EMR Notebooks magics sudo wget https://
github.com/kahing/goofys/releases/latest/download/goofys -P /usr/bin/
sudo chmod ugo+x /usr/bin/goofys
```

Installieren Sie EMR Notebooks magic

> **Note**
>
> Bei den Amazon-EMR-Versionen 6.0 bis 6.9.0 und 5.0 bis 5.36.0 unterstützen nur die `emr-notebooks-magics`-Paketversionen 0.2.0 und höher `%mount_workspace_dir` magic.

Führen Sie die folgenden Schritte aus, um EMR Notebooks magic zu installieren.

1. Führen Sie in Ihrem Notebook die folgenden Befehle aus, um das `emr-notebooks-magics`-Paket zu installieren.

   ```
   %pip install boto3 --upgrade
   %pip install botocore --upgrade
   %pip install emr-notebooks-magics --upgrade
   ```

2. Starten Sie Ihren Kernel neu, um die EMR Notebooks magic zu laden.
3. Überprüfen Sie Ihre Installation mit dem folgenden Befehl, der den Ausgabehilfetext für `%mount_workspace_dir` anzeigen sollte.

   ```
   %mount_workspace_dir?
   ```

Ein Workspace-Verzeichnis mit **`%mount_workspace_dir`** mounten

Mit `%mount_workspace_dir` magic können Sie Ihr Workspace-Verzeichnis auf Ihrem EMR-Cluster mounten, sodass Sie andere in Ihrem Verzeichnis gespeicherte Dateien, Module oder Pakete importieren und ausführen können.

Im folgenden Beispiel wird das gesamte Workspace-Verzeichnis auf einem Cluster bereitgestellt und das optionale *<--fuse-type>*-Argument angegeben, Goofys für das Mounten des Verzeichnisses zu verwenden.

```
%mount_workspace_dir . <--fuse-type goofys>
```

Um zu überprüfen, ob Ihr Workspace-Verzeichnis eingehängt ist, verwenden Sie das folgende Beispiel, um das aktuelle Arbeitsverzeichnis mit dem `ls`-Befehl anzuzeigen. Die Ausgabe sollte alle Dateien in Ihrem Workspace anzeigen.

```
%%sh
ls
```

Wenn Sie mit den Änderungen in Ihrem Workspace fertig sind, können Sie das Workspace-Verzeichnis mit dem folgenden Befehl unmounten:

> **Note**
>
> Ihr Workspace-Verzeichnis bleibt in Ihrem Cluster eingebunden, auch wenn der Workspace gestoppt oder getrennt wird. Sie müssen Ihr Workspace-Verzeichnis explizit unmounten.

```
%umount_workspace_dir
```

Herunterladen eines Amazon-S3-Objekts mit **`%generate_s3_download_url`**

Der `generate_s3_download_url`-Befehl erstellt eine vorsignierte URL für ein in Amazon S3 gespeichertes Objekt. Sie können die vorsignierte URL verwenden, um das Objekt auf Ihren lokalen Computer herunterzuladen. Sie könnten beispielsweise `generate_s3_download_url` ausführen, um das Ergebnis einer SQL-Abfrage herunterzuladen, die Ihr Code in Amazon S3 schreibt.

Die vorsignierte URL ist standardmäßig 60 Minuten lang gültig. Sie können die Ablaufzeit ändern, indem Sie eine Anzahl von Sekunden für das `--expires-in`-Kennzeichen angeben. `--expires-in 1800` erstellt beispielsweise eine URL, die 30 Minuten gültig ist.

Das folgende Beispiel generiert einen Download-Link für ein Objekt, indem der vollständige Amazon-S3-Pfad angegeben wird: *s3://EXAMPLE-DOC-BUCKET/path/to/my/object*.

```
%generate_s3_download_url s3://EXAMPLE-DOC-BUCKET/path/to/my/object
```

Um mehr über die Verwendung von `generate_s3_download_url` zu erfahren, führen Sie den folgenden Befehl aus, um den Hilfetext anzuzeigen.

```
%generate_s3_download_url?
```

Führen Sie ein Notebook im Headless-Modus mit **`%execute_notebook`**

Mit `%execute_notebook` magic können Sie ein anderes Notebook im Headless-Modus ausführen und die Ausgabe für jede Zelle anzeigen, die Sie ausgeführt haben. Diese magic erfordert zusätzliche Berechtigungen für die Instance-Rolle, die Amazon EMR und Amazon EC2 gemeinsam nutzen. Führen Sie den `%execute_notebook?`-Befehl aus, um weitere Informationen zur Gewährung zusätzlicher Berechtigungen zu erhalten.

Während eines Auftrags mit langer Laufzeit wechselt Ihr System möglicherweise aufgrund von Inaktivität in den Standbymodus oder verliert vorübergehend die Internetverbindung. Dadurch könnte die Verbindung zwischen Ihrem Browser und dem Jupyter Server unterbrochen werden. In diesem Fall verlieren Sie möglicherweise die Ausgabe der Zellen, die Sie vom Jupyter Server ausgeführt und gesendet haben.

Wenn Sie das Notebook im Headless-Modus mit `%execute_notebook` magic betreiben, erfasst EMR Notebooks die Ausgabe von den Zellen, die laufen, auch wenn das lokale Netzwerk unterbrochen wird. EMR Notebooks speichert die Ausgabe inkrementell in einem neuen Notebook mit demselben Namen wie das Notebook, das Sie ausgeführt haben. EMR Notebooks platziert das Notebook dann in einem neuen Ordner innerhalb des Workspace. Headless-Läufe finden auf demselben Cluster statt und verwenden die Servicerolle `EMR_Notebook_DefaultRole`, aber zusätzliche Argumente können die Standardwerte ändern.

Verwenden Sie den folgenden Befehl, um ein Notebook im Headless-Modus auszuführen:

```
%execute_notebook <relative-file-path>
```

Verwenden Sie den folgenden Befehl, um eine Cluster-ID und eine Servicerolle für einen Headless-Lauf anzugeben:

```
%execute_notebook <notebook_name>.ipynb --cluster-id <emr-cluster-id> --service-role
 <emr-notebook-service-role>
```

Wenn Amazon EMR und Amazon EC2 eine Instance-Rolle gemeinsam nutzen, erfordert die Rolle die folgenden zusätzlichen Berechtigungen:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:StartNotebookExecution",
                "elasticmapreduce:DescribeNotebookExecution",
                "ec2:DescribeInstances"
            ],
            "Resource": "*"
        },
        {
            "Effect": "Allow",
            "Action": [
                "iam:PassRole"
            ],
            "Resource": "arn:aws:iam::<AccoundId>:role/EMR_Notebooks_DefaultRole"
        }
    ]
}
```

> **Note**
>
> Um `%execute_notebook` magic zu verwenden, installieren Sie das `emr-notebooks-magics`-Paket, Version 0.2.3 oder höher.

Verwenden Sie mehrsprachige Notebooks mit Spark-Kerneln

Jeder Jupyter-Notebook-Kernel hat eine Standardsprache. Die Standardsprache des Spark-Kernels ist beispielsweise Scala, und die Standardsprache der PySpark-Kernel ist Python. Mit Amazon EMR 6.4.0 und höher unterstützt EMR Studio mehrsprachige Notizbücher. Das bedeutet, dass jeder Kernel in EMR Studio zusätzlich zur Standardsprache die folgenden Sprachen unterstützen kann: Python, Spark, R und Spark SQL.

Um dieses Feature zu aktivieren, geben Sie am Anfang einer beliebigen Zelle einen der folgenden magic-Befehle an.

Sprache	Befehl
Python	`%%pyspark`
Scala	`%%scalaspark`
R	`%%rspark` Wird nicht für interaktive Workloads mit EMR Serverless unterstützt.
Spark-SQL	`%%sql`

Wenn diese Befehle aufgerufen werden, führen sie die gesamte Zelle innerhalb derselben Spark-Sitzung mit dem Interpreter der entsprechenden Sprache aus.

Die `%%pyspark`-Zelle magic ermöglicht es Benutzern, PySpark-Code in alle Spark-Kernel zu schreiben.

```
%%pyspark
a = 1
```

Die `%%sql`-Zelle magic ermöglicht es Benutzern, Spark-SQL-Code in allen Spark-Kerneln auszuführen.

```
%%sql
SHOW TABLES
```

Die `%%rspark`-Zelle magic ermöglicht es Benutzern, SparkR in allen Spark-Kerneln auszuführen.

```
%%rspark
a <- 1
```

Die `%%scalaspark`-Zelle magic ermöglicht es Benutzern, Spark-Scala-Code in allen Spark-Kerneln auszuführen.

```
%%scalaspark
val a = 1
```

Teilen Sie Daten mit temporären Tabellen zwischen Sprachinterpretern

Mithilfe temporärer Tabellen können Sie Daten auch zwischen Sprachinterpretern austauschen. Das folgende Beispiel verwendet `%%pyspark` in einer Zelle, um eine temporäre Tabelle in Python zu erstellen, und verwendet `%%scalaspark` in der folgenden Zelle, um Daten aus dieser Tabelle in Scala zu lesen.

```
%%pyspark
df=spark.sql("SELECT * from nyc_top_trips_report LIMIT 20")
# create a temporary table called nyc_top_trips_report_view in python
df.createOrReplaceTempView("nyc_top_trips_report_view")
```

```
%%scalaspark
// read the temp table in scala
val df=spark.sql("SELECT * from nyc_top_trips_report_view")
df.show(5)
```

Überblick über Amazon EMR Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Sie können Amazon EMR Notebooks zusammen mit Amazon EMR-Clustern verwenden, auf denen Apache Spark ausgeführt wird, um Jupyter-Notebook- und JupyterLab-Schnittstellen über die Amazon-EMR-Konsole zu erstellen und zu öffnen. Ein EMR-Notebook ist ein „Serverless“-Notebook, mit dem Sie Abfragen und Code ausführen können. Im Gegensatz zu einem herkömmlichen Notebook werden die Inhalte eines EMR-Notebooks – die Gleichungen, Abfragen, Modelle, der Code und der erläuternde Text in Notizbuchzellen – in einem Client ausgeführt. Die Befehle werden auf einem Kernel in dem EMR-Cluster ausgeführt. Notebook-Inhalte werden auch getrennt von den Cluster-Daten in Amazon S3 gespeichert, um eine sichere Speicherung und flexible Wiederverwendung zu gewährleisten.

Sie können einen Cluster starten, ein EMR Notebook zur Analyse anfügen und dann den Cluster beenden. Sie können auch ein Notebook schließen, das an einen ausgeführten Cluster angefügt ist, und zu einem anderen Cluster wechseln. Mehrere Benutzer können gleichzeitig Notebooks an denselben Cluster anfügen und in Amazon S3 Notebook-Dateien miteinander teilen. Diese Funktionen ermöglichen Ihnen die On-Demand-Ausführung von Clustern, um Kosten zu sparen und den Zeitaufwand für die Neukonfiguration von Notebooks für verschiedene Cluster und Datensätze zu reduzieren.

Sie können ein EMR-Notebook auch programmgesteuert mithilfe der Amazon-EMR-API ausführen, ohne mit der Amazon-EMR-Konsole interagieren zu müssen („Headless Execution“). Sie müssen eine Zelle in das EMR-Notebook aufnehmen, die über ein Parameter-Tag verfügt. Diese Zelle ermöglicht es einem Skript, neue Eingabewerte an das Notizbuch zu übergeben. Parametrisierte Notizbücher können mit unterschiedlichen Eingabewerten wiederverwendet werden. Es ist nicht erforderlich, Kopien desselben Notebooks zu erstellen, um es mit neuen Eingabewerten zu

bearbeiten und auszuführen. Amazon EMR erstellt und speichert das Ausgabe-Notebook auf S3 für jeden Lauf des parametrisierten Notebooks. API-Codebeispiele für EMR-Notebooks finden Sie unter Beispielbefehle zum programmgesteuerten Ausführen von EMR-Notebooks.

> **Important**
>
> Die EMR-Notebooks-Funktion unterstützt Cluster, die Amazon-EMR-Versionen 5.18.0 und höher verwenden. Wir empfehlen, EMR Notebooks mit Clustern zu verwenden, die die neueste Version von Amazon EMR oder mindestens 5.30.0, 5.32.0 oder 6.2.0 verwenden. Mit diesen Versionen werden Jupyter-Kernel auf dem angefügten Cluster und nicht auf einer Jupyter-Instance ausgeführt werden. Dies verbessert die Leistung und erweitert Ihre Möglichkeiten von Kerneln und Bibliotheken zu verbessern. Weitere Informationen finden Sie unter Unterschiede in den Funktionalitäten nach Cluster-Release-Version.

Es fallen Gebühren für Amazon-S3-Speicher und für Amazon-EMR-Cluster an.

Amazon EMR Notebooks sind in der neuen Konsole als Amazon EMR Studio Workspaces verfügbar

Der Übergang von EMR Notebooks zu Workspaces

In der neuen Amazon-EMR-Konsole haben wir EMR Notebooks mit Amazon EMR Studio Workspaces zu einem einzigen Erlebnis zusammengeführt. Wenn Sie ein EMR Studio verwenden, können Sie verschiedene Workspaces erstellen und konfigurieren, um Notebooks zu organisieren und auszuführen. Wenn Sie Amazon-EMR-Notebooks in der alten Konsole hatten, sind sie in der neuen Konsole als EMR Studio Workspaces verfügbar.

Amazon EMR hat diese neuen EMR Studio Workspaces für Sie erstellt. Die Anzahl der Studios, die wir erstellt haben, entspricht der Anzahl der verschiedenen VPCs, die Sie von EMR Notebooks aus verwenden. Wenn Sie beispielsweise von EMR Notebooks aus eine Verbindung zu EMR-Clustern in zwei verschiedenen VPCs herstellen, haben wir zwei neue EMR Studios erstellt. Ihre Notebooks werden auf die neuen Studios verteilt.

> **Important**
>
> Wir haben die Option zum Erstellen neuer Notizbücher in der alten Amazon-EMR-Konsole deaktiviert. Verwenden Sie stattdessen Workspace erstellen in der neuen Amazon-EMR-Konsole.

Weitere Informationen zu Amazon EMR Studio WorkSpaces finden Sie unter Informationen über Workspace-Grundlagen. Eine konzeptionelle Übersicht über EMR Studio finden Sie unter Workspaces auf der Seite Wie Amazon EMR Studio funktioniert.

Was müssen Sie als Nächstes tun?

Sie können Ihre vorhandenen Notebooks zwar weiterhin in der alten Konsole verwenden, wir empfehlen jedoch, stattdessen Amazon EMR Studio Workspaces in der neuen Konsole zu verwenden. Sie müssen zusätzliche Rollenberechtigungen konfigurieren, um die Funktionen in EMR Studio zu aktivieren, die in EMR-Notebooks nicht verfügbar sind.

> **Note**
>
> Um bestehende EMR-Notebooks als EMR Studio Workspaces anzuzeigen und neue Workspaces zu erstellen, müssen Benutzer mindestens über `elasticmapreduce:ListStudios`- und `elasticmapreduce:CreateStudioPresignedUrl`-Berechtigungen für ihre Rollen verfügen. Um auf alle Features von EMR Studio zuzugreifen, finden Sie unter Aktivierung der Feature von EMR Studio für Benutzer von EMR-Notebooks eine vollständige Liste der zusätzlichen Berechtigungen, die Benutzer von EMR-Notebooks benötigen.

Verbesserte Funktionen in EMR Studio, die über EMR-Notebooks hinausgehen

Mit Amazon EMR Studio können Sie die folgenden Funktionen einrichten und verwenden, die mit EMR-Notebooks nicht verfügbar sind:

- Durchsuchen und Verbinden mit EMR-Clustern aus Jupyterlab heraus
- Durchsuchen und Anhängen an virtuelle EMR-Notebook-Cluster aus Jupyterlab heraus

- Verbindung zu Git-Repos aus Jupyterlab heraus
- Zusammenarbeit mit anderen Mitgliedern Ihres Teams beim Schreiben und Ausführen von Notebook-Code
- Durchsuchen von Daten mit SQL Explorer
- Bereitstellung von EMR-Clustern mit Service Catalog

Eine vollständige Liste der Funktionen von Amazon EMR Studio finden Sie unter Hauptfeatures von EMR Studio.

Aktivierung der Feature von EMR Studio für Benutzer von EMR-Notebooks

Die neuen EMR Studios, die wir im Rahmen dieser Zusammenführung erstellen werden, verwenden die bestehende `EMR_Notebooks_DefaultRole`-IAM-Rolle als EMR-Studio-Servicerolle.

Benutzer, die von EMR-Notebooks zu EMR Studio wechseln und die zusätzlichen Funktionen von EMR Studio nutzen möchten, benötigen mehrere neue Rollenberechtigungen. Fügen Sie den Rollen Ihrer EMR-Notebooks-Benutzer, die EMR Studio verwenden möchten, die folgenden Berechtigungen hinzu.

> **Note**
>
> Um bestehende EMR-Notebooks als EMR Studio Workspaces anzuzeigen und neue Workspaces zu erstellen, müssen Benutzer mindestens über `elasticmapreduce:ListStudios`- und `elasticmapreduce:CreateStudioPresignedUrl`-Berechtigungen für ihre Rollen verfügen. Um alle Features von EMR Studio zu verwenden, fügen Sie alle unten aufgeführten Berechtigungen hinzu. Admin-Benutzer benötigen außerdem die Erlaubnis, ein EMR Studio zu erstellen und zu verwalten. Weitere Informationen finden Sie unter Administratorberechtigungen zum Erstellen und Verwalten eines EMR Studios.

```
"elasticmapreduce:DescribeStudio",
"elasticmapreduce:ListStudios",
"elasticmapreduce:CreateStudioPresignedUrl",
"elasticmapreduce:UpdateEditor",
"elasticmapreduce:PutWorkspaceAccess",
"elasticmapreduce:DeleteWorkspaceAccess",
"elasticmapreduce:ListWorkspaceAccessIdentities",
```

```
"emr-containers:ListVirtualClusters",
"emr-containers:DescribeVirtualCluster",
"emr-containers:ListManagedEndpoints",
"emr-containers:DescribeManagedEndpoint",
"emr-containers:CreateAccessTokenForManagedEndpoint",
"emr-containers:ListJobRuns",
"emr-containers:DescribeJobRun",
"servicecatalog:SearchProducts",
"servicecatalog:DescribeProduct",
"servicecatalog:DescribeProductView",
"servicecatalog:DescribeProvisioningParameters",
"servicecatalog:ProvisionProduct",
"servicecatalog:UpdateProvisionedProduct",
"servicecatalog:ListProvisioningArtifacts",
"servicecatalog:DescribeRecord",
"servicecatalog:ListLaunchPaths",
"cloudformation:DescribeStackResources"
```

Die folgenden Berechtigungen sind ebenfalls erforderlich, um die Funktionen für die Zusammenarbeit in EMR Studio zu nutzen, waren jedoch für EMR-Notebooks nicht erforderlich.

```
"sso-directory:SearchUsers",
"iam:GetUser",
"iam:GetRole",
"iam:ListUsers",
"iam:ListRoles",
"sso:GetManagedApplicationInstance"
```

Überlegungen zur Verwendung von EMR-Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Berücksichtigen Sie beim Erstellen von Clustern und Entwickeln von Lösungen mit EMR-Notebooks die folgenden Voraussetzungen.

Cluster-Voraussetzungen

- Amazon EMR Block Public Access aktivieren – Durch den eingehenden Zugriff auf einen Cluster können Cluster-Benutzer Notebook-Kernel ausführen. Stellen Sie sicher, dass nur autorisierte Benutzer auf den Cluster zugreifen können. Es wird dringend empfohlen, den öffentlichen Zugriff zu blockieren und eingehenden SSH-Datenverkehr auf vertrauenswürdige Quellen zu beschränken. Weitere Informationen finden Sie unter Verwenden von Amazon EMR Block Public Access und Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.
- Kompatiblen Cluster verwenden – Ein Cluster, der an ein Notebook angefügt ist, muss die folgenden Voraussetzungen erfüllen:
  - Es werden nur Cluster, die mit Amazon EMR erstellt wurden, unterstützt. Sie können innerhalb von Amazon EMR unabhängig einen Cluster erstellen und dann ein EMR-Notebook anfügen. Sie können einen kompatiblen Cluster auch erstellen, wenn Sie ein EMR-Notebook erstellen.
  - Es werden nur Cluster, die mit Amazon EMR Version 5.18.0 oder höher erstellt wurden, unterstützt. Siehe the section called “Unterschiede in den Funktionalitäten nach Cluster-Release-Version”.
  - Cluster, die mithilfe von Amazon-EC2-Instances mit AMD EPYC-Prozessoren erstellt wurden – zum Beispiel die Instance-Typen m5a.* und r5a.* – werden nicht unterstützt.
  - EMR-Notebooks funktioniert nur mit Clustern, die mit der `VisibleToAllUsers`-Einstellung auf `true` erstellt wurden. `VisibleToAllUsers` ist standardmäßig `true`.
  - Der Cluster muss innerhalb einer EC2-VPC gestartet werden. Öffentliche und private Subnetze werden unterstützt. Die EC2-Classic-Plattform wird nicht unterstützt.
  - Hadoop, Spark und Livy müssen auf dem Cluster installiert sein. Andere Anwendungen können installiert werden, aber EMR Notebook unterstützt derzeit nur Spark-Cluster.

    > **Important**
    >
    > Für Amazon-EMR-Versionen 5.32.0 und höher oder 6.2.0 und höher muss auf Ihrem Cluster auch die Jupyter Enterprise Gateway-Anwendung ausgeführt werden, um mit EMR-Notebooks zu funktionieren.

  - Cluster mit Kerberos-Authentifizierung werden nicht unterstützt.

- Mit AWS Lake Formation integrierte Cluster unterstützen nur die Installation von Notebook-Bibliotheken. Die Installation von Kerneln und Bibliotheken auf dem Cluster wird nicht unterstützt.
- Cluster mit mehreren Primärknoten werden nicht unterstützt.
- Cluster, die Amazon-EC2-Instances verwenden, die auf AWS-Graviton2 basieren, werden nicht unterstützt.

Unterschiede in den Funktionalitäten nach Cluster-Release-Version

Wir empfehlen dringend, EMR-Notebooks mit Clustern zu verwenden, die mit den Amazon-EMR-Versionen 5.30.0, 5.32.0 oder höher oder 6.2.0 oder höher erstellt wurden. Mit diesen Versionen führt EMR Notebooks-Kernel auf dem angeschlossenen Amazon-EMR-Cluster aus. Kernel und Bibliotheken können direkt auf dem Cluster-Primärknoten installiert werden. Die Verwendung von EMR-Notebooks mit diesen Cluster-Versionen hat folgende Vorteile:

- Verbesserte Leistung – Notebook-Kernel werden auf Clustern mit von Ihnen ausgewählten EC2-Instance-Typen ausgeführt. Frühere Versionen führen Kernel auf einer spezialisierten Instance aus, die nicht in der Größe geändert, auf die nicht zugegriffen und die nicht angepasst werden kann.
- Möglichkeit zum Hinzufügen und Anpassen von Kerneln – Sie können eine Verbindung zum Cluster herstellen, um Kernel-Pakete mit `conda` und `pip` zu installieren. Darüber hinaus wird die `pip`-Installation mithilfe von Terminal-Befehlen innerhalb von Notebook-Zellen unterstützt. In früheren Versionen waren nur vorinstallierte Kernel verfügbar (Python, PySpark, Spark und SparkR). Weitere Informationen finden Sie unter Installieren von Kernels und Python-Bibliotheken auf einem Cluster-Primärknoten.
- Möglichkeit, Python-Bibliotheken zu installieren – Sie können Python-Bibliotheken mit `conda` und `pip` auf dem Cluster-Primärknoten installieren. Wir empfehlen die Verwendung von `conda`. Bei früheren Versionen werden nur dedizierte Notebook-Bibliotheken für PySpark unterstützt.

Unterstützte EMR-Notebooks-Features nach Cluster-Version

Cluster-Version	Dedizierte Notebook-Bibliotheken für PySpark	Kernel-Installation auf dem Cluster	Installation der Python-Bibliothek auf Primärknoten
Früher als 5.18.0	EMR Notebooks werden nicht unterstützt		
5.18.0–5.25.0	Nein	Nein	Nein

Cluster-Version	Dedizierte Notebook-Bibliotheken für PySpark	Kernel-Installation auf dem Cluster	Installation der Python-Bibliothek auf Primärknoten
5.26.0–5-29.0	Ja	Nein	Nein
5.30.0	Ja	Ja	Ja
6.0.0	Nein	Nein	Nein
5.32.0 und höher und 6.2.0 und höher	Ja	Ja	Ja

Limits für gleichzeitig angefügte EMR-Notebooks

Wenn Sie einen Cluster erstellen, der Notebooks unterstützt, beachten Sie den EC2-Instance-Typ des Cluster-Primärknotens. Die Anzahl der Notebooks, die gleichzeitig Code und Abfragen auf dem Cluster gleichzeitig ausführen können, wird durch Speicherbeschränkungen dieser EC2-Instance bestimmt.

EC2-Instance-Typ des Primärknotens	Anzahl der EMR Notebooks
*.medium	2
*.large	4
*.xlarge	8
*.2xlarge	16
*.4xlarge	24
*.8xlarge	24
*.16xlarge	24

Jupyter Notebook und Python-Versionen

EMR-Notebooks führt Jupyter Notebook Version 6.0.2 und Python 3.6.5 aus, unabhängig von der Amazon-EMR-Version des angefügten Clusters.

Sicherheitsüberlegungen

Verwenden verschlüsselter S3-Standorte

Wenn Sie einen verschlüsselten Speicherort in Amazon S3 zum Speichern von Notebook-Dateien angeben, müssen Sie die Servicerolle für EMR Notebooks als Schlüsselbenutzer einrichten. Die Standard-Servicerolle ist `EMR_Notebooks_DefaultRole`. Wenn Sie einen AWS KMS-Schlüssel für die Verschlüsselung verwenden, finden Sie unter Verwenden von Schlüsselrichtlinien in AWS KMS im AWS Key Management Service-Entwicklerhandbuch unter Support-Artikel zum Hinzufügen von Schlüsselbenutzern weitere Informationen.

Erstellen eines Notebook

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Sie erstellen ein EMR-Notebook mit der alten Amazon-EMR-Konsole. Das Erstellen von Notebooks mithilfe AWS CLI oder der Amazon-EMR-API wird nicht unterstützt.

Erstellen eines EMR-Notebooks

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/.
2. Wählen Sie Notebooks, Create notebook (Notebook erstellen).
3. Geben Sie einen Notebook name (Notebook-Namen) und optional eine Notebook description (Notebook-Beschreibung) ein.

4. Wenn Sie einen aktiven Cluster haben, den Sie an das Notebook anfügen möchten, behalten Sie die Standardeinstellung Vorhandenen Cluster auswählen bei und wählen Wählen aus. Wählen Sie anschließend einen Cluster aus der Liste und Cluster wählen aus. Informationen zu den Clusteranforderungen für EMR Notebooks finden Sie unter Überlegungen zur Verwendung von EMR-Notebooks.

   —oder—

   Wählen Sie Create a cluster (Cluster erstellen), geben Sie einen Clusternamen ein und wählen Sie Optionen gemäß den folgenden Richtlinien aus. Der Cluster wird unter Verwendung von On-Demand-Instances in der Standard-VPC für das Konto erstellt.

Einstellung	Beschreibung
Cluster name	Der Anzeigename, der zum Identifizieren des Clusters verwendet wird.
Veröffentlichung	Kann nicht geändert werden. Standardmäßig wird die neueste Amazon-EMR-Version (5.36.1) verwendet.
Anwendungen	Kann nicht geändert werden. Listet die Anwendungen auf, die auf dem Cluster installiert sind.
Instance	Geben Sie die Anzahl der Instances ein und wählen Sie den EC2-Instance-Typ aus. Eine Instance wird für den Primärknoten verwendet. Der Rest wird für Core-Knoten verwendet. Der Instance-Typ bestimmt die Anzahl der Notebooks, die gleichzeitig an den Cluster angefügt sein können. Weitere Informationen finden Sie unter Limits für gleichzeitig angefügte EMR-Notebooks.

Einstellung	Beschreibung
EMR role (EMR-Rolle)	Behalten Sie die Standardeinstellung bei, oder wählen Sie den Link aus, um eine benutzerdefinierte Servicerolle für Amazon EMR anzugeben. Weitere Informationen finden Sie unter Servicerolle für Amazon EMR (EMR-Rolle).
EC2 instance profile (EC2-Instance-Profile)	Behalten Sie die Standardeinstellung bei, oder wählen Sie den Link aus, um eine benutzerdefinierte Servicerolle für EC2-Instances anzugeben. Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).
EC2 key pair	Wählen Sie ein EC2-Schlüsselpaar, um eine Verbindung zu Cluster-Instances herstellen zu können. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.
Automatische Beendigung	Automatische Beendigung wird für Amazon-EMR-Versionen 5.30.0 und 6.1.0 und höher unterstützt. Aktivieren Sie das Kontrollkästchen, um die automatische Beendigung zu aktivieren, und geben Sie dann die Leerlaufzeit an, nach der der Cluster automatisch heruntergefahren werden soll. Weitere Informationen finden Sie unter Verwenden einer Richtlinie zur automatischen Beendigung.

5. Wählen Sie unter Security groups (Sicherheitsgruppen) die Option Use default security groups (Standardsicherheitsgruppen verwenden). Alternativ können Sie Choose security groups (Sicherheitsgruppen auswählen) wählen und dann benutzerdefinierte Sicherheitsgruppen auswählen, die in der VPC des Clusters verfügbar sind. Sie wählen eine Sicherheitsgruppe für

die primäre Instance und eine andere für den Notebook-Service aus. Weitere Informationen finden Sie unter the section called “Sicherheitsgruppe für EMR Notebooks”.

6. Behalten Sie für AWS-Servicerolle die Standardeinstellung bei oder wählen Sie eine benutzerdefinierte Rolle aus der Liste aus. Die Client-Instance für das Notebook verwendet diese Rolle. Weitere Informationen finden Sie unter Servicerolle für EMR Notebooks.
7. Wählen Sie unter Notebook-Speicherort den Speicherort für die Notebook-Datei in Amazon S3 aus oder geben Sie einen eigenen Speicherort an. Wenn der Bucket und Ordner nicht vorhanden sind, werden sie von Amazon EMR erstellt.

   Amazon EMR erstellt einen Ordner mit der Notebook-ID als Ordnernamen und speichert das Notebook in einer Datei mit dem Namen *NotebookName*`.ipynb`. Wenn Sie zum Beispiel den Amazon-S3-Speicherort `s3://MyBucket/MyNotebooks` für ein Notebook mit dem Namen `MyFirstEMRManagedNotebook` angeben, wird die Notebook-Datei unter `s3://MyBucket/MyNotebooks/`*NotebookID*`/MyFirstEMRManagedNotebook.ipynb` gespeichert.

   Wenn Sie einen verschlüsselten Speicherort in Amazon S3 angeben, müssen Sie Servicerolle für EMR Notebooks als Schlüsselbenutzer einrichten. Die Standard-Servicerolle ist `EMR_Notebooks_DefaultRole`. Wenn Sie einen AWS KMS-Schlüssel für die Verschlüsselung verwenden, finden Sie unter Verwenden von Schlüsselrichtlinien in AWS KMS im AWS Key Management Service-Entwicklerhandbuch unter Support-Artikel zum Hinzufügen von Schlüsselbenutzern weitere Informationen.
8. (Optional) Wenn Sie ein Git-basiertes Repository zu Amazon EMR hinzugefügt haben, das Sie mit diesem Notebook verknüpfen möchten, wählen Sie Git-Repository, wählen Sie auf Repository auswählen und wählen Sie dann ein Repository aus der Liste aus. Weitere Informationen finden Sie unter Verknüpfen von Git-basierten Repositorys mit EMR Notebooks.
9. Wählen Sie optional Tags und fügen Sie dann alle zusätzlichen Schlüssel-Wert-Tags für das Notebook hinzu.

   > **Important**
   >
   > Für den Zugriff wird ein Standard-Tag verwendet, bei dem die Schlüsselzeichenfolge auf `creatorUserID` und der Wert auf Ihre IAM-Benutzer-ID festgelegt ist. Wir empfehlen, dieses Tag nicht zu ändern oder zu entfernen, da es für die Zugriffssteuerung verwendet werden kann. Weitere Informationen finden Sie unter Verwenden Sie Cluster- und Notebook-Tags mit IAM-Richtlinien für die Zugriffskontrolle.
10. Klicken Sie auf Create Notebook (Notebook erstellen).

Arbeiten mit EMR-Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Nach dem Erstellen eines EMR-Notebooks dauert es einige Zeit, bis das Notebook gestartet wird. Der Status in der Liste Notebooks zeigt Starting (Wird gestartet) an. Sie können ein Notebook öffnen, wenn der Status Ready (Bereit) lautet. Es kann etwas länger dauern, bis ein Notebook den Status Ready (Bereit) anzeigt, wenn Sie einen Cluster mit diesem zusammen erstellt haben.

> **Tip**
>
> Aktualisieren Sie Ihren Browser oder wählen Sie das Aktualisierungssymbol über der Liste „Notebooks“, um den Notebookstatus zu aktualisieren.

Grundlegendes zum Notebook-Status

Ein EMR-Notebook kann unter Status in der Liste Notebooks die folgenden Optionen anzeigen.

Status	Bedeutung
Bereit	Sie können das Notebook mithilfe des Notebook-Editors öffnen. Wenn ein Notebook den Status Ready (Bereit) aufweist, können Sie es anhalten oder löschen. Um Cluster zu wechseln, müssen Sie das Notebook zuerst anhalten. Wenn ein Notebook mit dem Status

Status	Bedeutung
	Ready (Bereit) für einen langen Zeitraum inaktiv ist, wird es automatisch angehalten.
Wird gestartet	Das Notebook wird erstellt und an den Cluster angehängt. Während ein Notebook gestartet wird, können Sie den Notebook-Editor nicht öffnen, anhalten oder löschen und Cluster nicht wechseln.
Ausstehend	Das Notebook wurde erstellt und wartet darauf, dass die Integration mit dem Cluster abgeschlossen ist. Der Cluster stellt möglicherweise weiterhin Ressourcen bereit oder reagiert auf andere Anfragen. Sie können den Notebook-Editor mit dem Notebook im lokalen Modus öffnen. Code, der von Cluster-Prozessen abhängt, wird nicht ausgeführt und schlägt fehl.
Wird angehalten	Das Notebook wird heruntergefahren oder der Cluster, an den das Notebook angehängt ist, wird beendet. Während ein Notebook beendet wird, können Sie den Notebook-Editor nicht öffnen, anhalten oder löschen und Cluster nicht wechseln.
Angehalten	Das Notebook wurde heruntergefahren. Sie können das Notebook auf demselben Cluster starten, solange der Cluster noch ausgeführt wird. Sie können Cluster wechseln und den Cluster löschen.
Wird gelöscht	Der Cluster wird aus der Liste der verfügbaren Cluster entfernt. Die Notebook-Datei *NotebookName* `.ipynb` verbleibt in Amazon S3 und es fallen weiterhin Gebühren für die Speicherung an.

Arbeiten mit dem Notebook-Editor

Ein Vorteil der Verwendung eines EMR-Notebooks ist, dass Sie das Notebook in Jupyter oder JupyterLab direkt von der Konsole aus starten können.

In EMR-Notebooks ist der Notebook-Editor, den Sie über die Amazon-EMR-Konsole aufrufen, der gewohnte Open-Source-Jupyter-Notebook-Editor oder JupyterLab. Da der Notebook-Editor innerhalb der Amazon-EMR-Konsole gestartet wird, ist es effizienter, den Zugriff hierüber zu konfigurieren als mit einem auf einem Amazon-EMR-Cluster gehosteten Notebook. Sie müssen den Client eines Benutzers nicht so konfigurieren, dass er über Webzugriff über SSH, Sicherheitsgruppenregeln und Proxy-Konfigurationen verfügt. Wenn ein Benutzer über ausreichende Berechtigungen verfügt, kann er den Notebook-Editor einfach innerhalb der Amazon-EMR-Konsole öffnen.

Ein EMR-Notebook kann immer nur von einem Benutzer aus mit Amazon EMR geöffnet sein. Wenn ein anderer Benutzer versucht, ein bereits geöffnetes EMR-Notebook zu öffnen, tritt ein Fehler auf.

> **Important**
>
> Amazon EMR erstellt eine eindeutige vorsignierte URL für jede Notebook-Editorsitzung, die nur für kurze Zeit gültig ist. Wir empfehlen, dass Sie die Notebook-Editor-URL nicht freigeben. Dies stellt ein Sicherheitsrisiko dar, da Empfänger der URL Ihre Berechtigungen zur Bearbeitung des Notebooks übernehmen und Notebook-Code für die Lebensdauer der URL ausführen. Wenn andere Benutzer Zugriff auf ein Notebook benötigen, legen Sie über Berechtigungsrichtlinien Berechtigungen für deren Benutzer fest und stellen Sie sicher, dass die Servicerolle für EMR-Notebooks Zugriff auf den Amazon-S3-Speicherort hat. Weitere Informationen finden Sie unter the section called “Sicherheit” und Servicerolle für EMR Notebooks.

So öffnen Sie den Notebook-Editor für ein EMR-Notebook

1. Wählen Sie einen Notebook mit dem Status Ready (Bereit) oder Pending (Ausstehend) in der Liste Notebooks aus.
2. Wählen Sie Open in JupyterLab (In JupyterLab öffnen) oder Open in Jupyter (In Jupyter öffnen) aus.

   Eine neue Browser-Registerkarte zum JupyterLab oder Jupyter-Notebook-Editor wird geöffnet.

3. Wählen Sie im Menü Kernel die Option Change Kernel (Kernel ändern) und wählen Sie dann den Kernel für Ihre Programmiersprache aus.

   Sie können jetzt Code innerhalb des Notebook-Editors schreiben und ausführen.

Speichern der Inhalte eines Notebooks

Wenn Sie im Notebook-Editor arbeiten, werden die Inhalte von Notebook-Zellen und Ausgaben automatisch regelmäßig in der Notebook-Datei in Amazon S3 gespeichert. Ein Notebook ohne Änderungen seit der letzten Bearbeitung von Zellen zeigt den Eintrag (autosaved) (automatisch gespeichert) neben dem Notebook-Namen im Editor an. Wenn Änderungen noch nicht gespeichert wurden, wird unsaved changes (nicht gespeicherte Änderungen) angezeigt.

Sie können ein Notebook manuell speichern. Wählen Sie im Menü Datei die Option Speichern und Checkpoint oder drücken Sie STRG+S. Dadurch wird eine Datei mit dem Namen *NotebookName*`.ipynb` in einem Checkpoints-Ordner innerhalb des Notebookordners in Amazon S3 erstellt. Zum Beispiel `s3://`*MyBucket*`/`*MyNotebookFolder*`/`*NotebookID*`/checkpoints/`*NotebookName*`.ipynb`. Nur die aktuelle Prüfpunktdatei wird an diesem Speicherort gespeichert.

Wechseln von Clustern

Sie können den Cluster wechseln, an den ein EMR-Notebook angehängt ist, ohne die Inhalte des Notebooks selbst zu ändern. Sie können Cluster nur für Notebooks mit dem Status Stopped (Angehalten) wechseln.

So ändern Sie den Cluster eines EMR-Notebooks

1. Wenn das Notebook, das Sie wechseln möchten, ausgeführt wird, wählen Sie dieses in der Liste Notebooks und anschließend Stop (Anhalten) aus.
2. Wenn das Notebook den Status Stopped (Angehalten) aufweist, wählen Sie das Notebook in der Liste Notebooks und anschließend View details (Details anzeigen) aus.
3. Wählen Sie Change cluster (Cluster wechseln).
4. Wenn Sie einen aktiven Cluster haben, auf dem Hadoop, Spark und Livy ausgeführt werden und an den Sie das Notebook anfügen möchten, behalten Sie die Standardeinstellung bei und wählen Sie einen Cluster aus der Liste aus. Es werden nur Cluster aufgeführt, die diesen Anforderungen entsprechen.

–oder –

Wählen Sie Create a cluster (Cluster erstellen) und anschließend die Clusteroptionen. Weitere Informationen finden Sie unter Cluster-Voraussetzungen.

5. Wählen Sie eine Option für Security groups (Sicherheitsgruppen) und anschließend Change cluster and start notebook (Cluster wechseln und Notebook starten).

Löschen von Notebooks und Notebook-Dateien

Wenn Sie ein EMR-Notebook mithilfe der Amazon-EMR-Konsole löschen, löschen Sie das Notebook aus der Liste der verfügbaren Notebooks. Notebook-Dateien verbleiben jedoch in Amazon S3 und es fallen weiterhin Speicherkosten an.

So löschen Sie ein Notizbuch und entfernen die zugehörigen Dateien

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/.
2. Wählen Sie Notebooks, wählen Sie Ihr Notebook aus der Liste und anschließend View details (Details anzeigen) aus.
3. Wählen Sie das Ordnersymbol neben Notebook location (Notebook-Speicherort) und kopieren Sie die URL mit dem Muster `s3://MyNotebookLocationPath/NotebookID/`.
4. Wählen Sie Delete (Löschen).

   Das Notebook wird aus der Liste entfernt und die Notebook-Details können nicht mehr angezeigt werden.
5. Befolgen Sie die Anweisungen für Wie kann ich Ordner aus einem S3-Bucket löschen? im Benutzerhandbuch für Amazon Simple Storage Service. Navigieren Sie zum Bucket und Ordner aus Schritt 3.

   –oder –

   Wenn Sie die AWS CLI installiert haben, öffnen Sie eine Eingabeaufforderung und geben Sie den Befehl am Ende dieses Absatzes ein. Ersetzen Sie den Amazon-S3-Speicherort mit dem oben kopierten Speicherort. Stellen Sie sicher, dass die AWS CLI mit den Zugriffsschlüsseln eines Benutzers mit Berechtigungen zum Löschen des Amazon-S3-Speicherorts konfiguriert ist. Weitere Informationen finden Sie unter Konfigurieren der AWS CLI im AWS Command Line Interface-Leitfaden.

```
aws s3 rm s3://MyNotebookLocationPath/NotebookID
```

Freigeben von Notebook-Dateien

Jedes EMR-Notebook wird in Amazon S3 als eine Datei mit dem Namen *NotebookName*.ipynb gespeichert. Solange eine Notebook-Datei mit derselben Version von Jupyter Notebook kompatibel ist, auf der EMR-Notebooks basiert, können Sie das Notizbuch als EMR-Notebook öffnen.

Die einfachste Möglichkeit, eine Notebook-Datei eines anderen Benutzers zu öffnen, besteht darin, die *.ipynb-Datei von dem betreffenden Benutzer in Ihrem lokalen Dateisystem zu speichern und dann die Upload-Funktion im Jupyter- bzw. JupyterLab-Editor zu verwenden.

Mithilfe dieses Verfahrens können Sie von anderen Personen freigegebene EMR-Notebooks und in der Jupyter-Community freigegebene Notebooks verwenden oder aus der Konsole gelöschte Notebooks wiederherstellen, sofern die Notebook-Datei noch vorhanden ist.

So verwenden Sie eine andere Notebook-Datei als Basis für ein EMR-Notebook

1. Bevor Sie fortfahren, schließen Sie den Notebook-Editor für alle Notebooks, mit denen Sie arbeiten werden, und halten Sie dann das Notebook an, wenn es sich um ein EMR-Notebook handelt.
2. Erstellen Sie ein EMR-Notebook und geben Sie einen Namen dafür ein. Der Name, den Sie für das Notebook eingeben, wird der Name der Datei sein, die Sie ersetzen müssen. Der neue Dateiname muss genau mit diesem Dateinamen übereinstimmen.
3. Notieren Sie sich den Speicherort in Amazon S3, den Sie für das Notebook wählen. Die Datei, die Sie ersetzen, befindet sich in einem Ordner mit einem Pfad und Dateinamen, die dem folgenden Muster entsprechen: s3://*MyNotebookLocation*/*NotebookID*/*MyNotebookName*.ipynb.
4. Halten Sie das Notebook an.
5. Ersetzen Sie die alte Notebook-Datei im Amazon-S3-Speicherort mit der neuen Datei, die denselben Namen trägt.

   Der folgende AWS CLI-Befehl für Amazon S3 ersetzt eine auf einem lokalen Computer gespeicherte Datei mit dem Namen SharedNotebook.ipynb durch ein EMR-Notebook mit dem Namen MyNotebook und der ID e-12A3BCDEFJHIJKLMNO45PQRST, die mit MyBucket/MyNotebooksFolder in Amazon S3 erstellt wurde. Weitere Informationen zur Verwendung

der Amazon S3 Konsole zum Kopieren und Ersetzen von Dateien finden Sie unter Objekte hochladen, herunterladen und verwalten im Benutzerhandbuch für Amazon Simple Storage Service..

```
aws s3 cp SharedNotebook.ipynb s3://MyBucket/
MyNotebooksFolder/-12A3BCDEFJHIJKLMNO45PQRST/MyNotebook.ipynb
```

Beispielbefehle zum programmgesteuerten Ausführen von EMR-Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Übersicht

Sie können EMR-Notebooks mit Ausführungs-APIs über ein Skript oder über die Befehlszeile ausführen. Wenn Sie EMR-Notebook-Ausführungen außerhalb der AWS-Konsole starten, stoppen, auflisten und beschreiben, können Sie ein EMR-Notebook programmgesteuert steuern. Sie können verschiedene Parameterwerte an ein Notebook mit einer parametrisierten Notebookzelle übergeben. Dadurch entfällt die Notwendigkeit, für jeden neuen Satz von Parameterwerten eine Kopie des Notebooks zu erstellen. Weitere Informationen finden Sie unter API-Aktionen in Amazon EMR.

Sie können EMR-Notebook-Ausführungen mit Amazon CloudWatch Events und AWS Lambda stapeln. Weitere Informationen finden Sie unter Verwendung von AWS Lambda mit Amazon CloudWatch Events.

Rollenberechtigungen für die programmatische Ausführung

Um die programmgesteuerte Ausführung mit EMR Notebooks zu verwenden, müssen Sie Benutzerberechtigungen mit den folgenden Richtlinien konfigurieren:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowExecutionActions",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:StartNotebookExecution",
                "elasticmapreduce:DescribeNotebookExecution",
                "elasticmapreduce:ListNotebookExecutions"
            ],
            "Resource": "*"
        },
        {
            "Sid": "AllowPassingServiceRole",
            "Effect": "Allow",
            "Action": [
                "iam:PassRole"
            ],
            "Resource": "arn:aws:iam::account-id:role/EMR_Notebooks_DefaultRole"
        }
    ]
}
```

Wenn Sie EMR Notebooks programmgesteuert auf einem EMR-Notebooks-Cluster ausführen, müssen Sie die folgenden zusätzlichen Berechtigungen hinzufügen:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowRetrievingManagedEndpointCredentials",
            "Effect": "Allow",
            "Action": [
                "emr-containers:GetManagedEndpointSessionCredentials"
            ],
            "Resource": [
```

```
                "arn:aws:emr-containers:region:account-id:/virtualclusters/virtual-
cluster-id/endpoints/managed-endpoint-id"
            ],
            "Condition": {
                "StringEquals": {
                    "emr-containers:ExecutionRoleArn": [
                        "arn:aws:iam::account-id:role/emr-on-eks-execution-role"
                    ]
                }
            }
        },
        {
            "Sid": "AllowDescribingManagedEndpoint",
            "Effect": "Allow",
            "Action": [
                "emr-containers:DescribeManagedEndpoint"
            ],
            "Resource": [
                "arn:aws:emr-containers:region:account-id:/virtualclusters/virtual-
cluster-id/endpoints/managed-endpoint-id"
            ]
        }
    ]
}
```

Einschränkungen bei der programmatischen Ausführung

- Pro AWS-Region-Konto werden maximal 100 gleichzeitige Ausführungen unterstützt.
- Eine Ausführung wird beendet, wenn sie länger als 30 Tage läuft.
- Die programmatische Ausführung von Notebooks wird mit interaktiven Amazon-EMR-Serverless-Anwendungen nicht unterstützt.

Beispiele für die programmatische Ausführung von EMR-Notebooks

Die folgenden Abschnitte enthalten mehrere Beispiele für die programmatische Ausführung von EMR-Notebooks mit der AWS CLI, dem Boto3-SDK (Python) und Ruby:

- CLI-Befehlsbeispiele für die Ausführung von Notebooks
- Python-Beispiele für die Notebook-Ausführung
- Ruby-Beispiele für die Ausführung von Notebooks

Sie können parametrisierte Notebooks auch als Teil geplanter Workflows mit einem Orchestrierungstool wie Apache Airflow oder Amazon Managed Workflows für Apache Airflow (MWAA) ausführen. Weitere Informationen finden Sie unter Orchestrieren von Analyseaufträgen auf EMR Notebooks mithilfe von MWAA im AWS-Big-Data-Blog.

CLI-Befehlsbeispiele für die Ausführung von Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Im folgenden Beispiel wird das Demo-Notebook aus der EMR-Notebooks-Konsole verwendet. Um das Notebook zu finden, verwenden Sie den Dateipfad relativ zum Home-Verzeichnis. In diesem Beispiel gibt es zwei Notebookdateien, die Sie ausführen können: `demo_pyspark.ipynb` und `my_folder/python3.ipynb`.

Der relative Pfad für die Datei `demo_pyspark.ipynb` ist `demo_pyspark.ipynb`, wie unten dargestellt.

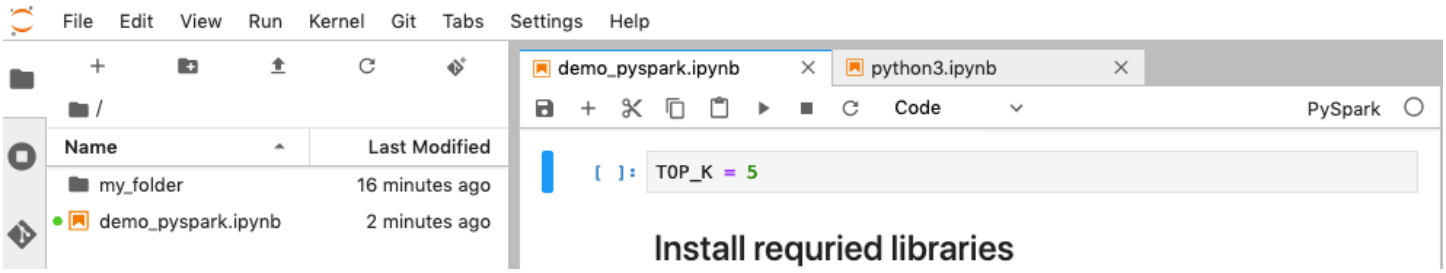

Der relative Pfad für `python3.ipynb` ist `my_folder/python3.ipynb`, wie unten dargestellt.

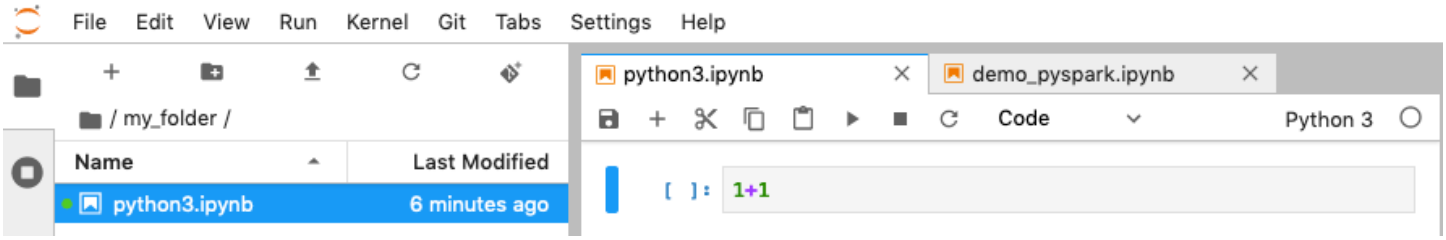

Informationen zu den API-`NotebookExecution`-Aktionen in Amazon-EMR finden Sie unter Amazon-EMR-API-Aktionen.

Ein Notebook ausführen

Sie können AWS CLI verwenden, um Ihr Notebook mit der `start-notebook-execution`-Aktion auszuführen, wie die folgenden Beispiele zeigen.

Example – Ausführen eines EMR-Notebooks in einem EMR Studio Workspace mit einem Amazon-EMR-Cluster (läuft auf Amazon EC2)

```
aws emr --region us-east-1 \
start-notebook-execution \
--editor-id e-ABCDEFG123456 \
--notebook-params '{"input_param":"my-value", "good_superhero":["superman", "batman"]}'
 \
--relative-path test.ipynb \
--notebook-execution-name my-execution \
--execution-engine '{"Id" : "j-1234ABCD123"}' \
--service-role EMR_Notebooks_DefaultRole

{
    "NotebookExecutionId": "ex-ABCDEFGHIJ1234ABCD"
}
```

Example – Ausführen eines EMR-Notebooks in einem EMR Studio Workspace mit einem EMR-Notebooks-Cluster

```
aws emr start-notebook-execution \
    --region us-east-1 \
    --service-role EMR_Notebooks_DefaultRole \
    --environment-variables '{"KERNEL_EXTRA_SPARK_OPTS": "--conf
 spark.executor.instances=1", "KERNEL_LAUNCH_TIMEOUT": "350"}' \
    --output-notebook-format HTML \
    --execution-engine Id=arn:aws:emr-containers:us-west-2:account-id:/
virtualclusters/ABCDEFG/
endpoints/ABCDEF,Type=EMR_ON_EKS,ExecutionRoleArn=arn:aws:iam::account-
id:role/execution-role \
    --editor-id e-ABCDEFG \
    --relative-path EMRonEKS-spark_python.ipynb
```

Example – Ausführen eines EMR Notebooks unter Angabe seines Amazon-S3-Standorts

```
aws emr start-notebook-execution \
    --region us-east-1 \
    --notebook-execution-name my-execution-on-emr-on-eks-cluster \
    --service-role EMR_Notebooks_DefaultRole \
    --environment-variables '{"KERNEL_EXTRA_SPARK_OPTS": "--conf
 spark.executor.instances=1", "KERNEL_LAUNCH_TIMEOUT": "350"}' \
    --output-notebook-format HTML \
    --execution-engine Id=arn:aws:emr-containers:us-west-2:account-id:/
virtualclusters/ABCDEF/
endpoints/ABCDEF,Type=EMR_ON_EKS,ExecutionRoleArn=arn:aws:iam::account-
id:role/execution-role \
    --notebook-s3-location '{"Bucket": "your-s3-bucket","Key": "s3-prefix-to-notebook-
location/EMRonEKS-spark_python.ipynb"}' \
    --output-notebook-s3-location '{"Bucket": "your-s3-bucket","Key": "s3-prefix-for-
storing-output-notebook"}'
```

Notebook-Ausgabe

Hier ist die Ausgabe eines Beispiel-Notebooks. Zelle 3 zeigt die neu eingegebenen Parameterwerte.

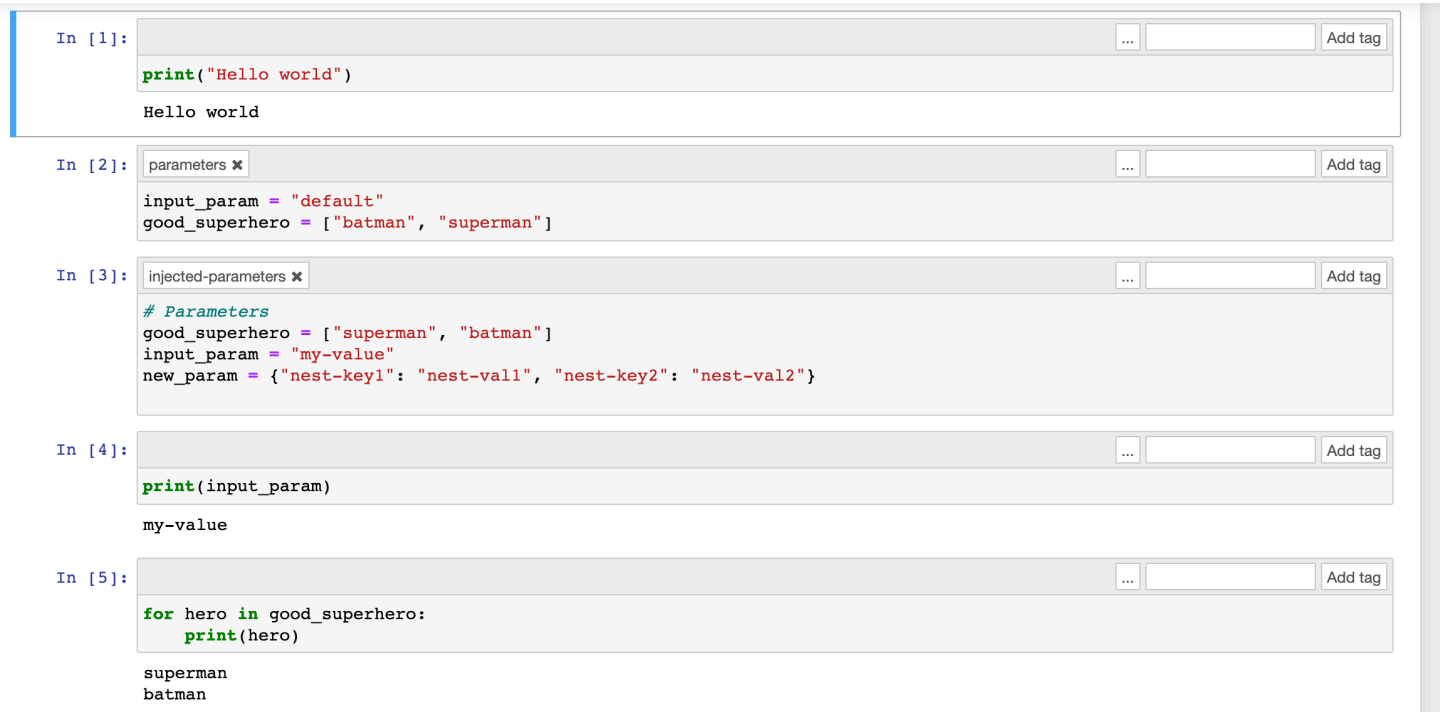

Ein Notebook beschreiben

Sie können die `describe-notebook-execution`-Aktion verwenden, um auf Informationen über eine bestimmte Notebook-Ausführung zuzugreifen.

```
aws emr --region us-east-1 \
describe-notebook-execution --notebook-execution-id ex-IZWZZVR9DKQ9WQ7VZWXJZR29UGHTE

{
    "NotebookExecution": {
        "NotebookExecutionId": "ex-IZWZZVR9DKQ9WQ7VZWXJZR29UGHTE",
        "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
        "ExecutionEngine": {
            "Id": "j-2QMOV6JAX1TS2",
            "Type": "EMR",
            "MasterInstanceSecurityGroupId": "sg-05ce12e58cd4f715e"
        },
        "NotebookExecutionName": "my-execution",
        "NotebookParams": "{\"input_param\":\"my-value\", \"good_superhero\":
[\"superman\", \"batman\"]}",
        "Status": "FINISHED",
        "StartTime": 1593490857.009,
        "Arn": "arn:aws:elasticmapreduce:us-east-1:123456789012:notebook-execution/ex-
IZWZZVR9DKQ9WQ7VZWXJZR29UGHTE",
        "LastStateChangeReason": "Execution is finished for cluster j-2QMOV6JAX1TS2.",
        "NotebookInstanceSecurityGroupId": "sg-0683b0a39966d4a6a",
        "Tags": []
    }
}
```

Ein Notebook stoppen

Wenn auf Ihrem Notebook eine Ausführung läuft, die Sie beenden möchten, können Sie dies mit dem `stop-notebook-execution`-Befehl tun.

```
# stop a running execution
aws emr --region us-east-1 \
stop-notebook-execution --notebook-execution-id ex-IZWZX78UVPAATC8LHJR129B1RBN4T


# describe it
aws emr --region us-east-1 \
```

```
describe-notebook-execution --notebook-execution-id ex-IZWZX78UVPAATC8LHJR129B1RBN4T

{
    "NotebookExecution": {
        "NotebookExecutionId": "ex-IZWZX78UVPAATC8LHJR129B1RBN4T",
        "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
        "ExecutionEngine": {
            "Id": "j-2QMOV6JAX1TS2",
            "Type": "EMR"
        },
        "NotebookExecutionName": "my-execution",
        "NotebookParams": "{\"input_param\":\"my-value\", \"good_superhero\":
[\"superman\", \"batman\"]}",
        "Status": "STOPPED",
        "StartTime": 1593490876.241,
        "Arn": "arn:aws:elasticmapreduce:us-east-1:123456789012:editor-execution/ex-
IZWZX78UVPAATC8LHJR129B1RBN4T",
        "LastStateChangeReason": "Execution is stopped for cluster j-2QMOV6JAX1TS2.
 Internal error",
        "Tags": []
    }
}
```

Listet die Ausführungen für ein Notebook nach Startzeit auf

Sie können einen `--from`-Parameter an `list-notebook-executions` übergeben, um die Ausführungen Ihres Notebooks nach Startzeit aufzulisten.

```
# filter by start time
aws emr --region us-east-1 \
list-notebook-executions --from 1593400000.000

{
    "NotebookExecutions": [
        {
            "NotebookExecutionId": "ex-IZWZX78UVPAATC8LHJR129B1RBN4T",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "STOPPED",
            "StartTime": 1593490876.241
        },
        {
            "NotebookExecutionId": "ex-IZWZZVR9DKQ9WQ7VZWXJZR29UGHTE",
```

```
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "RUNNING",
            "StartTime": 1593490857.009
        },
        {
            "NotebookExecutionId": "ex-IZWZYRS0M14L5V95WZ9OQ399SKMNW",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "STOPPED",
            "StartTime": 1593490292.995
        },
        {
            "NotebookExecutionId": "ex-IZX009ZK83IVY5E33VH8MDMELVK8K",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "FINISHED",
            "StartTime": 1593489834.765
        },
        {
            "NotebookExecutionId": "ex-IZWZXOZF88JWDF9J09GJ91R57VI0N",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "FAILED",
            "StartTime": 1593488934.688
        }
    ]
}
```

Listet die Ausführungen für ein Notebook nach Startzeit und Status auf

Der `list-notebook-executions`-Befehl kann auch einen `--status`-Parameter verwenden, um die Ergebnisse zu filtern.

```
# filter by start time and status
aws emr --region us-east-1 \
list-notebook-executions --from 1593400000.000 --status FINISHED
{
    "NotebookExecutions": [
        {
            "NotebookExecutionId": "ex-IZWZZVR9DKQ9WQ7VZWXJZR29UGHTE",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
```

```
            "Status": "FINISHED",
            "StartTime": 1593490857.009
        },
        {
            "NotebookExecutionId": "ex-IZX009ZK83IVY5E33VH8MDMELVK8K",
            "EditorId": "e-BKTM2DIHXBEDRU44ANWRKIU8N",
            "NotebookExecutionName": "my-execution",
            "Status": "FINISHED",
            "StartTime": 1593489834.765
        }
    ]
}
```

Python-Beispiele für die Notebook-Ausführung

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Das folgende Codebeispiel namens `demo.py` ist eine Datei von SDK für Python (Boto3), die die Notebook-Ausführungs-APIs anzeigt.

Informationen zu den Amazon-EMR-API-`NotebookExecution`-Aktionen finden Sie unter Amazon-EMR-API-Aktionen.

```
import boto3,time

emr = boto3.client(
    'emr',
    region_name='us-west-1'
)

start_resp = emr.start_notebook_execution(
    EditorId='e-40AC8ZO6EGGCPJ4DLO48KGGGI',
```

```
    RelativePath='boto3_demo.ipynb',
    ExecutionEngine={'Id':'j-1HYZS6JQKV11Q'},
    ServiceRole='EMR_Notebooks_DefaultRole'
)

execution_id = start_resp["NotebookExecutionId"]
print(execution_id)
print("\n")

describe_response = emr.describe_notebook_execution(NotebookExecutionId=execution_id)

print(describe_response)
print("\n")

list_response = emr.list_notebook_executions()
print("Existing notebook executions:\n")
for execution in list_response['NotebookExecutions']:
    print(execution)
    print("\n")

print("Sleeping for 5 sec...")
time.sleep(5)

print("Stop execution " + execution_id)
emr.stop_notebook_execution(NotebookExecutionId=execution_id)
describe_response = emr.describe_notebook_execution(NotebookExecutionId=execution_id)
print(describe_response)
print("\n")
```

Hier ist die Ausgabe vom ausgeführten `demo.py`.

```
ex-IZX56YJDW1D29Q1PHR32WABU2SAPK

{'NotebookExecution': {'NotebookExecutionId': 'ex-IZX56YJDW1D29Q1PHR32WABU2SAPK',
 'EditorId': 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'ExecutionEngine': {'Id':
 'j-1HYZS6JQKV11Q', 'Type': 'EMR'}, 'NotebookExecutionName': '', 'Status': 'STARTING',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 49, 19, 418000, tzinfo=tzlocal()),
 'Arn': 'arn:aws:elasticmapreduce:us-west-1:123456789012:notebook-execution/ex-
IZX56YJDW1D29Q1PHR32WABU2SAPK', 'LastStateChangeReason': 'Execution is starting
 for cluster j-1HYZS6JQKV11Q.', 'Tags': []}, 'ResponseMetadata': {'RequestId':
 '70f12c5f-1dda-45b7-adf6-964987d373b7', 'HTTPStatusCode': 200, 'HTTPHeaders': {'x-
amzn-requestid': '70f12c5f-1dda-45b7-adf6-964987d373b7', 'content-type': 'application/
```

```
x-amz-json-1.1', 'content-length': '448', 'date': 'Wed, 19 Aug 2020 00:49:22 GMT'},
 'RetryAttempts': 0}}

Existing notebook executions:

{'NotebookExecutionId': 'ex-IZX56YJDW1D29Q1PHR32WABU2SAPK', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'STARTING',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 49, 19, 418000, tzinfo=tzlocal())}


{'NotebookExecutionId': 'ex-IZX5ABS5PR1E5AHMFYEMX3JJIORRB', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'RUNNING',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 48, 36, 373000, tzinfo=tzlocal())}


{'NotebookExecutionId': 'ex-IZX5GLVXIU1HNI8BWVW057F6MF4VE', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'FINISHED',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 45, 14, 646000, tzinfo=tzlocal()),
 'EndTime': datetime.datetime(2020, 8, 19, 0, 46, 26, 543000, tzinfo=tzlocal())}


{'NotebookExecutionId': 'ex-IZX5CV8YDUO8JAIWMXN2VH32RUIT1', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'FINISHED',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 43, 5, 807000, tzinfo=tzlocal()),
 'EndTime': datetime.datetime(2020, 8, 19, 0, 44, 31, 632000, tzinfo=tzlocal())}


{'NotebookExecutionId': 'ex-IZX5AS0PPW55CEDEURZ9NSOWSUJZ6', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'FINISHED',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 42, 29, 265000, tzinfo=tzlocal()),
 'EndTime': datetime.datetime(2020, 8, 19, 0, 43, 48, 320000, tzinfo=tzlocal())}


{'NotebookExecutionId': 'ex-IZX57YF5Q53BKWLR4I5QZ14HJ7DRS', 'EditorId':
 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'NotebookExecutionName': '', 'Status': 'FINISHED',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 38, 37, 81000, tzinfo=tzlocal()),
 'EndTime': datetime.datetime(2020, 8, 19, 0, 40, 39, 646000, tzinfo=tzlocal())}

Sleeping for 5 sec...
Stop execution ex-IZX56YJDW1D29Q1PHR32WABU2SAPK
{'NotebookExecution': {'NotebookExecutionId': 'ex-IZX56YJDW1D29Q1PHR32WABU2SAPK',
 'EditorId': 'e-40AC8ZO6EGGCPJ4DLO48KGGGI', 'ExecutionEngine': {'Id':
 'j-1HYZS6JQKV11Q', 'Type': 'EMR'}, 'NotebookExecutionName': '', 'Status': 'STOPPING',
 'StartTime': datetime.datetime(2020, 8, 19, 0, 49, 19, 418000, tzinfo=tzlocal()),
```

```
 'Arn': 'arn:aws:elasticmapreduce:us-west-1:123456789012:notebook-execution/ex-
IZX56YJDW1D29Q1PHR32WABU2SAPK', 'LastStateChangeReason': 'Execution is being stopped
 for cluster j-1HYZS6JQKV11Q.', 'Tags': []}, 'ResponseMetadata': {'RequestId':
 '2a77ef73-c1c6-467c-a1d1-7204ab2f6a53', 'HTTPStatusCode': 200, 'HTTPHeaders': {'x-
amzn-requestid': '2a77ef73-c1c6-467c-a1d1-7204ab2f6a53', 'content-type': 'application/
x-amz-json-1.1', 'content-length': '453', 'date': 'Wed, 19 Aug 2020 00:49:30 GMT'},
 'RetryAttempts': 0}}
```

Ruby-Beispiele für die Ausführung von Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Im Folgenden finden Sie Ruby-Codebeispiele, die die Verwendung der Notebook-Ausführungs-API demonstrieren.

```
# prepare an Amazon EMR client

emr = Aws::EMR::Client.new(
  region: 'us-east-1',
  access_key_id: 'AKIA...JKPKA',
  secret_access_key: 'rLMeu...vU0OLrAC1',
)
```

Starten der Notebook-Ausführung und Abrufen der Ausführungs-ID

In diesem Beispiel sind der Amazon-S3-Editor und das EMR-Notebook `s3://mybucket/notebooks/e-EA8VGAA429FEQTC8HC9ZHWISK/test.ipynb`.

Informationen zu den Amazon-EMR-API-`NotebookExecution`-Aktionen finden Sie unter Amazon-EMR-API-Aktionen.

```
start_response = emr.start_notebook_execution({
    editor_id: "e-EA8VGAA429FEQTC8HC9ZHWISK",
    relative_path: "test.ipynb",

    execution_engine: {id: "j-3U82I95AMALGE"},

    service_role: "EMR_Notebooks_DefaultRole",
})


notebook_execution_id = start_resp.notebook_execution_id
```

Beschreibung der Ausführung des Notebooks und Ausdrucken der Details

```
describe_resp = emr.describe_notebook_execution({
    notebook_execution_id: notebook_execution_id
})
puts describe_resp.notebook_execution
```

Die Ausgabe der obigen Befehle wird wie folgt aussehen.

```
{
:notebook_execution_id=>"ex-IZX3VTVZWVWPP27KUB90BZ7V9IEDG",
:editor_id=>"e-EA8VGAA429FEQTC8HC9ZHWISK",
:execution_engine=>{:id=>"j-3U82I95AMALGE", :type=>"EMR", :master_instance_security_group_id=>n
:notebook_execution_name=>"",
:notebook_params=>nil,
:status=>"STARTING",
:start_time=>2020-07-23 15:07:07 -0700,
:end_time=>nil,
:arn=>"arn:aws:elasticmapreduce:us-east-1:123456789012:notebook-execution/ex-
IZX3VTVZWVWPP27KUB90BZ7V9IEDG",
:output_notebook_uri=>nil,
:last_state_change_reason=>"Execution is starting for cluster
 j-3U82I95AMALGE.", :notebook_instance_security_group_id=>nil,
:tags=>[]
}
```

Notebookfilter

```
"EditorId": "e-XXXX",           [Optional]
"From" : "1593400000.000",    [Optional]
"To" :
```

Beenden der Notebook-Ausführung

```
stop_resp = emr.stop_notebook_execution({
    notebook_execution_id: notebook_execution_id
})
```

Aktivieren des Identitätswechsels zur Überwachung von Spark-Benutzer- und -Aufgabenaktivitäten

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

EMR-Notebooks ermöglichen die Konfiguration von Benutzer-Identitätswechseln auf einem Spark-Cluster. Mit dieser Funktion können Sie die Auftragsaktivität nachverfolgen, die innerhalb des Notebook-Editors initiiert wurde. Darüber hinaus verfügen EMR-Notebooks über ein integriertes Jupyter-Notebook-Widget zur Anzeige von Details zu Spark-Aufgaben zusammen mit der Abfrageausgabe im Notebook-Editor. Das Widget ist standardmäßig verfügbar und erfordert keine spezielle Konfiguration. Um die Verlaufsserver anzeigen zu können, muss Ihr Client jedoch so konfiguriert sein, dass Amazon-EMR-Webschnittstellen angezeigt werden, die auf dem Primärknoten gehostet werden.

Einrichten der Spark-Benutzerkennung

Standardmäßig stammen Spark-Aufträge, die Benutzer mit dem Notebook-Editor übermitteln, scheinbar aus einer unbestimmten `livy`-Benutzeridentität. Sie können eine Benutzerkennung für den Cluster konfigurieren, damit diese Aufträge stattdessen mit der Benutzeridentität verknüpft

werden, die den Code ausgeführt hat. HDFS-Benutzerverzeichnisse auf dem Primärknoten werden für jede Benutzeridentität erstellt, die Code im Notebook ausführt. Beispiel: Wenn der Benutzer `NbUser1` Code aus dem Notebook-Editor ausführt, können Sie eine Verbindung mit dem Primärknoten herstellen und sehen, dass `hadoop fs -ls /user` das Verzeichnis `/user/user_NbUser1` zeigt.

Sie können diese Funktion aktivieren, indem Sie Eigenschaften in den Konfigurationsklassifizierungen `core-site` und `livy-conf` festlegen. Dieses Feature ist nicht standardmäßig verfügbar, wenn Amazon EMR einen Cluster zusammen mit einem Notebook erstellt. Weitere Informationen zur Verwendung von Konfigurationsklassifizierungen zum Anpassen von Anwendungen finden Sie unter Konfigurieren von Anwendungen in Amazon-EMR-Versionshinweise.

Verwenden Sie die folgenden Konfigurationsklassifizierungen und Werte, um einen Benutzer-Identitätswechsel für EMR Notebooks: zu aktivieren:

```
[
    {
        "Classification": "core-site",
        "Properties": {
          "hadoop.proxyuser.livy.groups": "*",
          "hadoop.proxyuser.livy.hosts": "*"
        }
    },
    {
        "Classification": "livy-conf",
        "Properties": {
          "livy.impersonation.enabled": "true"
        }
    }
]
```

Verwenden des Spark-Widgets für die Auftragsüberwachung

Wenn Sie im Notebook-Editor Code ausführen, der Spark-Aufträge im EMR-Cluster ausführt, enthält die Ausgabe ein Jupyter-Notebook-Widget für die Spark-Auftragsüberwachung. Das Widget stellt Auftragsdetails, nützliche Links zur Spark-Verlaufsserverseite und zur Hadoop-Auftragsverlaufsseite sowie praktische Links zu Auftragsprotokollen in Amazon S3 für alle fehlgeschlagenen Aufträge bereit.

Um Verlaufsserverseiten auf dem Cluster-Primärknoten anzuzeigen, müssen Sie einen SSH-Client und einen Proxy nach Bedarf einrichten. Weitere Informationen finden Sie unter Anzeigen von auf

Amazon-EMR-Clustern gehosteten Webschnittstellen. Um Protokolle in Amazon S3 anzuzeigen, muss die Cluster-Protokollierung aktiviert sein. Dies ist die Standardeinstellung für neue Cluster. Weitere Informationen finden Sie unter In Amazon S3 archivierte Protokolldateien anzeigen.

Nachstehend finden Sie ein Beispiel für die Spark-Auftragsüberwachung.

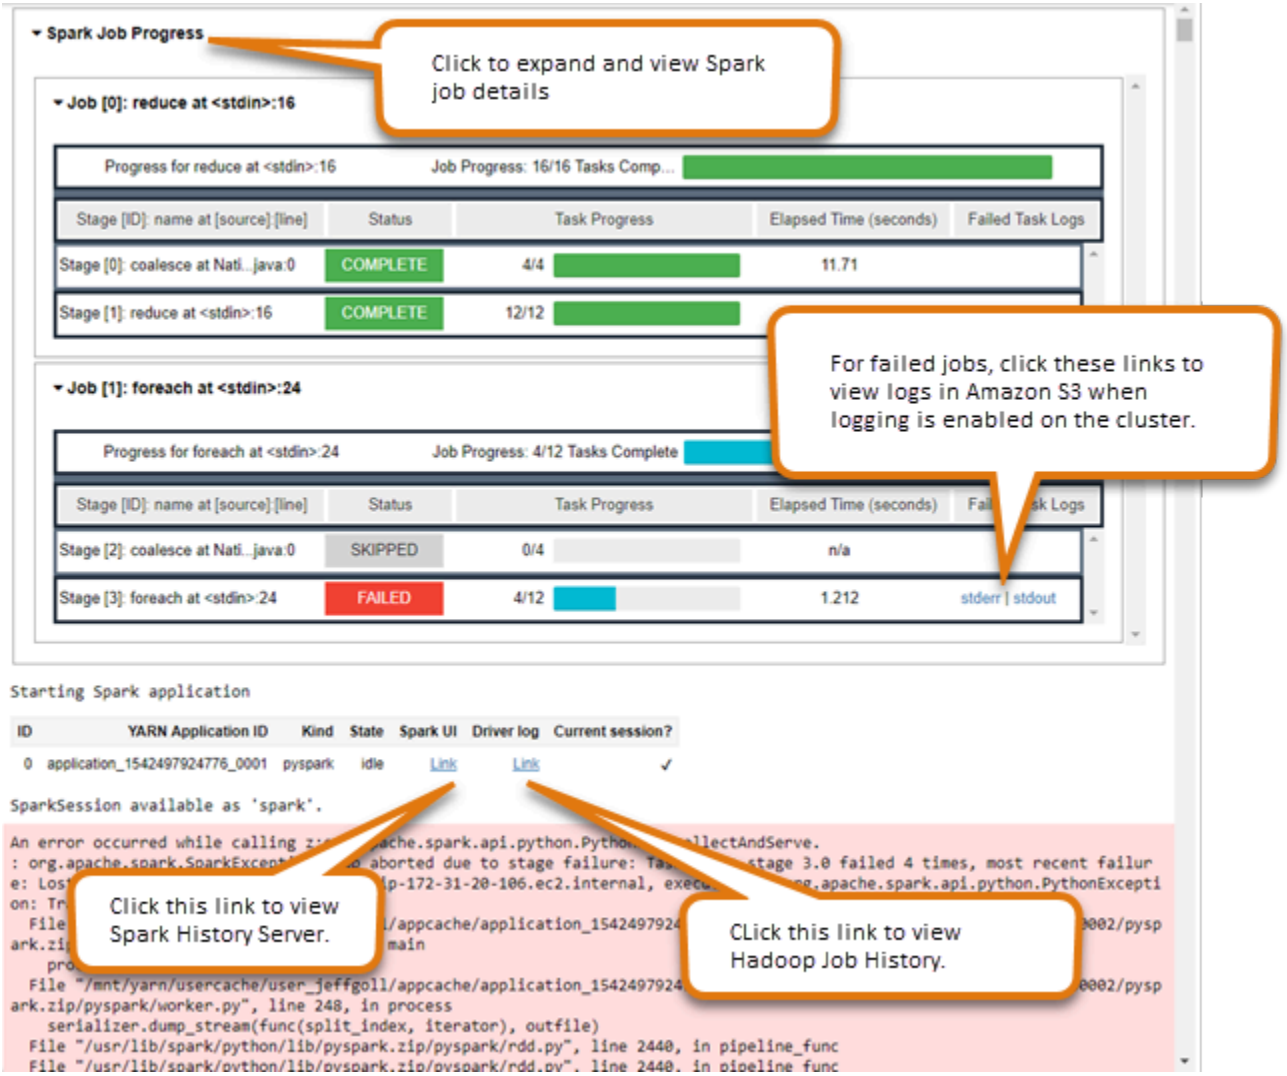

Sicherheit und Zugriffskontrolle für EMR Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces

zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Es sind verschiedene Features verfügbar, mit denen Sie die Sicherheitslage von EMR Notebooks anpassen können. Dadurch wird sichergestellt, dass nur autorisierte Benutzer Zugriff auf ein EMR Notebook haben, mit Notebooks arbeiten und den Notebook-Editor zum Ausführen von Code auf dem Cluster verwenden können. Diese Features arbeiten mit den für Amazon EMR und Amazon-EMR-Cluster verfügbaren Sicherheitsfunktionen zusammen. Weitere Informationen finden Sie unter Sicherheit in Amazon EMR.

- Sie können AWS Identity and Access Management-Richtlinienanweisungen zusammen mit Notebook-Tags verwenden, um den Zugriff einzuschränken. Weitere Informationen finden Sie unter Funktionsweise von Amazon EMR mit IAM und Beispielhafte identitätsbasierte Richtlinienanweisungen für EMR Notebooks.
- Amazon-EC2-Sicherheitsgruppen fungieren als virtuelle Firewalls, die den Netzwerkdatenverkehr zwischen der primären Instance des Clusters und dem Notebook-Editor steuern. Sie können Standardwerte verwenden oder diese Sicherheitsgruppen anpassen. Weitere Informationen finden Sie unter Angeben von EC2-Sicherheitsgruppen für EMR Notebooks.
- Sie geben eine AWS-Servicerolle an, die die Berechtigungen eines EMR Notebook für die Interaktion mit anderen AWS-Services festlegt. Weitere Informationen finden Sie unter Servicerolle für EMR Notebooks.

Installieren und Verwenden von Kerneln und Bibliotheken

Note

EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Jedes EMR Notebook wird mit einer Reihe vorinstallierter Bibliotheken und Kernel ausgeliefert. Sie können in einem EMR-Cluster zusätzliche Bibliotheken und Kernel installieren, wenn der Cluster Zugriff auf das Repository hat, in dem sich die Kernel und Bibliotheken befinden. Beispielsweise müssen Sie für Cluster in privaten Subnetzen möglicherweise die Netzwerkadressübersetzung (Network Address Translation, NAT) konfigurieren und dem Cluster einen Pfad für den Zugriff auf das öffentliche PyPI-Repository angeben, um eine Bibliothek zu installieren. Weitere Informationen zum Konfigurieren des externen Zugriffs für verschiedene Netzwerkkonfigurationen finden Sie unter Szenarien und Beispiele im Amazon-VPC-Benutzerhandbuch.

Serverless-EMR-Anwendungen werden mit den folgenden vorinstallierten Bibliotheken für Python und PySpark geliefert:

- Python-Bibliotheken – ggplot, matplotlib, numpy, pandas, plotly, bokeh, scikit-learn, scipy, scipy
- PySpark-Bibliotheken – ggplot, matplotlib, numpy, pandas, plotly, bokeh, scikit-learn, scipy, scipy

Installieren von Kernels und Python-Bibliotheken auf einem Cluster-Primärknoten

Mit Amazon-EMR-Version 5.30.0 und höher (außer Version 6.0.0) können Sie zusätzliche Python-Bibliotheken und Kernel auf dem Primärknoten des Clusters installieren. Nach der Installation stehen diese Kernel und Bibliotheken allen Benutzern zur Verfügung, die ein an den Cluster angefügtes EMR Notebook ausführen. Auf diese Weise installierte Python-Bibliotheken sind nur für Prozesse verfügbar, die auf dem Primärknoten ausgeführt werden. Die Bibliotheken werden nicht auf Core- oder Aufgabenknoten installiert und sind für Executors, die auf diesen Knoten ausgeführt werden, nicht verfügbar.

> **Note**
>
> Für die Amazon-EMR-Versionen 5.30.1, 5.31.0 und 6.1.0 müssen Sie zusätzliche Schritte unternehmen, um Kernel und Bibliotheken auf dem Primärknoten eines Clusters zu installieren.
> Um das Feature zu aktivieren, gehen Sie wie folgt vor:
>
> 1. Stellen Sie sicher, dass die der Servicerolle für EMR Notebooks zugeordnete Berechtigungsrichtlinie die folgende Aktion zulässt:
>
>    ```
>    elasticmapreduce:ListSteps
>    ```

Weitere Informationen finden Sie unter Servicerolle für EMR-Notebooks.

2. Verwenden Sie AWS CLI, um einen Schritt auf dem Cluster auszuführen, der EMR Notebooks einrichtet, wie im folgenden Beispiel gezeigt. Sie müssen den Schrittnamen `EMRNotebooksSetup` verwenden. Ersetzen Sie *`us-east-1`* durch die Region, in der sich Ihr Cluster befindet. Weitere Informationen finden Sie unter Hinzufügen von Schritten zu einem Cluster AWS CLI.

```
aws emr add-steps --cluster-id MyClusterID --steps
 Type=CUSTOM_JAR,Name=EMRNotebooksSetup,ActionOnFailure=CONTINUE,Jar=s3://us-
east-1.elasticmapreduce/libs/script-runner/script-runner.jar,Args=["s3://
awssupportdatasvcs.com/bootstrap-actions/EMRNotebooksSetup/emr-notebooks-
setup.sh"]
```

Sie können Kernel und Bibliotheken mithilfe von `pip` oder `conda` im `/emr/notebook-env/bin`-Verzeichnis auf dem Primärknoten installieren.

Example – Installieren von Python-Bibliotheken

Führen Sie im Python3-Kernel den `%pip` Magic als Befehl in einer Notebook-Zelle aus, um Python-Bibliotheken zu installieren.

```
%pip install pmdarima
```

Möglicherweise müssen Sie den Kernel neu starten, um aktualisierte Pakete verwenden zu können. Sie können auch die `%%sh`-Spark-Magie zum Aufrufen von `pip` verwenden.

```
%%sh
/emr/notebook-env/bin/pip install -U matplotlib
/emr/notebook-env/bin/pip install -U pmdarima
```

Wenn Sie einen PySpark-Kernel verwenden, können Sie entweder Bibliotheken auf dem Cluster mithilfe von `pip`-Befehlen installieren oder Notebookbibliotheken aus einem PySpark-Notebook heraus verwenden.

Um `pip`-Befehle auf dem Cluster vom Terminal aus auszuführen, stellen Sie zunächst über SSH eine Verbindung zum Primärknoten her, wie die folgenden Befehle zeigen.

```
sudo pip3 install -U matplotlib
```

```
sudo pip3 install -U pmdarima
```

Alternativ können Sie Bibliotheken im Notebookbereich verwenden. Bei Bibliotheken für Notebooks ist Ihre Bibliotheksinstallation auf den Umfang Ihrer Sitzung beschränkt und erfolgt auf allen Spark-Executoren. Weitere Informationen finden Sie unter Verwenden von Notebook Bibliotheken.

Wenn Sie mehrere Python-Bibliotheken in einen PySpark-Kernel packen möchten, können Sie auch eine isolierte virtuelle Python-Umgebung erstellen. Anwendungsbeispiele finden Sie unter VerwendenVirtualenv.

Um eine virtuelle Python-Umgebung in einer Sitzung zu erstellen, verwenden Sie die Spark-Eigenschaft `spark.yarn.dist.archives` aus dem `%%configure` magischen Befehl in der ersten Zelle in einem Notebook, wie das folgende Beispiel zeigt.

```
%%configure -f
{
   "conf": {
   "spark.yarn.appMasterEnv.PYSPARK_PYTHON":"./environment/bin/python",
   "spark.yarn.appMasterEnv.PYSPARK_DRIVER_PYTHON":"./environment/bin/python",
   "spark.yarn.dist.archives":"s3://DOC-EXAMPLE-BUCKET/prefix/
my_pyspark_venv.tar.gz#environment",
   "spark.submit.deployMode":"cluster"
   }
}
```

Auf ähnliche Weise können Sie eine Spark-Executor-Umgebung erstellen.

```
%%configure -f
{
   "conf": {
   "spark.yarn.appMasterEnv.PYSPARK_PYTHON":"./environment/bin/python",
   "spark.yarn.appMasterEnv.PYSPARK_DRIVER_PYTHON":"./environment/bin/python",
   "spark.executorEnv.PYSPARK_PYTHON":"./environment/bin/python",
   "spark.yarn.dist.archives":"s3://DOC-EXAMPLE-BUCKET/prefix/
my_pyspark_venv.tar.gz#environment",
   "spark.submit.deployMode":"cluster"
   }
}
```

Sie können es auch `conda` zur Installation von Python-Bibliotheken verwenden. Für die Verwendung von `conda` benötigen Sie keinen Sudo-Zugriff. Sie müssen über SSH eine Verbindung mit dem

Primärknoten herstellen und dann `conda` vom Terminal aus ausführen. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Example – Installieren eines Kernels

Das folgende Beispiel zeigt die Installation des Kotlin-Kernels mithilfe eines Terminalbefehls, während eine Verbindung zum Primärknoten eines Clusters besteht:

```
sudo /emr/notebook-env/bin/conda install kotlin-jupyter-kernel -c jetbrains
```

> **Note**
>
> Diese Anweisungen installieren keine Kernel-Abhängigkeiten. Wenn Ihr Kernel Abhängigkeiten von Drittanbietern hat, müssen Sie möglicherweise zusätzliche Einrichtungsschritte durchführen, bevor Sie den Kernel mit Ihrem Notebook verwenden können.

Überlegungen und Einschränkungen bei Bibliotheken für Notebooks

Beachten Sie bei der Verwendung von Bibliotheken im Format Notebook-Scoped Folgendes:

- Bibliotheken für Notebooks sind für Cluster verfügbar, die Sie mit Amazon-EMR-Versionen 5.26.0 und höher erstellen.
- Dedizierte Notebook-Bibliotheken sind nur für die Verwendung mit dem PySpark-Kernel vorgesehen.
- Jeder Benutzer kann zusätzliche dedizierte Notebook-Bibliotheken innerhalb einer Notebook-Zelle installieren. Diese Bibliotheken stehen diesem Notebook-Benutzer nur während genau einer Notebook-Sitzung zur Verfügung. Wenn andere Benutzer dieselben Bibliotheken benötigen oder derselbe Benutzer dieselben Bibliotheken in einer anderen Sitzung benötigt, muss die Bibliothek neu installiert werden.
- Sie können nur die Bibliotheken deinstallieren, die mit der `install_pypi_package`-API installiert wurden. Sie können keine Bibliotheken deinstallieren, die auf dem Cluster vorinstalliert sind.
- Wenn dieselben Bibliotheken mit unterschiedlichen Versionen auf dem Cluster und als Notebook-Bibliotheken installiert sind, überschreibt die Version der Notebook-Bibliothek die Version der Cluster-Bibliothek.

Arbeiten mit Notebook-Bibliotheken

Um Bibliotheken zu installieren, muss Ihr Amazon-EMR-Cluster Zugriff auf das PyPI-Repository haben, in dem sich die Bibliotheken befinden.

Die folgenden Beispiele zeigen einfache Befehle zum Auflisten, Installieren und Deinstallieren von Bibliotheken in einer Notebook-Zelle mithilfe der PySpark-Kernel und -APIs. Weitere Beispiele finden Sie unter Installieren von Python-Bibliotheken auf einem ausgeführten Cluster mit EMR Notebooks im AWS-Big-Data-Blog.

Example – Auflisten aktueller Bibliotheken

Der folgende Befehl listet die Python-Pakete auf, die für die aktuelle Spark-Notebook-Sitzung verfügbar sind. Hiermit werden Bibliotheken aufgelistet, die auf dem Cluster installiert sind, und Bibliotheken für Notebook-Bereiche.

```
sc.list_packages()
```

Example – Installieren der Celery-Bibliothek

Mit dem folgenden Befehl wird die Celery-Bibliothek als Notebook-Bibliothek installiert.

```
sc.install_pypi_package("celery")
```

Nach der Installation der Bibliothek bestätigt der folgende Befehl, dass die Bibliothek auf dem Spark-Treiber und den Executors verfügbar ist.

```
import celery
sc.range(1,10000,1,100).map(lambda x: celery.__version__).collect()
```

Example – Installieren der Arrow-Bibliothek unter Angabe der Version und des Repositorys

Mit dem folgenden Befehl wird die Pfeilbibliothek als Bibliothek mit einem „Notebook-Scoped“-Format mit einer Spezifikation der Bibliotheksversion und der Repository-URL installiert.

```
sc.install_pypi_package("arrow==0.14.0", "https://pypi.org/simple")
```

Example – Deinstallieren einer Bibliothek

Der folgende Befehl deinstalliert die Pfeilbibliothek und entfernt sie als Notebook-Bibliothek aus der aktuellen Sitzung.

```
sc.uninstall_package("arrow")
```

Verknüpfen von Git-basierten Repositorys mit EMR Notebooks

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Sie können Git-basierte Repositorys mit Ihren Amazon-EMR-Notebooks verknüpfen, um Ihre Notebooks in einer versionskontrollierten Umgebung zu speichern. Sie können einem Notebook bis zu drei Repositorys zuordnen. Folgende Git-basierte Services werden unterstützt:

- AWS CodeCommit
- GitHub
- Bitbucket
- GitLab

Die Verknüpfung von Git-basierten Repositorys mit Ihrem Notebook hat folgende Vorteile:

- Versionskontrolle – Sie können Codeänderungen in einem Versionskontrollsystem aufzeichnen, damit Sie den Verlauf Ihrer Änderungen überprüfen und selektiv rückgängig machen können.
- Zusammenarbeit – Kollegen, die in verschiedenen Notebooks arbeiten, können Code über Git-basierte Remote-Repositorys füreinander freigeben. Notebooks können Code aus Remote-Repositorys klonen oder zusammenführen und Änderungen in diese Remote-Repositorys zurückübertragen.
- Code-Wiederverwendung – Viele Jupyter-Notebooks zur Veranschaulichung von Datenanalyse- oder Machine-Learning-Techniken sind in öffentlich gehosteten Repositorys wie beispielsweise

GitHub verfügbar. Sie können Ihre Notebooks mit einem Repository verknüpfen, um die in diesem Repository enthaltenen Jupyter-Notebooks wiederzuverwenden.

Um Git-basierte Repositorys mit EMR Notebooks verwenden zu können, fügen Sie die Repositorys als Ressourcen in der Amazon-EMR-Konsole hinzu, ordnen Sie Anmeldeinformationen für Repositorys zu, die eine Authentifizierung erfordern, und verknüpfen Sie sie mit Ihren Notebooks. In der Amazon-EMR-Konsole können Sie eine Liste der Repositorys, die in Ihrem Konto gespeichert sind, sowie Details zu den einzelnen Repositorys anzeigen. Sie können ein vorhandenes Git-basiertes Repository mit einem Notebook verknüpfen, wenn Sie es erstellen.

Themen

- Voraussetzungen und Überlegungen
- Hinzufügen eines Git-basierten Repositorys zu Amazon EMR
- Aktualisieren oder Löschen eines Git-basierten Repositorys
- Verknüpfen oder Aufheben der Verknüpfung eines Git-basierten Repositorys
- Erstellen eines neuen Notebooks mit einem zugehörigen Git-Repository
- Verwenden von Git-Repositorys in einem Notebook

Voraussetzungen und Überlegungen

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Berücksichtigen Sie Folgendes, wenn Sie ein Git-basiertes Repository in EMR Notebooks integrieren möchten.

AWS CodeCommit

Wenn Sie ein CodeCommit-Repository verwenden, müssen Sie Git-Anmeldeinformationen und HTTPS mit CodeCommit verwenden. SSH-Schlüssel und HTTPS mit dem AWS CLI Credential Helper werden nicht unterstützt. CodeCommit unterstützt keine Personal Access Tokens (PATs). Weitere Informationen finden Sie unter Verwenden von IAM mit CodeCommit: Git-Anmeldeinformationen, SSH-Schlüssel und AWS-Zugriffsschlüssel im IAM-Benutzerhandbuch und unter Setup für HTTPS-Benutzer, die Git-Anmeldeinformationen verwenden im AWS CodeCommit-Benutzerhandbuch.

Überlegungen zu Zugriff und Berechtigungen

Bevor Sie ein Repository mit Ihrem Notebook verknüpfen, müssen Sie sicherstellen, dass Ihr Cluster, Ihre IAM-Rolle für EMR Notebooks und Ihre Sicherheitsgruppen über die richtigen Einstellungen und Berechtigungen verfügen. Sie können auch Git-basierte Repositorys konfigurieren, die Sie in einem privaten Netzwerk hosten, indem Sie den Anweisungen unter Ein privat gehostetes Git-Repository für EMR Notebooks konfigurieren folgen.

- Cluster-Internetzugriff – Die Netzwerkschnittstelle, die gestartet wird, hat nur eine private IP-Adresse. Das bedeutet, dass der Cluster, mit dem Ihr Notebook eine Verbindung herstellt, sich in einem privaten Subnetz mit einem NAT-Gateway (Network Address Translation) befinden oder über ein Virtual Private Gateway auf das Internet zugreifen können muss. Weitere Informationen finden Sie unter Amazon-VPC-Optionen.

  Die Sicherheitsgruppen für Ihr Notebook müssen eine Regel für ausgehenden Datenverkehr enthalten, sodass das Notebook Datenverkehr vom Cluster an das Internet weiterleiten kann. Wir empfehlen, eigene Sicherheitsgruppen zu erstellen. Weitere Informationen finden Sie unter Angeben von EC2-Sicherheitsgruppen für EMR Notebooks.

  > **Important**
  >
  > Wenn die Netzwerkschnittstelle in ein öffentliches Subnetz gestartet wird, kann sie nicht über ein Internet-Gateway (IGW) mit dem Internet kommunizieren.

- Berechtigungen für AWS Secrets Manager – Wenn Sie Secrets Manager zum Speichern von Secrets verwenden, die Sie für den Zugriff auf ein Repository verwenden, muss an die the section called “EMR-Notebooks-Rolle” eine Berechtigungsrichtlinie angefügt sein, die die Aktion `secretsmanager:GetSecretValue` zulässt.

Ein privat gehostetes Git-Repository für EMR Notebooks konfigurieren

Verwenden Sie die folgenden Anweisungen, um privat gehostete Repositorys für EMR Notebooks zu konfigurieren. Sie müssen eine Konfigurationsdatei mit Informationen zu Ihren DNS- und Git-Servern bereitstellen. Amazon EMR verwendet diese Informationen, um EMR Notebooks zu konfigurieren, die den Datenverkehr an Ihre privat gehosteten Repositorys weiterleiten können.

Voraussetzungen

Bevor Sie ein privat gehostetes Git-Repository für EMR Notebooks konfigurieren, benötigen Sie Folgendes:

- Ein Amazon S3 Control Ort, an dem Dateien für Ihr EMR Notebook gespeichert werden.

Um ein oder mehrere privat gehostete Git-Repositorys für EMR Notebooks zu konfigurieren

1. Erstellen Sie eine Konfigurationsdatei mit der bereitgestellten Vorlage. Geben Sie für jeden Git-Server, den Sie in Ihrer Konfiguration angeben möchten, die folgenden Werte an:

   - **`DnsServerIpV4`** – Die IPv4-Adresse Ihres DNS-Servers. Wenn Sie Werte für sowohl `DnsServerIpV4` als auch `GitServerIpV4List` angeben, hat der Wert für `DnsServerIpV4` Vorrang und wird zur Auflösung Ihres `GitServerDnsName` verwendet.

     > **Note**
     >
     > Um privat gehostete Git-Repositorys verwenden zu können, muss Ihr DNS-Server eingehenden Zugriff von EMR Notebooks zulassen. Wir empfehlen Ihnen dringend, Ihren DNS-Server vor anderen, unbefugten Zugriffen zu schützen.

   - **`GitServerDnsName`** – Der DNS-Name Ihres Git-Servers. Zum Beispiel `"git.example.com"`.
   - **`GitServerIpV4List`** – Eine Liste von IPv4-Adressen, die zu deinen Git-Servern gehören.

```
[
    {
        "Type": "PrivatelyHostedGitConfig",
        "Value": [
            {
                "DnsServerIpV4": "<10.24.34.xxx>",
```

```
                "GitServerDnsName": "<enterprise.git.com>",
                "GitServerIpV4List": [
                    "<xxx.xxx.xxx.xxx>",
                    "<xxx.xxx.xxx.xxx>"
                ]
            },
            {
                "DnsServerIpV4": "<10.24.34.xxx>",
                "GitServerDnsName": "<git.example.com>",
                "GitServerIpV4List": [
                    "<xxx.xxx.xxx.xxx>",
                    "<xxx.xxx.xxx.xxx>"
                ]
            }
        ]
    }
]
```

2. Speichern Sie Ihre Konfigurationsdatei unter `configuration.json`.
3. Laden Sie die Konfigurationsdatei in den von Ihnen angegebenen Amazon-S3-Speicherort in einem Ordner mit dem Namen `life-cycle-configuration` hoch. Wenn Ihr Standard-S3-Speicherort beispielsweise `s3://DOC-EXAMPLE-BUCKET/notebooks` lautet, sollte sich Ihre Konfigurationsdatei unter `s3://DOC-EXAMPLE-BUCKET/notebooks/`**`life-cycle-configuration/configuration.json`** befinden.

   > **Important**
   >
   > Wir empfehlen dringend, den Zugriff auf Ihren `life-cycle-configuration`-Ordner nur auf Ihre EMR-Notebooks-Administratoren und auf die Servicerolle für EMR Notebooks zu beschränken. Sie sollten auch `configuration.json` vor unbefugtem Zugriff schützen. Anweisungen finden Sie unter Steuern des Zugriffs auf einen Bucket mit Benutzerrichtlinien oder Bewährte Sicherheitsmethoden für Amazon S3.

   Anweisungen zum Hochladen finden Sie unter Erstellen eines Ordners und Hochladen von Objekten im Benutzerhandbuch für Amazon Simple Storage Service.

Hinzufügen eines Git-basierten Repositorys zu Amazon EMR

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

In den folgenden Abschnitten finden Sie Informationen zum Hinzufügen eines Git-basierten Repositorys zu einem EMR-Notebook in der alten Konsole oder zu einem EMR Studio Workspace in der neuen Konsole.

New console

Da EMR Notebooks in der neuen Konsole EMR-Studio-Workspaces sind, können Sie den Anweisungen unter Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen folgen, um Ihrem Workspace bis zu drei Git-Repositorys zuzuordnen.

Sie können aber auch die JupyterLab Git-Erweiterung verwenden. Wählen Sie das Git-Symbol in der linken Seitenleiste Ihres Jupyterlab-Notebooks, um auf die Erweiterung zuzugreifen. Informationen zur Erweiterung finden Sie im GitHub-Repo jupyterlab-git.

Um ein Git-Repository mit einem Workspace zu verknüpfen, muss Ihr Studio-Administrator Schritte unternehmen, um das Studio so zu konfigurieren, dass die Verknüpfung mit Git-Repositorys zulässig ist. Weitere Informationen finden Sie unter Zugriff und Berechtigungen für Git-basierte Repositorys einrichten.

Old console

So fügen Sie ein Git-basiertes Repository als Ressource in Ihrem Amazon-EMR-Konto hinzu

1. Öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/elasticmapreduce/.
2. Wählen Sie Git repositories (Git-Repositorys) und dann Add repository (Repository hinzufügen) aus.

3. Geben Sie unter Repository-Name einen Namen ein, der für das Repository in Amazon EMR verwendet werden soll.

   Namen dürfen nur alphanumerische Zeichen, Bindestriche (-) oder Unterstriche (_) enthalten.

4. Geben Sie für Git repository URL (Git-Repository-URL) die URL für das Repository ein. Wenn Sie ein CodeCommit Repository verwenden, handelt es sich dabei um die URL, die kopiert wird, wenn Sie die Option URL klonen und dann HTTPS klonen wählen, z. B. `https://git-codecommit.us-west-2.amazonaws.com/v1/repos/MyCodeCommitRepoName`.

5. Geben Sie für Branch (Verzweigung) einen Verzweigungsnamen ein.

6. Wählen Sie Optionen für Git credentials (Git-Anmeldeinformationen) gemäß den folgenden Richtlinien. Sie können einen Git-Benutzernamen und ein Passwort oder ein persönliches Zugriffstoken (Personal Access Token, PAT) verwenden, um sich bei Ihrem Repository zu authentifizieren. EMR Notebooks greift mithilfe von Geheimnissen, die im Secrets Manager gespeichert sind, auf Ihre Git-Anmeldeinformationen zu.

   > **Note**
   >
   > Wenn Sie ein GitHub-Repository verwenden, empfehlen wir Ihnen, zur Authentifizierung ein Personal Access Token (PAT) zu verwenden. Ab dem 13. August 2021 akzeptiert GitHub bei der Authentifizierung von Git-Vorgängen keine Passwörter mehr. Weitere Informationen findest du im Beitrag Token-Authentifizierungsanforderungen für Git-Operationen im GitHub-Blog.

Option	Beschreibung
Verwenden eines vorhandenen AWS-Secrets	Wählen Sie diese Option, wenn Sie Ihre Anmeldeinformationen bereits als Secret in Secrets Manager gespeichert haben, und wählen Sie dann den Namen des Secrets in der Liste aus. Wenn Sie ein Secret auswählen, das mit einem Git-Benutzernamen und -Passwort verknüpft ist, muss das Secret das Format `{"gitUsername": " MyUserName ",`

Option	Beschreibung
	`"gitPassword": " MyPassword "}` aufweisen.
Erstellen eines neuen Secrets	Wählen Sie diese Option, um vorhandene Git-Anmeldeinformationen mit einem neuen Secret zu verknüpfen, das Sie in Secrets Manager erstellen. Führen Sie basierend auf den Git-Anmeldeinformationen, die Sie für das Repository verwenden, einen der folgenden Schritte aus. Wenn Sie für den Zugriff auf das Repository einen Git-Benutzernamen mit Passwort verwenden, wählen Sie Benutzername und Passwort aus, geben Sie den Namen des Secrets ein, das in Secrets Manager verwendet werden soll, und geben Sie dann den Benutzernamen und das Passwort ein, die mit dem Secret verknüpft werden sollen. -ODER- Wenn Sie ein persönliches Zugriffstoken für den Zugriff auf das Repository verwenden, wählen Sie Persönliches Zugriffstoken (PAT) aus, geben Sie den Secret-Name ein, der in Secrets Manager verwendet werden soll, und geben Sie dann Ihr persönliches Zugriffstoken ein. Weitere Informationen finden Sie unter Erstellen eines persönlichen Zugriffstoken für die Befehlszeile für GitHub und Persönliche Zugriffstoken für Bitbucket. CodeCommit-Repositorys unterstützen diese Option nicht.

Option	Beschreibung
Verwenden eines öffentlichen Repository ohne Anmeldeinformationen	Wählen Sie diese Option, um auf ein öffentliches Repository zuzugreifen.

7. Wählen Sie Add repository (repository hinzufügen) aus.

Aktualisieren oder Löschen eines Git-basierten Repositorys

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

In den folgenden Abschnitten finden Sie Informationen zum Löschen eines Git-basierten Repositorys aus einem EMR-Notebook in der alten Konsole oder aus einem EMR Studio Workspace in der neuen Konsole.

New console

Da es sich bei EMR Notebooks in der neuen Konsole um EMR-Studio-Workspaces handelt, finden Sie weitere Informationen zur Arbeit mit Git-Repositorys in Ihrem Workspace unter Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen. Derzeit können Sie Git-Repositorys jedoch nicht aus Workspaces löschen.

Old console

Wie Sie ein Git-basiertes Repository in der alten Konsole aktualisieren

1. Wählen Sie auf der Seite Git repositories (Git-Repositorys) das Repository aus, das Sie aktualisieren möchten.
2. Wählen Sie auf der Repository-Seite Edit Repositiory (Repository bearbeiten).

3. Aktualisieren Sie die Angaben unter Git credentials (Git-Anmeldeinformationen) auf der Repository-Seite.

So löschen Sie ein Git-Repository in der alten Konsole

1. Wählen Sie auf der Seite Git repositories (Git-Repositorys) das Repository aus, das Sie löschen möchten.
2. Wählen Sie auf der Repository-Seite alle Notebooks aus, die derzeit mit dem Repository verknüpft sind. Wählen Sie Unlink Notebook (Notebook-Verknüpfung aufheben).
3. Wählen Sie auf der Repository-Seite Delete (Löschen).

> **Note**
>
> Um das lokale Git-Repository aus Amazon EMR löschen zu können, müssen Sie zuerst die Verknüpfung aller Notebooks mit diesem Repository aufheben. Weitere Informationen finden Sie unter Verknüpfen oder Aufheben der Verknüpfung eines Git-basierten Repositorys. Wenn Sie ein Git-Repository löschen, werden keine für das Repository erstellten Geheimnisse gelöscht. Sie können das Secret in AWS Secrets Manager löschen.

Verknüpfen oder Aufheben der Verknüpfung eines Git-basierten Repositorys

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Gehen Sie wie folgt vor, um ein Git-basiertes Repository mit einem EMR-Notebook in der alten Konsole oder mit einem EMR Studio Workspace in der neuen Konsole zu verknüpfen oder die Verknüpfung aufzuheben.

New console

Da es sich bei EMR Notebooks in der neuen Konsole um EMR-Studio-Workspaces handelt, finden Sie weitere Informationen zur Arbeit mit Git-Repositorys in Ihrem Workspace unter Git-basierte Repositorys mit einem EMR Studio Workspace verknüpfen. Derzeit können Sie Git-Repositorys jedoch nicht aus Workspaces löschen.

Old console

So verknüpfen Sie ein Git-basiertes Repository mit einem EMR-Notebook

Das Repository kann mit einem Notebook verknüpft werden, sobald der Status des Notebooks Ready (Bereit) lautet.

1. Wählen Sie in der Liste Notebooks das Notebook aus, das Sie aktualisieren möchten.
2. Wählen Sie im Bereich Git repositories (Git-Repositorys) auf der Seite Notebook die Option Link new repository (Neues Repository verknüpfen) aus.
3. Wählen Sie in der Repository-Liste des Fensters Link Git repository to notebook (Git-Repository mit Notebook verknüpfen) ein oder mehrere Repositorys aus, die Sie mit Ihrem Notebook verknüpfen möchten, und klicken Sie dann auf Link repository (Repository verknüpfen).

Or

1. Wählen Sie auf der Seite Git repositories (Git-Repositorys) das Repository aus, das Sie mit Ihrem Notebook verknüpfen möchten.
2. Wählen Sie in der Liste EMR notebooks (EMR-Notebooks) die Option Link new notebook (Neues Notebook verknüpfen) aus, um dieses Repository mit einem vorhandenen Notebook zu verknüpfen.

So heben Sie die Verknüpfung eines Git-Repositorys mit einem EMR-Notebook auf

1. Wählen Sie in der Liste Notebooks das Notebook aus, das Sie aktualisieren möchten.

2. Wählen Sie in der Liste Git repositories (Git-Repositories) das Repository aus, dessen Verknüpfung mit Ihrem Notebook Sie aufheben möchten, und wählen Sie dann Unlink repository (Verknüpfung des Repositorys aufheben).

Or

1. Wählen Sie auf der Seite Git repositories (Git-Repositorys) das Repository aus, an dem Sie Aktualisierungen vornehmen möchten.
2. Wählen Sie in der Liste EMR notebooks (EMR-Notebooks) das Notebook aus, dessen Verknüpfung mit dem Repository Sie aufheben möchten, und wählen Sie dann Unlink notebook (Verknüpfung des Notebooks aufheben).

> **Note**
>
> Wenn Sie ein Git-Repository mit einem Notebook verknüpfen, wird das Remote-Repository auf Ihrem lokalen Jupyter-Notebook geklont. Durch das Aufheben der Verknüpfung des Git-Repositorys mit einem Notebook wird das Notebook vom Remote-Repository getrennt, das lokale Git-Repository aber nicht gelöscht.

Grundlegendes zum Repository-Status

Ein Git-Repository kann beliebige der folgenden Status in der Repository-Liste aufweisen. Für weitere Informationen zum Verknüpfen von EMR-Notebooks mit Git-Repositorys siehe Verknüpfen oder Aufheben der Verknüpfung eines Git-basierten Repositorys.

Status	Bedeutung
Verknüpfen	Das Git-Repository wird mit dem Notebook verknüpft. Während der Status des Repositorys Linking (Verknüpfung wird hergestellt) lautet, können Sie das Notebook anhalten.
Verknüpft	Das Git-Repository ist mit dem Notebook verknüpft. Solange das Repository den Status

Status	Bedeutung
	Linked (Verknüpft) aufweist, ist es mit dem Remote-Repository verbunden.
Verknüpfung fehlgeschlagen	Das Git-Repository konnte nicht mit dem Notebook verknüpft werden. Sie können erneut versuchen, es zu verknüpfen.
Verknüpfung aufheben	Die Verknüpfung des Git-Repositorys mit dem Notebook wird aufgehoben. Während der Status des Repositorys Unlinking (Verknüpf ung wird aufgehoben) lautet, können Sie das Notebook nicht anhalten. Durch das Aufheben der Verknüpfung eines Git-Repositorys mit einem Notebook wird nur die Verbindung mit dem Remote-Repository getrennt; es wird kein Code aus dem Notebook gelöscht.
Verknüpfung aufheben fehlgeschlagen	Das Git-Repository konnte die Verknüpfung mit dem Notebook nicht aufheben. Sie können erneut versuchen, die Verknüpfung aufzuhebe n.

Erstellen eines neuen Notebooks mit einem zugehörigen Git-Repository

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

So erstellen Sie ein Notebook und ordnen es Git-Repositorys in der alten Amazon-EMR-Konsole zu

1. Folgen Sie den Anweisungen unter Erstellen eines Notebook.
2. Wählen Sie für Security group (Sicherheitsgruppe) die Option Use your own security group (Eigene Sicherheitsgruppe verwenden) aus.

   > **Note**
   >
   > Die Sicherheitsgruppen für Ihr Notebook müssen eine Regel für ausgehenden Datenverkehr enthalten, sodass das Notebook Datenverkehr über den Cluster an das Internet weiterleiten kann. Wir empfehlen, eigene Sicherheitsgruppen zu erstellen. Weitere Informationen finden Sie unter Angeben von EC2-Sicherheitsgruppen für EMR Notebooks.

3. Wählen Sie für Git repositories (Git-Repositorys) unter Choose repository (Repository wählen) das Repository aus, das dem Notebook zugeordnet werden soll.

   1. Wählen Sie ein Repository aus, das als Ressource in Ihrem Konto gespeichert ist, und wählen Sie dann Save (Speichern).
   2. Um ein neues Repository als Ressource in Ihrem Konto hinzuzufügen, wählen Sie add a new repository (Neues Repository hinzufügen). Führen Sie den Workflow Add repository (Repository hinzufügen) in einem neuen Fenster durch.

Verwenden von Git-Repositorys in einem Notebook

> **Note**
>
> EMR-Notebooks sind in der neuen Konsole als EMR Studio Workspaces verfügbar. Sie können Ihre vorhandenen Notebooks weiterhin in der alten Konsole verwenden, aber Sie können in der alten Konsole keine neuen Notebooks erstellen. Die Schaltfläche Workspace erstellen in der neuen Konsole ersetzt diese Funktion. Um auf Workspaces zuzugreifen oder diese zu erstellen, benötigen EMR-Notebook-Benutzer zusätzliche IAM-Rollenberechtigungen. Weitere Informationen finden Sie unter Amazon EMR Notebooks sind Amazon EMR Studio Workspaces in der neuen Konsole und Was ist neu in der Konsole?

Sie können zum Öffnen eines Notebooks Open in JupyterLab (In JupyterLab öffnen) oder Open in Jupyter (In Jupyter öffnen) wählen.

Wenn Sie das Notebook in Jupyter öffnen, wird eine Liste erweiterbarer Dateien und Ordner im Notebook angezeigt. Sie können Git-Befehle wie die folgenden manuell in einer Notebook-Zelle ausführen.

```
!git pull origin primary
```

Zum Öffnen der zusätzlichen Repositorys wechseln Sie in andere Ordner.

Wenn Sie das Notebook mit einer JupyterLab-Schnittstelle öffnen, können Sie die vorinstallierte JupyterLab-Git-Erweiterung verwenden. Weitere Informationen über die Erweiterung finden Sie unter jupyterlab-git.

Cluster planen und konfigurieren

In diesem Abschnitt werden die Konfigurationsoptionen und Anweisungen für das Planen, Konfigurieren und Starten von Clustern mit Amazon EMR beschrieben. Bevor Sie einen Cluster starten, treffen Sie Entscheidungen hinsichtlich Ihres Systems auf der Grundlage der Daten, die Sie verarbeiten, und Ihrer Anforderungen an Kosten, Geschwindigkeit, Kapazität, Verfügbarkeit, Sicherheit und Verwaltbarkeit. Ihre Entscheidungen betreffen u. a. Folgendes:

- Welche Region in einem Cluster ausgeführt wird, wo und wie Daten gespeichert werden und wie Ergebnisse ausgegeben werden. Siehe Cluster-Standort und Datenspeicher konfigurieren.
- Wenn Sie Amazon-EMR-Cluster in Outposts oder Local Zones ausführen. Weitere Informationen unter EMR-Cluster auf AWS Outposts oder EMR-Cluster in AWS Local Zones.
- Die Frage, ob ein Cluster von langer Dauer oder vorübergehend ist, und welche Software dort ausgeführt wird. Siehe Konfigurieren eines Clusters zum Fortfahren oder Beenden nach der Schrittausführung und Konfigurieren der Cluster-Software.
- Wenn ein Cluster einen einzelnen Primärknoten oder drei Primärknoten besitzt. Siehe Primärknoten planen und konfigurieren.
- Die Hardware- und Netzwerkoptionen, mit denen Kosten, Leistung und Verfügbarkeit Ihrer Anwendung optimiert werden. Siehe Cluster-Hardware und Netzwerken konfigurieren.
- Die Einrichtung von Clustern für eine leichtere Verwaltung sowie die Überwachung von Aktivitäten, Leistung und Zustand. Siehe Konfigurieren der Cluster-Protokollierung und des Debuggings und Tag-Cluster.
- Authentifizierung und Autorisierung des Zugriffs auf Cluster-Ressourcen und Verschlüsselung von Daten. Siehe Sicherheit in Amazon EMR.
- Die Integration in andere Software und Services. Siehe Treiber und Drittanbieter-Anwendungsintegration.

Schnell einen Cluster starten

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So starten Sie schnell einen Cluster mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr/clusters.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Geben Sie auf der Seite Cluster erstellen Werte für die bereitgestellten Felder ein oder wählen Sie sie aus. Das persistente Übersichtsfenster zeigt eine Echtzeitansicht Ihrer aktuell ausgewählten Clusteroptionen an. Wählen Sie im Übersichtsfenster eine Überschrift aus, um zum entsprechenden Abschnitt zu navigieren und Anpassungen vorzunehmen. Sie müssen alle erforderlichen Konfigurationen abschließen, bevor Sie Cluster erstellen auswählen können.
4. Wählen Sie Cluster erstellen aus, um die Konfiguration wie im Image gezeigt zu akzeptieren.
5. Dadurch wird die Cluster-Detailseite geöffnet. Suchen Sie den Cluster-Status neben dem Clusternamen. Der Status sollte sich während des Clustererstellungsprozesses von Startet zu Läuft zu Warten ändern. Möglicherweise müssen Sie das Aktualisierungssymbol oben rechts auswählen oder Ihren Browser aktualisieren, um Updates zu erhalten.

   Wenn sich der Status in Warten ändert, ist Ihr Cluster betriebsbereit und bereit, Schritte und SSH-Verbindungen anzunehmen.

Old console

Verwenden Sie die Seite Create Cluster – Quick Options in der alten Amazon-EMR-Konsole, um schnell einen Cluster für einfache Aufgaben oder für Evaluierungs- oder Testzwecke zu erstellen. Schnelloptionen verwendet Standardwerte für Konfigurationsoptionen wie Cluster-Software, Netzwerk und Sicherheit.

Wie Sie einen Cluster mit Schnelloptionen mit der alten Konsole starten

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Cluster und anschließend Cluster erstellen, um die Seite mit den Schnelloptionen zu öffnen.

3. Geben Sie auf der Seite Cluster erstellen – Schnelloptionen Werte für die bereitgestellten Felder ein oder wählen Sie sie aus.
4. Wählen Sie Cluster erstellen aus, um den Cluster zu starten und die Cluster-Statusseite zu öffnen.
5. Suchen Sie auf der Cluster-Statusseite neben dem Cluster-Namen nach dem Cluster-Status. Der Status sollte sich während des Clustererstellungsprozesses von Startet zu Läuft zu Warten ändern. Möglicherweise müssen Sie das Aktualisierungs-Symbol auf der rechten Seite betätigen oder Ihren Browser aktualisieren, um Updates zu erhalten.

   Wenn sich der Status in Warten ändert, ist Ihr Cluster betriebsbereit und bereit, Schritte und SSH-Verbindungen anzunehmen.

Cluster-Standort und Datenspeicher konfigurieren

In diesem Abschnitt wird beschrieben, wie Sie die Region für einen Cluster konfigurieren, welche verschiedenen Dateisysteme mit Amazon EMR zur Verfügung stehen und wie sie verwendet werden. Außerdem wird erläutert, wie Sie Daten vorbereiten ober bei Bedarf in Amazon EMR hochladen und wie Sie einen Ausgabespeicherort für Protokolldateien und andere Ausgabedatendateien, die Sie konfigurieren, vorbereiten.

Themen

- Eine AWS-Region auswählen
- Mit Storage- und Dateisystemen arbeiten
- Eingabedaten vorbereiten
- Einen Ausgabespeicherort konfigurieren

Eine AWS-Region auswählen

Amazon Web Services wird auf Servern in Rechenzentren auf der ganzen Welt ausgeführt. Die Rechenzentren sind nach geografischer Region organisiert. Wenn Sie einen Amazon-EMR-Cluster starten, müssen Sie eine Region angeben. So können Sie eine Region auswählen, die die Latenz oder die Kosten verringert oder behördliche Vorschriften erfüllt. Die Liste der von Amazon EMR unterstützten Regionen und Endpunkte finden Sie unter Regionen und Endpunkte im Allgemeine Amazon Web Services-Referenz.

Um eine optimale Leistung zu erzielen, sollten Sie den Cluster in derselben Region starten wie Ihre Daten. Wenn sich der Amazon-S3-Bucket, in dem Ihre Eingabedaten gespeichert sind, beispielsweise in der Region USA West (Oregon) befindet, sollten Sie Ihren Cluster in der Region USA West (Oregon) starten, um Gebühren für die regionsübergreifende Datenübertragung zu vermeiden. Wenn Sie einen Amazon-S3-Bucket für den Empfang der Cluster-Ausgabe verwenden, sollten Sie diesen Bucket ebenfalls in der Region USA West (Oregon) erstellen.

Wenn Sie vorhaben, ein Amazon-EC2-Schlüsselpaar mit dem Cluster zu verknüpfen (was für die Protokollierung mit SSH auf dem Hauptknoten erforderlich ist), muss das Schlüsselpaar in der gleichen Region erstellt werden wie der Cluster. Auch die Sicherheitsgruppen, die Amazon EMR zum Verwalten des Clusters erstellt, müssen sich in der gleichen Region wie der Cluster befinden.

Wenn Sie sich am oder nach dem 17. Mai 2017 für einen AWS-Konto angemeldet haben, ist die Standardregion, wenn Sie von der AWS Management Console aus auf eine Ressource zugreifen, USA Ost (Ohio) (us-east-2); für ältere Konten ist die Standardregion entweder USA West (Oregon) (us-west-2) oder USA Ost (Nord-Virginia) (us-east-1). Weitere Informationen finden Sie unter Regionen und Endpunkte.

Einige AWS-Feature sind nur in bestimmten Regionen verfügbar. Beispielsweise sind Cluster-Compute-Instances nur in der Region USA Ost (Nord-Virginia) verfügbar und die Region Asien-Pazifik (Sydney) unterstützt nur Hadoop 1.0.3 und höher. Prüfen Sie bei der Auswahl einer Region, dass die Feature, die Sie verwenden möchten, in dieser Region unterstützt werden.

Um eine optimale Leistung zu erzielen, verwenden Sie dieselbe Region für alle Ihre AWS-Ressourcen, die mit dem Cluster genutzt werden. In der folgenden Tabelle werden die Regionsnamen den Services zugeordnet. Die Liste der Amazon-EMR-Regionen finden Sie unter AWS-Regionen-Regionen und Endpunkte in der Allgemeine Amazon Web Services-Referenz.

Auswählen einer Region mithilfe der Konsole

Ihre Standardregion wird links neben Ihren Kontoinformationen in der Navigationsleiste angezeigt. Um die Region sowohl auf der neuen als auch auf der alten Konsole zu wechseln, wähle das Drop-down-Menü Region und wähle eine neue Option aus.

Eine Region mit dem AWS CLI angeben

Sie geben in der AWS CLI eine Standardregion an, indem Sie den Befehl aws configure oder die Umgebungsvariable `AWS_DEFAULT_REGION` verwenden. Weitere Informationen finden Sie unter Konfigurieren der AWS-Region im AWS Command Line Interface-Leitfaden.

Eine Region mithilfe eines SDK oder der API auswählen

Um eine Region mit einem SDK auszuwählen, Sie Ihre Anwendung für die Verwendung des Endpunkts dieser Region. Wenn Sie eine Client-Anwendung mit einem AWS-SDK erstellen, können Sie den Client-Endpunkt ändern, indem Sie `setEndpoint` wie im folgenden Beispiel gezeigt aufrufen:

```
client.setEndpoint("elasticmapreduce.us-west-2.amazonaws.com");
```

Nachdem Ihre Anwendung eine Region durch Festlegen des Endpunkts angegeben hat, können Sie die Availability Zone für die EC2-Instances Ihres Clusters bestimmen. Availability Zones sind eindeutige geografische Standorte. Sie sollen vor Fehlern in anderen Availability Zones schützen und eine kostengünstige Netzwerkkonnektivität mit geringer Latenz zu anderen Availability Zones in der gleichen Region bereitstellen. Eine Region umfasst eine oder mehr Availability Zones. Um die Leistung zu optimieren und die Latenz zu verkürzen, sollten sich alle Ressourcen in derselben Availability Zone befinden wie der Cluster, der sie verwendet.

Mit Storage- und Dateisystemen arbeiten

Amazon EMR und Hadoop bieten eine Vielzahl von Dateisystemen an, die Sie bei der Verarbeitung von Cluster-Schritten verwenden können. Sie geben über das Präfix des URI an, welches Dateisystem Sie nutzen möchten. Beispielsweise referenziert `s3://DOC-EXAMPLE-BUCKET1/path` einen Amazon-S3-Bucket mittels EMRFS. In der folgenden Tabelle werden die verfügbaren Dateisysteme sowie Empfehlungen zu ihrer Verwendung aufgeführt.

Amazon EMR und Hadoop verwenden bei der Ausführung eines Clusters normalerweise zwei oder mehr der folgenden Dateisysteme. HDFS und EMRFS sind zwei der wichtigsten mit Amazon EMR verwendeten Dateisysteme.

> **Important**
>
> Ab Amazon-EMR-Version 5.22.0 verwendet Amazon EMR AWS Signature Version 4 ausschließlich zur Authentifizierung von Anfragen an Amazon S3. Frühere Amazon-EMR-Versionen verwenden in einigen Fällen AWS Signature Version 2, sofern in den Versionshinweisen nicht angegeben ist, dass ausschließlich Signature Version 4 verwendet wird. Weitere Informationen finden Sie unter Authentifizierung von Anforderungen (AWS Signatur Version 4) und Authentifizierung von Anforderungen (AWS Signatur Version 2) im Entwicklerhandbuch für Amazon Simple Storage Service.

Dateisystem	Präfix	Beschreibung
HDFS	`hdfs://` (oder ohne Präfix)	HDFS ist ein verteiltes, skalierbares und portierbares Dateisystem für Hadoop. Ein Vorteil von HDFS ist, dass die Daten für die Hadoop-Cluster-Knoten zur Verwaltung der Cluster und die Hadoop-Cluster-Kno ten für die Verwaltung der einzelnen Schritte bekannt sind. Weitere Informationen finden Sie in der Hadoop-Dokumentation. HDFS wird von den Master- und Core-Knoten verwendet. Ein Vorteil ist, dass es schneller ist. Ein Nachteil ist, dass es ein flüchtiger Speicher ist. Dieser wird beim Beenden des Clusters verworfen. Es eignet sich am besten für die Zwischenspeicherung der Ergebnisse von zwischengeschalteten Auftragsv erlaufsschritten.
EMRFS	`s3://`	EMRFS ist eine Implementierung des Hadoop-Da teisystems, die zum direkten Lesen und Schreiben regulärer Dateien aus Amazon EMR zu Amazon S3 verwendet wird. EMRFS ermöglicht das Speichern persistenter Daten in Amazon S3 zur Verwendung mit Hadoop. Gleichzeitig sind Features wie die serversei tige Amazon-S3-Verschlüsselung, Read-after-Write-K onsistenz und Listenkonsistenz verfügbar. **Note** Zuvor verwendete Amazon EMR die Dateisyst eme `s3n` und `s3a` Dies funktioniert zwar noch, doch wir empfehlen, dass Sie das URI-Schem a `s3` verwenden. Es bietet mehr Leistung, Sicherheit und Zuverlässigkeit.
Lokales Dateisystem		Das lokale Dateisystem bezieht sich auf einen lokal verbundenen Datenträger. Wenn Sie einen Hadoop-

Dateisystem	Präfix	Beschreibung
		Cluster erstellen, werden die einzelnen Knoten aus einer EC2-Instance erstellt, die einen vorkonfigurierten Block mit bereits zugeordnetem Festplattenspeicher enthält, einen sogenannten Instance-Speicher. Die Daten auf den Instance-Speicher-Volumes bleiben nur während des Lebenszyklus der EC2-Instance erhalten. Instance-Speicher-Volumen eignen sich perfekt für die Speicherung von temporärer Daten, die sich ständig ändern (z. B. Puffer, Caches, Arbeitsdaten und andere temporäre Inhalte). Weitere Informationen finden Sie unter Amazon-EC2-Instance Speicher. Das lokale Dateisystem wird von HDFS verwendet, aber Python wird auch vom lokalen Dateisystem aus ausgeführt, und Sie können wählen, ob Sie zusätzliche Anwendungsdateien auf Instance-Speicher-Volumes speichern möchten.
Amazon-S3-Block-Dateisystem (veraltet)	`s3bfs://`	Das Amazon-S3-Block-Dateisystem ist ein veraltetes Dateispeichersystem. Es wird ausdrücklich von der Verwendung dieses Systems abgeraten. **Important** Wir empfehlen, dass Sie dieses Dateisystem nicht verwenden. Es kann dazu führen, dass der Cluster ausfällt. Möglicherweise ist es jedoch für ältere Anwendungen erforderlich.

Zugriff auf Dateisysteme

Sie geben über das Präfix des URI (Uniform Resource Identifier) für den Zugriff auf die Daten an, welches Dateisystem Sie nutzen möchten. Die folgenden Verfahren veranschaulichen den Zugriff auf verschiedene Dateisystemarten.

So greifen Sie auf ein lokales HDFS zu

- Geben Sie in `hdfs:///`-Präfix im URI an. Amazon EMR löst Pfade ohne Präfix im URI für das lokale HDFS auf. Beispielsweise führen die folgenden URIs zum selben Speicherort in HDFS.

```
hdfs:///path-to-data

/path-to-data
```

So greifen Sie auf ein Remote-HDFS zu

- Fügen Sie, wie in den folgenden Beispielen dargestellt, die IP-Adresse des Master-Knotens zum URI hinzu.

```
hdfs://master-ip-address/path-to-data

master-ip-address/path-to-data
```

So greifen Sie auf Amazon S3 zu

- Verwenden Sie den `s3://`-Präfix.

```
s3://bucket-name/path-to-file-in-bucket
```

So greifen Sie auf das Amazon-S3-Block-Dateisystem zu

- Verwenden Sie dieses Dateisystem nur für ältere Anwendungen, die das Amazon-S3-Block-Dateisystem benötigen. Für den Zugriff auf Daten mit diesem Dateisystem verwenden Sie das `s3bfs://`-Präfix im URI.

  Das Amazon-S3-Block-Dateisystem ist ein veraltetes Dateisystem, das für Uploads zu Amazon S3 mit einer Größe von mehr als 5 GB verwendet wurde. Mittels der Funktionalität für mehrteilige

Uploads, die Amazon EMR über das AWS-SDK für Java bereitstellt, können Sie Dateien mit einer Größe von bis zu 5 TB zum nativen Dateisystem von Amazon S3 hochladen. Das Amazon-S3-Block-Dateisystem ist daher veraltet.

> **Warning**
>
> Da dieses veraltete Dateisystem zu Beschädigungen führen kann, sollten Sie es vermeiden. Verwenden Sie stattdessen EMRFS.

```
s3bfs://bucket-name/path-to-file-in-bucket
```

Eingabedaten vorbereiten

Die meisten Clustern laden Eingabedaten und verarbeitet diese anschließend. Zum Laden von Daten müssen diese sich an einem Speicherort befinden, auf den der Cluster zugreifen kann und der ein Format hat, das der Cluster verarbeiten kann. Das gängigste Szenario ist das zum Hochladen von Eingabedaten in Amazon S3. Amazon EMR bietet Tools, mit denen Ihr Cluster Daten aus Amazon S3 importieren oder lesen kann.

Das Standardeingabeformat in Hadoop sind Textdateien. Sie können Hadoop jedoch anpassen und Tools zum Importieren von Daten in anderen Formaten verwenden.

Themen

- Arten von Eingabedaten, die Amazon EMR akzeptieren kann
- So laden Sie Daten in Amazon EMR

Arten von Eingabedaten, die Amazon EMR akzeptieren kann

Das Standardeingabeformat für einen Cluster sind Textdateien, bei denen jede Zeile durch ein Zeilenvorschubzeichen (\ n) getrennt ist. Dies ist das am häufigsten verwendete Eingabeformat.

Wenn Ihre Eingabedaten in einem anderen Format geschrieben werden müssen als Standardtextdateien, können Sie die Hadoop-Benutzeroberfläche `InputFormat` verwenden, um andere Eingabetypen anzugeben. Sie können auch eine Unterklasse der `FileInputFormat`-Klasse

für den Umgang mit benutzerdefinierten Datentypen verwenden. Weitere Informationen finden Sie unter http://hadoop.apache.org/docs/current/api/org/apache/hadoop/mapred/InputFormat.html.

Wenn Sie Hive verwenden, können Sie einen Serializer/Deserializer (SerDe) verwenden, um Daten in einem bestimmten Format in HDFS einzulesen. Weitere Informationen finden Sie unter https://cwiki.apache.org/confluence/display/Hive/SerDe.

So laden Sie Daten in Amazon EMR

Amazon EMR bietet mehrere Möglichkeiten, um Daten auf einen Cluster zu laden. Die häufigste Methode besteht im Hochladen der Daten zu Amazon S3 und der Verwendung der integrierten Features von Amazon EMR, um die Daten in Ihren Cluster zu laden. Sie können auch das Hadoop-Feature für den verteilten Cache verwenden, um Dateien von einem verteilten Dateisystem in das lokale Dateisystem zu übertragen. Die von Amazon EMR bereitgestellte Hive-Implementierung (Hive-Version 0.7.1.1 und höher) enthält Funktionen, die Sie zum Importieren und Exportieren von Daten zwischen DynamoDB und einen Amazon-EMR-Cluster verwenden können. Wenn Sie große Datenmengen On-Premises verarbeiten müssen, kann der AWS Direct Connect-Service nützlich sein.

Themen

- Daten aus Amazon S3 uploaden
- Daten mit AWS DataSync hochladen
- Dateien mit verteiltem Cache importieren
- So verarbeiten Sie komprimierte Dateien
- DynamoDB-Daten in Hive importieren
- Verbindung zu Daten mit AWS Direct Connect herstellen
- Große Datenmengen mit AWS Snowball hochladen

Daten aus Amazon S3 uploaden

Informationen zum Hochladen von Objekten in Amazon S3 finden Sie unter Ein Objekts zu Ihrem Bucket hinzufügen im Benutzerhandbuch zu Amazon Simple Storage Service. Weitere Informationen zur Verwendung von Amazon S3 mit Hadoop finden Sie unter http://wiki.apache.org/hadoop/AmazonS3.

Themen

- Erstellen und Konfigurieren eines Amazon S3-Buckets

- Konfigurieren von mehrteiligen Uploads für Amazon S3
- Bewährte Methoden

Erstellen und Konfigurieren eines Amazon S3-Buckets

Amazon EMR verwendet AWS SDK for Java mit Amazon S3 zum Speichern von Eingabedaten, Protokolldateien und Ausgabedaten. Amazon S3 bezeichnet diese Speicherorte als Buckets. Buckets haben in Übereinstimmung mit den Amazon-S3- und DNS-Anforderungen bestimmte Einschränkungen und Bedingungen. Weitere Informationen finden Sie unter Bucket-Einschränkungen und -Limits im Benutzerhandbuch zu Amazon Simple Storage Service.

In diesem Abschnitt wird die Verwendung der Amazon S3 AWS Management Console zur Erstellung von Amazon-S3-Buckets und zur Festlegung von Berechtigungen für diese gezeigt. Sie können Berechtigungen für einen Amazon-S3-Bucket auch über die Amazon-S3-API oder die AWS CLI erstellen und festlegen. Sie können Curl auch zusammen mit einer Änderung verwenden, um die entsprechenden Authentifizierungsparameter für Amazon S3 zu übergeben.

Weitere Informationen finden Sie in den folgenden Ressourcen:

- Informationen zur Bucket-Erstellung mittels Konsole finden Sie unter Erstellen eines Buckets im Amazon-S3-Benutzerhandbuch.
- Informationen zum Erstellen und Arbeiten mit Buckets mithilfe des AWS CLI finden Sie unter Verwenden von S3-Befehlen auf hoher Ebene mit dem AWS Command Line Interface im Amazon-S3-Benutzerhandbuch.
- Informationen zum Erstellen eines Buckets mithilfe eines SDK finden Sie unter Beispiele für die Erstellung eines Buckets im Benutzerhandbuch für Amazon Simple Storage Service.
- Informationen zum Arbeiten mit Buckets über Curl finden Sie unter Amazon-S3-Authentifizierungstool für Curl.
- Weitere Informationen zum Angeben regionsspezifischer Buckets finden Sie unter Zugreifen auf einen Bucket im Benutzerhandbuch für Amazon Simple Storage Service.
- Informationen zum Arbeiten mit Buckets unter Verwendung von Amazon S3 Access Points finden Sie unter Verwenden eines Alias im Bucket-Stil für Ihren Zugangspunkt im Amazon-S3-Benutzerhandbuch. Sie können Amazon S3 Access Points problemlos mit dem Alias von Amazon S3 Access Points anstelle des Amazon-S3-Bucket-Namens verwenden. Sie können den Alias Amazon S3 Access Point sowohl für bestehende als auch für neue Anwendungen verwenden, darunter Spark, Hive, Presto und andere.

> **Note**
>
> Wenn Sie für einen Bucket die Option „Protokollierung“ aktivieren, werden nur Bucket-Zugriffslogs aktiviert und nicht Amazon-EMR-Cluster-Logs.

Während der Bucket-Erstellung oder danach können Sie die entsprechenden Berechtigungen für den Zugriff auf den Bucket festlegen, abhängig von Ihrer Anwendung. Hierbei sollten Sie sich selbst (als Eigentümer) Lese- und Schreibzugriff und anderen autorisierten Benutzern Lesezugriff erteilen.

Erforderliche Amazon-S3-Buckets müssen vorhanden sein, bevor Sie einen Cluster erstellen können. Sie müssen alle erforderlichen Skripts und Daten auf Amazon S3 hochladen, auf die im Cluster verwiesen wird. In der folgenden Tabelle werden Beispiele für Speicherorte für Daten, Skripts und Protokolldateien beschrieben.

Konfigurieren von mehrteiligen Uploads für Amazon S3

Amazon EMR unterstützt mehrteilige Uploads in Amazon S3 über das AWS-SDK für Java. Mit dem mehrteiligen Upload können Sie ein einzelnes Objekt in mehreren Teilen hochladen. Sie können diese Objektteile unabhängig und in beliebiger Reihenfolge hochladen. Wenn die Übertragung eines Teils fehlschlägt, können Sie das Teil erneut übertragen, ohne dass dies Auswirkungen auf andere Teile hat. Nachdem alle Teile Ihres Objekts hochgeladen sind, fügt Amazon S3 diese Teile zusammen und erstellt das Objekt.

Weitere Informationen finden Sie unter Mehrteiliger Upload – Übersicht im Benutzerhandbuch zu Amazon Simple Storage Service.

Darüber hinaus stellt Amazon EMR Eigenschaften bereit, mit denen Sie die Bereinigung fehlgeschlagener mehrteiliger Uploads genauer steuern können.

In der folgenden Tabelle werden die Amazon-EMR-Konfigurationsparameter für mehrteilige Uploads beschrieben. Sie können diese mit der Konfigurationsklassifizierung `core-site` konfigurieren. Weitere Informationen finden Sie unter Konfigurieren von Anwendungen in den Amazon-EMR-Versionshinweisen.

Name des Konfigurationsparameters	Standardwert	Beschreibung
`fs.s3n.multipart.uploads.enabled`	`true`	Dieser Boolesche Typ gibt an, ob mehrteilige Uploads aktiviert werden sollen. Wenn

Name des Konfigurationsparameters	Standardwert	Beschreibung
		EMRFS konsistente Ansicht aktiviert ist, sind mehrteilige Uploads standardmäßig aktiviert. Eine Festlegung dieses Werts auf `false` wird ignoriert.
`fs.s3n.multipart.uploads.split.size`	`134217728`	Gibt die maximale Größe eines Teils in Byte an, bevor EMRFS einen neuen Teil-Upload startet, wenn die Funktion für mehrteilige Uploads aktiviert ist. Der Mindestwert ist `5242880` (5 MB). Wenn ein kleinerer Wert angegeben wird, wird `5242880` verwendet. Der Höchstwert ist `5368709120` (5 GB). Wenn ein größerer Wert angegeben wird, wird `5368709120` verwendet. Wenn die clientseitige EMRFS-Verschlüsselung und der Amazon S3 Optimized Committer deaktiviert sind, steuert dieser Wert auch die maximale Größe, die eine Datendatei erreichen kann, bis EMRFS zum Hochladen der Datei anstelle einer `PutObject` -Anfrage mehrteilige Uploads verwendet. Weitere Informationen finden Sie unter
`fs.s3n.ssl.enabled`	`true`	Dieser Boolesche Typ gibt an, ob HTTP oder HTTPS verwendet werden soll.
`fs.s3.buckets.create.enabled`	`false`	Ein boolescher Typ, der angibt, ob ein Bucket erstellt werden soll, wenn er nicht vorhanden ist. Wenn Sie dies auf `false` festlegen, wird eine Ausnahme für `CreateBucket` -Operationen ausgelöst.

Name des Konfigurationsparameters	Standardwert	Beschreibung
`fs.s3.multipart.clean.enabled`	`false`	Ein boolescher Typ, der angibt, ob unvollständige mehrteilige Uploads regelmäßig im Hintergrund bereinigt werden sollen.
`fs.s3.multipart.clean.age.threshold`	`604800`	Ein long-Typ, der das Mindestalter eines mehrteiligen Uploads in Sekunden angibt, bevor er zur Bereinigung vorgesehen wird. Die Standardeinstellung ist eine Woche.
`fs.s3.multipart.clean.jitter.max`	`10000`	Eine integer-Typ, der den maximalen Betrag für zufällige Jitter-Verzögerungen in Sekunden angibt, die der festen Verzögerung von 15 Minuten hinzugefügt werden, bevor die nächste Bereinigung geplant wird.

So deaktivieren Sie mehrteilige Uploads

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So deaktivieren Sie mehrteilige Uploads mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.

3. Geben Sie in Softwareeinstellungen bearbeiten die folgende Konfiguration ein: `classification=core-site,properties=[fs.s3n.multipart.uploads.enabled=false]`.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So deaktivieren Sie mehrteilige Uploads mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.
3. Geben Sie in Softwareeinstellungen bearbeiten die folgende Konfiguration ein: `classification=core-site,properties=[fs.s3n.multipart.uploads.enabled=false]`
4. Fahren Sie mit der Erstellung des Clusters fort.

CLI

So deaktivieren Sie mehrteilige Uploads mit der AWS CLI

In diesem Verfahren wird erläutert, wie Sie mehrteilige Uploads mithilfe der AWS CLI deaktivieren. Um mehrteilige Uploads zu deaktivieren, geben Sie den Befehl `create-cluster` mit dem Parameter `--bootstrap-actions` ein.

1. Erstellen Sie eine Datei mit dem Namen `myConfig.json` und dem folgenden Inhalt und speichern Sie sie in dem Verzeichnis, in dem Sie den Befehl ausführen:

```
[
  {
    "Classification": "core-site",
    "Properties": {
      "fs.s3n.multipart.uploads.enabled": "false"
    }
  }
```

```
]
```

2. Geben Sie den folgenden Befehl ein und ersetzen Sie *myKey* durch den Namen Ihres EC2-Schlüsselpaars.

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "Test cluster" \
--release-label emr-5.36.1 --applications Name=Hive Name=Pig \
--use-default-roles --ec2-attributes KeyName=myKey --instance-type m5.xlarge \
--instance-count 3 --configurations file://myConfig.json
```

CLI

So deaktivieren Sie den mehrteiligen Upload mithilfe der API

- Informationen zur programmgesteuerten Verwendung von Amazon S3-Multipart-Uploads finden Sie unter Verwenden des AWS SDK für Java für Multipart-Uploads im Benutzerhandbuch zu Amazon Simple Storage Service.

  Weitere Informationen zum AWS-SDK für Java finden Sie unter AWS-SDK für Java.

Bewährte Methoden

Nachfolgend sind die Empfehlungen für die Nutzung von Amazon-S3-Buckets mit EMR-Clustern aufgeführt.

Aktivieren von Versioning

Versioning ist eine empfohlene Konfiguration für Ihre Amazon S3-Buckets. Durch das Aktivieren von Versioning stellen Sie sicher, dass Sie auch versehentlich gelöschte oder überschriebene Daten wiederhergestellt werden können. Weitere Informationen finden Sie unter Verwenden von Versionsverwaltung im Benutzerhandbuch für Amazon Simple Storage Service.

Bereinigung mehrteiliger Uploads fehlgeschlagen

EMR-Clusterkomponenten verwenden standardmäßig mehrteilige Uploads über das AWS-SDK für Java mit Amazon-S3-APIs zum Schreiben von Protokolldateien und Ausgabedaten zu Amazon S3. Informationen zum Ändern von Eigenschaften im Zusammenhang mit dieser Konfiguration über Amazon EMR finden Sie unter Konfigurieren von mehrteiligen Uploads für Amazon S3. Es kann vorkommen, dass das Hochladen einer großen Datei zu einem unvollständigen mehrteiligen Upload in Amazon S3 führt. Wenn ein mehrteiliger Upload nicht erfolgreich abgeschlossen werden kann, belegt der laufende Vorgang Ihren Bucket und es fallen Speichergebühren an. Wir empfehlen die folgenden Optionen, um eine übermäßige Dateispeicherung zu vermeiden:

- Verwenden Sie für mit Amazon EMR verwendete Buckets eine Lebenszyklus-Konfigurationsregel in Amazon S3, um unvollständige mehrteilige Uploads drei Tage nach dem Startdatum des betreffenden Uploads zu entfernen. Mit Lebenszyklus-Konfigurationsregeln können Sie Speicherklasse und Lebensdauer von Objekten steuern. Weitere Informationen finden Sie unter Verwaltung des Objektlebenszyklus und Abbrechen unvollständiger mehrteiliger Uploads mit einer Bucket-Lebenszyklusrichtlinie.
- Sie aktivieren das Amazon-EMR-Feature für die Bereinigung mehrteiliger Uploads, indem Sie `fs.s3.multipart.clean.enabled` auf `TRUE` festlegen und andere Bereinigungsparameter optimieren. Diese Funktion ist bei einem hohen Volumen, einem großem Umfang und Clustern mit begrenzte Betriebszeit nützlich. In diesem Fall ist der `DaysAfterIntitiation`-Parameter einer Lebenszyklus-Konfigurationsregel möglicherweise zu lang, selbst wenn er auf das Minimum eingestellt ist, was zu Spitzen im Amazon-S3-Speicher führt. Die mehrteilige Bereinigung von Amazon EMR ermöglicht eine genauere Steuerung. Weitere Informationen finden Sie unter Konfigurieren von mehrteiligen Uploads für Amazon S3.

Versionsmarkierungen verwalten

Sie sollten eine Lebenszyklus-Konfigurationsregel in Amazon S3 aktivieren, um abgelaufene Objektlöschmarkierungen für versionierte Buckets, die Sie mit Amazon EMR verwenden, zu entfernen. Beim Löschen eines Objekts in einem versionierten Bucket wird eine Löschmarkierung erstellt. Wenn anschließend alle vorherigen Versionen des Objekts ablaufen, verbleibt eine Löschmarkierung für abgelaufene Objekte im Bucket. Löschmarkierungen werden Ihnen zwar nicht berechnet, die Entfernung abgelaufener Löschmarkierungen kann jedoch die Leistung von LIST-Anfragen verbessern. Weitere Informationen finden Sie unter Lebenszykluskonfiguration für einen Bucket mit Versionsverwaltung im Benutzerhandbuch zu Amazon Simple Storage Service.

Bewährte Methoden zur Leistungssteigerung

Je nach Workloads können bestimmte Nutzungsarten von EMR-Clustern und Anwendungen in diesen Clustern zu einer hohe Anzahl von Anfragen an einen Bucket führen. Weitere Informationen finden Sie unter Erwägungen zur Anforderungsrate und Leistung im Benutzerhandbuch zu Amazon Simple Storage Service.

Daten mit AWS DataSync hochladen

AWS DataSync ist ein Online-Datenübertragungsdienst, der den Prozess der Datenverschiebung zwischen Ihrem On-Premises-Speicher und AWS-Speicherservices oder zwischen AWS-Speicherservices vereinfacht, automatisiert und beschleunigt. DataSync unterstützt eine Vielzahl von On-Premises-Speichersystemen wie Hadoop Distributed File System (HDFS), NAS-Dateiserver und selbstverwalteten Objektspeicher.

Der gängigste Weg, Daten auf einen Cluster zu übertragen, besteht darin, die Daten auf Amazon S3 hochzuladen und die integrierten Features von Amazon EMR zu verwenden, um die Daten auf Ihren Cluster zu laden.

DataSync kann Ihnen dabei helfen, die folgenden Aufgaben zu erledigen:

- Replizieren Sie HDFS auf Ihrem Hadoop-Cluster auf Amazon S3 für Geschäftskontinuität
- HDFS nach Amazon S3 kopieren, um Ihre Data Lakes zu füllen
- Daten zwischen dem HDFS Ihres Hadoop-Clusters und Amazon S3 zur Analyse und Verarbeitung übertragen

Um Daten in Ihren S3-Bucket hochzuladen, stellen Sie zunächst einen oder mehrere DataSync-Agenten im selben Netzwerk wie Ihr On-Premises-Speicher bereit. Ein Agent ist eine virtuelle Maschine (VM), die zum Lesen von Daten oder zum Schreiben von Daten an einem selbstverwalteten Speicherort verwendet wird. Anschließend aktivieren Sie Ihre Agenten in dem AWS-Konto und AWS-Region, wo sich Ihr S3-Bucket befindet.

Nachdem Ihr Agent aktiviert wurde, erstellen Sie einen Quellstandort für Ihren On-Premises-Speicher, einen Zielort für Ihren S3-Bucket und eine Aufgabe. Eine Aufgabe ist ein Satz von zwei Speicherorten (Quelle und Ziel) und eine Reihe von Standardoptionen, die Sie verwenden, um das Verhalten der Aufgabe zu steuern.

Schließlich führen Sie Ihre DataSync-Aufgabe aus, um Daten von der Quelle zum Ziel zu übertragen.

Weitere Informationen finden Sie unter Erste Schritte mit AWS DataSync.

Dateien mit verteiltem Cache importieren

Themen

- Unterstützte Dateitypen
- Speicherort der zwischengespeicherten Dateien
- Auf zwischengespeicherte Dateien über Streaming-Anwendungen zugreifen
- Auf zwischengespeicherte Dateien über Streaming-Anwendungen zugreifen

Beim verteilten Cache handelt es sich um ein Hadoop-Feature, die die Effizienz erhöhen kann, wenn eine Zuordnungs- oder Reduzierungs-Aufgabe Zugriff auf allgemeine Daten benötigt. Wenn Ihr Cluster von vorhandenen Anwendungen oder Binärdateien abhängt, die bei der Erstellung des Clusters nicht installiert sind, können Sie den verteilten Cache zum Importieren dieser Dateien verwenden. Mit dieser Funktion kann ein Cluster-Knoten die importierten Dateien aus seinem lokalen Dateisystem lesen, anstatt die Dateien von anderen Cluster-Knoten abzurufen.

Weitere Informationen finden Sie unter http://hadoop.apache.org/docs/stable/api/org/apache/hadoop/filecache/DistributedCache.html.

Sie rufen den verteilten Cache beim Erstellen des Clusters auf. Die Dateien werden vor dem Starten des Hadoop-Auftrags nur für die Dauer des Auftrags im Cache zwischengespeichert. Sie können Dateien, die in einem beliebigen Hadoop-kompatiblen Dateisystem wie HDFS oder Amazon S3 gespeichert sind, im Cache zwischenspeichern. Die Standardgröße des Datei-Caches ist 10 GB. Zum Ändern der Größe des Caches konfigurieren Sie den Hadoop-Parameter `local.cache.size` mithilfe der Bootstrap-Aktion neu. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.

Unterstützte Dateitypen

Der verteilte Cache lässt sowohl einzelne Dateien als auch Archive zu. Einzelne Dateien werden schreibgeschützt zwischengespeichert. Für ausführbare und Binärdateien werden Ausführungsberechtigungen festgelegt.

Bei Archiven handelt es sich um eine oder mehrere Dateien im Paket, das mit einem Dienstprogramm wie `gzip` erstellt wird. Der verteilte Cache übergibt die komprimierten Dateien an die einzelnen Core-Knoten und dekomprimiert das Archiv im Rahmen des Cachings. Der verteilte Cache unterstützt die folgenden Komprimierungsformate:

- zip

- tgz
- tar.gz
- tar
- jar

Speicherort der zwischengespeicherten Dateien

Der verteilte Cache kopiert Dateien ausschließlich zu Core-Knoten. Wenn es im Cluster keine Core-Knoten gibt, kopiert der verteilte Cache die Dateien zum Primärknoten.

Der verteilte Cache weist die Cache-Dateien dem aktuellen Arbeitsverzeichnis des Zuordners und Reduzierers mithilfe von symbolischen Links zu. Ein symbolischer Link (symlink) ist ein Alias für einen Dateispeicherort, nicht der tatsächliche Speicherort. Der Wert des Parameters, `yarn.nodemanager.local-dirs` in `yarn-site.xml`, gibt den Speicherort der temporären Dateien an. Amazon EMR legt diesen Parameter auf `/mnt/mapred` oder eine Variante basierend auf dem Instance-Typ und der EMR-Version fest. Eine Einstellung kann die Werte `/mnt/mapred` und `/mnt1/mapred` haben, da der Instance-Typ über zwei flüchtige Volumes verfügt. Cache-Dateien befinden sich in einem Unterverzeichnis des Speicherorts für temporäre Dateien unter `/mnt/mapred/taskTracker/archive`.

Wenn Sie eine einzelne Datei zwischenspeichern wird sie über den verteilten Cache im Verzeichnis `archive` abgelegt. Wenn Sie ein Archiv zwischenspeichern, wird sie vom verteilten Cache dekomprimiert und es wird ein Unterverzeichnis in `/archive` mit demselben Namen wie das Archiv erstellt. Die einzelnen Dateien befinden sich im neuen Unterverzeichnis.

Sie können den verteilten Cache nur bei Verwendung von Streaming verwenden.

Auf zwischengespeicherte Dateien über Streaming-Anwendungen zugreifen

Um aus Ihren Mapper- oder Reducer-Anwendungen auf die zwischengespeicherten Dateien zugreifen zu können, müssen Sie Ihrem Anwendungspfad das aktuelle Arbeitsverzeichnis (./) hinzufügen und die zwischengespeicherten Dateien so referenzieren, als würden sie sich im aktuellen Arbeitsverzeichnis befinden.

Auf zwischengespeicherte Dateien über Streaming-Anwendungen zugreifen

Sie können die AWS Management Console und AWS CLI zum Erstellen von Clustern verwenden, die den verteilten Cache nutzen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So geben Sie verteilte Cache-Dateien mithilfe der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Schritte die Option Schritt hinzufügen aus. Dadurch wird das Dialogfeld Schritt hinzufügen geöffnet. Geben Sie im Feld Argumente die Dateien und Archive an, die im Cache gespeichert werden sollen. Die Größe der Datei (oder Gesamtgröße der Dateien in einer Archivdatei) muss geringer sein als die zugewiesene Cachegröße.

   Wenn Sie eine einzelne Datei zum verteilten Cache hinzufügen möchten, geben Sie `-cacheFile` an, gefolgt vom Namen und Speicherort der Datei, dem Rautenzeichen (#) und dem Namen, den Sie der Datei geben möchten, wenn sie im lokalen Cache abgelegt wird. Im folgenden Beispiel wird gezeigt, wie eine einzelne Datei zum verteilten Cache hinzugefügt wird.

   ```
   -cacheFile \
   s3://DOC-EXAMPLE-BUCKET/file-name#cache-file-name
   ```

   Geben Sie `-cacheArchive` gefolgt von dem Speicherort der Dateien in Amazon S3, dem Rautenzeichen (#) und dann dem Namen ein, den Sie der Sammlung von Dateien im verteilten Cache geben möchten. Im folgenden Beispiel wird gezeigt, wie eine einzelne Datei zum verteilten Cache hinzugefügt wird.

   ```
   -cacheArchive \
   s3://DOC-EXAMPLE-BUCKET/archive-name#cache-archive-name
   ```

Geben Sie die entsprechenden Werte in die anderen Dialogfelder ein. Die Optionen unterscheiden sich je nach Schritttyp. Um Ihren Schritt hinzuzufügen und das Dialogfeld zu verlassen, wählen Sie Schritt hinzufügen.

4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So geben Sie verteilte Cache-Dateien mithilfe der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Step execution (Schrittausführung) als Startmodus aus.
4. Wählen Sie im Abschnitt Steps (Schritte) im Feld Add step (Schritt hinzufügen) in der Liste die Option Streaming program (Streaming-Programm) aus. Klicken Sie anschließend auf Configure and add (Konfigurieren und hinzufügen).
5. Geben Sie im Feld Argumente die Dateien und Archive an, die im Cache gespeichert werden sollen. Klicken Sie anschließend auf Hinzufügen. Die Größe der Datei (oder Gesamtgröße der Dateien in einer Archivdatei) muss geringer sein als die zugewiesene Cachegröße.

   Wenn Sie eine einzelne Datei zum verteilten Cache hinzufügen möchten, geben Sie `-cacheFile` an, gefolgt vom Namen und Speicherort der Datei, dem Rautenzeichen (#) und dem Namen, den Sie der Datei geben möchten, wenn sie im lokalen Cache abgelegt wird. Im folgenden Beispiel wird gezeigt, wie eine einzelne Datei zum verteilten Cache hinzugefügt wird.

   ```
   -cacheFile \
   s3://DOC-EXAMPLE-BUCKET/file_name#cache_file_name
   ```

   Geben Sie `-cacheArchive` gefolgt von dem Speicherort der Dateien in Amazon S3, dem Rautenzeichen (#) und dann dem Namen ein, den Sie der Sammlung von Dateien im verteilten Cache geben möchten. Im folgenden Beispiel wird gezeigt, wie eine einzelne Datei zum verteilten Cache hinzugefügt wird.

```
-cacheArchive \
s3://DOC-EXAMPLE-BUCKET/archive_name#cache_archive_name
```

6. Fahren Sie mit dem Konfigurieren und Starten Ihres Clusters fort. Vor der Verarbeitung von Cluster-Schritten kopiert Ihr Cluster die Dateien in den Cache-Standort.

CLI

So geben Sie verteilte Cache-Dateien mithilfe der AWS CLI an

- Um einen Streaming-Schritt beim Erstellen eines Clusters zu senden, geben Sie den Befehl `create-cluster` mit dem Parameter `--steps` ein. Um verteilte Cache-Dateien mit der AWS CLI anzugeben, legen Sie die entsprechenden Argumente beim Senden eines Streaming-Schritts fest.

  Wenn Sie eine einzelne Datei zum verteilten Cache hinzufügen möchten, geben Sie `-cacheFile` an, gefolgt vom Namen und Speicherort der Datei, dem Rautenzeichen (#) und dem Namen, den Sie der Datei geben möchten, wenn sie im lokalen Cache abgelegt wird.

  Geben Sie `-cacheArchive` gefolgt von dem Speicherort der Dateien in Amazon S3, dem Rautenzeichen (#) und dann dem Namen ein, den Sie der Sammlung von Dateien im verteilten Cache geben möchten. Im folgenden Beispiel wird gezeigt, wie eine einzelne Datei zum verteilten Cache hinzugefügt wird.

  Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Example 1

Geben Sie den folgenden Befehl zum Starten eines Clusters und zum Senden eines Streaming-Schritts ein, der `-cacheFile` zum Hinzufügen einer Datei, `sample_dataset_cached.dat`, zum Cache verwendet.

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.0.0 --
applications Name=Hive Name=Pig --use-default-roles --ec2-attributes KeyName=myKey
 --instance-type m5.xlarge --instance-count 3 --steps Type=STREAMING,Name="Streaming
 program",ActionOnFailure=CONTINUE,Args=["--files","s3://my_bucket/my_mapper.py
 s3://my_bucket/my_reducer.py","-mapper","my_mapper.py","-reducer","my_reducer.py","-
```

```
input","s3://my_bucket/my_input","-output","s3://my_bucket/my_output", "-
cacheFile","s3://my_bucket/sample_dataset.dat#sample_dataset_cached.dat"]
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

Wenn Sie zuvor nicht die standardmäßige EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie `aws emr create-default-roles` ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

Example 2

Der folgende Befehl erstellt einen Streaming-Cluster und verwendet `-cacheArchive`, um dem Cache ein Dateiarchiv hinzuzufügen.

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.0.0 --
applications Name=Hive Name=Pig --use-default-roles --ec2-attributes KeyName=myKey
 --instance-type m5.xlarge --instance-count 3 --steps Type=STREAMING,Name="Streaming
 program",ActionOnFailure=CONTINUE,Args=["--files","s3://my_bucket/my_mapper.py
 s3://my_bucket/my_reducer.py","-mapper","my_mapper.py","-reducer","my_reducer.py","-
input","s3://my_bucket/my_input","-output","s3://my_bucket/my_output", "-
cacheArchive","s3://my_bucket/sample_dataset.tgz#sample_dataset_cached"]
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

Wenn Sie zuvor nicht die standardmäßige EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie `aws emr create-default-roles` ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

So verarbeiten Sie komprimierte Dateien

Hadoop überprüft die Dateierweiterung zur Erkennung von komprimierten Dateien. Folgende Komprimierungstypen werden von Hadoop unterstützt: gzip, bzip2 und LZO. Sie müssen keine zusätzlichen Schritte ausführen, um Dateien dieser Komprimierungstypen zu extrahieren, da Hadoop diesen Vorgang für Sie erledigt.

Zum Indizieren von LZO-Dateien können Sie die Hadoop-lzo-Bibliothek verwenden, die Sie unter https://github.com/kevinweil/hadoop-lzoherunterladen können. Beachten Sie, dass es sich um eine Drittanbieter-Bibliothek handelt. Amazon EMR bietet daher keinen Entwickler-Support bei Verwendung dieses Tools. Informationen zur Nutzung finden Sie in der Readme-Datei für hadoop-lzo.

DynamoDB-Daten in Hive importieren

Die von Amazon EMR bereitgestellte Hive-Implementierung enthält Funktionalität, die Sie zum Importieren und Exportieren von Daten zwischen DynamoDB und einem Amazon-EMR-Cluster verwenden können. Dies ist nützlich, wenn Ihre Eingabedaten in DynamoDB gespeichert sind. Weitere Informationen finden Sie unter Exportieren, Importieren, Abfragen und Verknüpfen von Tabellen in DynamoDB mit Amazon EMR.

Verbindung zu Daten mit AWS Direct Connect herstellen

AWS Direct Connect ist ein Service, den Sie verwenden können, um eine private, dedizierte Netzwerkverbindung mit Amazon Web Services von Ihrem Rechenzentrum, Büro oder einer Co-Location-Umgebung herzustellen. Bei großen Eingabedatenmengen können Sie mit AWS Direct Connect Netzwerkkosten reduzieren und den Bandbreitendurchsatz steigern. Außerdem entsteht dadurch eine konsistentere Netzwerkfunktionalität als mit internetbasierten Verbindungen. Weitere Informationen finden Sie im AWS Direct Connect-Benutzerhandbuch.

Große Datenmengen mit AWS Snowball hochladen

AWS Snowball ist ein Service, mit dem Sie große Datenmengen zwischen Amazon Simple Storage Service (Amazon S3) und Ihrem lokalen Datenspeicherort schneller als im Internet übertragen können. Snowball unterstützt zwei Auftragstypen: Importaufträte und Exportaufträge. Importaufträge beinhalten eine Datenübertragung von einer On-Premises-Quelle zu einem Amazon-S3-Bucket. Exportaufträge beinhalten eine Datenübertragung aus einem Amazon-S3-Bucket zu einer On-Premises-Quelle. Bei beiden Auftragstypen sichern und schützen Snowball-Geräte Ihre Daten, während regionale Spediteure sie zwischen Amazon S3 und Ihrem Datenspeicherort vor Ort transportieren. Snowball-Geräte sind physisch robust und werden durch die AWS Key Management Service (AWS KMS) geschützt. Weitere Informationen finden Sie im AWS Snowball-Edge-Entwicklerhandbuch.

Einen Ausgabespeicherort konfigurieren

Das häufigste Ausgabeformat eines Amazon-EMR-Clusters sind Textdateien, und zwar entweder komprimiert oder nicht komprimiert. Diese Dateien werden in der Regel in einen Amazon-S3-Bucket

geschrieben. Dieser Bucket muss erstellt werden, bevor Sie den Cluster starten. Sie geben den S3-Bucket als Ausgabespeicherort an, wenn Sie den Cluster starten.

Weitere Informationen finden Sie unter den folgenden Themen:

Themen

- Erstellen und Konfigurieren eines Amazon S3-Buckets
- Welche Formate kann Amazon EMR zurückgeben?
- So schreiben Sie Daten in einen Amazon S3-Bucket, für den Sie keine Rechte haben
- Die Ausgabe Ihres Clusters komprimieren

Erstellen und Konfigurieren eines Amazon S3-Buckets

Amazon EMR (Amazon EMR) verwendet Amazon S3 zum Speichern von Eingabedaten, Protokolldateien und Ausgabedaten. Amazon S3 bezeichnet diese Speicherorte als Buckets. Buckets haben in Übereinstimmung mit den Amazon-S3- und DNS-Anforderungen bestimmte Einschränkungen und Bedingungen. Weitere Informationen finden Sie unter Bucket-Einschränkungen und -Limits im Amazon Simple Storage Service-Entwicklerhandbuch.

Um einen Amazon-S3-Bucket zu erstellen, befolgen Sie die Anweisungen auf der Seite Bucket erstellen im Benutzerhandbuch zu Amazon Simple Storage Service.

> **Note**
>
> Wenn Sie im Assistenten Bucket erstellen die Protokollierung aktivieren, werden nur Bucket-Zugriffsprotokolle aktiviert und nicht Cluster-Protokolle.

> **Note**
>
> Weitere Informationen zur Angabe regionsspezifischer Buckets finden Sie unter Buckets und Regionen im Entwicklerhandbuch zu Amazon Simple Storage Service und unter Verfügbare Regionsendpunkte für die AWS-SDKs.

Nachdem Sie Ihren Bucket erstellt haben, können Sie die entsprechenden Zugriffsberechtigungen hierzu einrichten. Hierbei sollten Sie sich selbst (als Eigentümer) Lese- und Schreibzugriff

erteilen. Wir empfehlen Ihnen dringend, bei der Konfiguration Ihres Buckets die bewährten Sicherheitsmethoden für Amazon S3 zu befolgen.

Erforderliche Amazon-S3-Buckets müssen vorhanden sein, bevor Sie einen Cluster erstellen können. Sie müssen alle erforderlichen Skripts und Daten auf Amazon S3 hochladen, auf die im Cluster verwiesen wird. In der folgenden Tabelle werden Beispiele für Speicherorte für Daten, Skripts und Protokolldateien beschrieben.

Informationen	Beispielspeicherort auf Amazon S3
Skript oder Programm	`s3://DOC-EXAMPLE-BUCKET1/script/MapperScript.py`
Protokolldateien	`s3://DOC-EXAMPLE-BUCKET1/logs`
Eingabedaten	`s3://DOC-EXAMPLE-BUCKET1/input`
Ausgabedaten	`s3://DOC-EXAMPLE-BUCKET1/output`

Welche Formate kann Amazon EMR zurückgeben?

Das Standardausgabeformat für einen Cluster ist Text mit Schlüssel-Wert-Paaren, die in einzelne Zeilen der Textdateien geschrieben werden. Dies ist das am häufigsten verwendete Ausgabeformat.

Wenn Ihre Ausgabedaten in einem anderen Format geschrieben werden müssen als Standardtextdateien, können Sie die Hadoop-Benutzeroberfläche `OutputFormat` verwenden, um andere Ausgabetypen anzugeben. Sie können auch eine Unterklasse der `FileOutputFormat`-Klasse für den Umgang mit benutzerdefinierten Datentypen verwenden. Weitere Informationen finden Sie unter http://hadoop.apache.org/docs/current/api/org/apache/hadoop/mapred/OutputFormat.html.

Wenn Sie einen Hive-Cluster starten, können Sie einen Serializer/Deserializer (SerDe) verwenden, um Daten von HDFS in einem bestimmten Format auszugeben. Weitere Informationen finden Sie unter https://cwiki.apache.org/confluence/display/Hive/SerDe.

So schreiben Sie Daten in einen Amazon S3-Bucket, für den Sie keine Rechte haben

Wenn Sie eine Datei in einen Amazon Simple Storage Service (Amazon S3)-Bucket schreiben, können standardmäßig nur Sie die Datei lesen. Es wird davon ausgegangen, dass Sie Dateien in Ihre Buckets schreiben. Diese Standardeinstellung dient dem Schutz Ihrer Dateien.

Wenn Sie jedoch einen Cluster ausführen und die Ausgabe in den Amazon-S3-Bucket eines anderen AWS-Benutzers schreiben und dieser AWS-Benutzer diese Ausgaben lesen können soll, müssen Sie zwei Vorgänge ausführen:

- Der andere AWS-Benutzer muss Ihnen Schreibberechtigungen für den Amazon-S3-Bucket erteilen. Der Cluster, den Sie starten, wird unter Ihren AWS-Anmeldeinformationen ausgeführt. Somit kann jeder Cluster, den Sie starten, ebenfalls in den Bucket des anderen AWS-Benutzers schreiben.
- Legen Sie die Leseberechtigungen für die Dateien, die Sie oder die Cluster in den Amazon-S3-Bucket schreiben, für andere AWS-Benutzer fest. Diese Leseberechtigungen können Sie am einfachsten festlegen, indem Sie vordefinierte Zugriffssteuerungslisten (Access Control Lists, ACLs), also Sätze von vordefinierten Zugriffsrichtlinien verwenden, die von Amazon S3 festgelegt werden.

Weitere Informationen dazu, wie andere AWS-Benutzer Ihnen Berechtigungen zum Schreiben von Dateien zu ihren Amazon-S3-Buckets erteilen können, finden Sie unter Bearbeiten von Bucket-Berechtigungen im Benutzerhandbuch für Amazon Simple Storage Service.

Damit Ihr Cluster beim Schreiben von Dateien in Amazon S3 feste ACLs verwenden kann, setzen Sie die `fs.s3.canned.acl`-Cluster-Konfigurationsoption auf die zu verwendende feste ACL. In der folgenden Tabelle sind die derzeit festgelegten vordefinierten ACLs aufgeführt.

Vordefinierte ACL	Beschreibung
`AuthenticatedRead`	Gibt an, dass dem Eigentümer `Permission.FullControl` und dem Berechtigungsempfänger der Gruppe `GroupGrantee.AuthenticatedUsers` der Zugriff `Permission.Read` gewährt wird.
`BucketOwnerFullControl`	Gibt an, dass dem Bucket-Eigentümer `Permission.FullControl` gewährt wird. Der Bucket-Eigentümer muss nicht unbedingt derselbe wie der Objekteigentümer sein.
`BucketOwnerRead`	Gibt an, dass dem Bucket-Eigentümer `Permission.Read` gewährt wird. Der Bucket-Eigentümer muss nicht unbedingt derselbe wie der Objekteigentümer sein.

Vordefinierte ACL	Beschreibung
`LogDeliveryWrite`	Gibt an, dass dem Eigentümer `Permission.FullControl` und dem Berechtigungsempfänger der Gruppe `GroupGrantee.LogDelivery` der Zugriff `Permission.Write` gewährt wird, damit Zugriffsprotokolle bereitgestellt werden können.
`Private`	Gibt an, dass dem Eigentümer `Permission.FullControl` gewährt wird.
`PublicRead`	Gibt an, dass dem Eigentümer `Permission.FullControl` und dem Berechtigungsempfänger der Gruppe `GroupGrantee.AllUsers` der Zugriff `Permission.Read` gewährt wird.
`PublicReadWrite`	Gibt an, dass dem Eigentümer `Permission.FullControl` und dem Berechtigungsempfänger der Gruppe `GroupGrantee.AllUsers` die Zugriffsberechtigungen `Permission.Read` und `Permission.Write` gewährt wird.

Die Cluster-Konfigurationsoptionen können auf vielfältige Weise festgelegt werden, je nach Typ des ausgeführten Clusters. Die folgenden Verfahren zeigen die Festlegung der Option für allgemeine Anwendungsfälle.

So schreiben Sie Dateien mithilfe vorgefertigter ACLs in Hive

- Legen Sie in der Hive-Eingabeaufforderung die Konfigurationsoption `fs.s3.canned.acl` auf die vordefinierte ACL fest, die der Cluster für zu Amazon S3 geschriebene Dateien festlegen soll. Stellen Sie für den Zugriff auf die Hive-Eingabeaufforderung eine Verbindung mit dem Master-Knoten über SSH her und geben Sie an der Hadoop-Eingabeaufforderung "Hive" ein. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

  Im folgenden Beispiel wird die Konfigurationsoption `fs.s3.canned.acl` auf `BucketOwnerFullControl` festgelegt. Dadurch erhält der Eigentümer des Amazon-S3-Buckets vollständige Kontrolle über die Datei. Beachten Sie: Der Festlegungsbefehl erfordert

die Beachtung der Groß- und Kleinschreibung und enthält keine Anführungszeichen oder Leerzeichen.

```
hive> set fs.s3.canned.acl=BucketOwnerFullControl;
create table acl (n int) location 's3://acltestbucket/acl/';
insert overwrite table acl select count(*) from acl;
```

Die beiden letzten Zeilen des Beispiels erstellen eine Tabelle, die in Amazon S3 gespeichert wird, und schreiben Daten in die Tabelle.

So schreiben Sie Dateien mithilfe vorgefertigter ACLs in Pig

- Legen Sie in der Pig-Eingabeaufforderung die Konfigurationsoption `fs.s3.canned.acl` auf die vordefinierte ACL fest, die der Cluster für zu Amazon S3 geschriebene Dateien festlegen soll. Stellen Sie für den Zugriff auf die Pig-Eingabeaufforderung eine Verbindung mit dem Master-Knoten über SSH her und geben Sie an der Hadoop-Eingabeaufforderung "Pig" ein. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

  Im folgenden Beispiel wird die Konfigurationsoption `fs.s3.canned.acl` auf BucketOwnerFullControl festgelegt. Dadurch erhält der Eigentümer des Amazon-S3-Buckets vollständige Kontrolle über die Datei. Beachten Sie: Der Festlegungsbefehl enthält ein Leerzeichen vor dem Namen der vordefinierten ACL und keine Anführungszeichen.

  ```
  pig> set fs.s3.canned.acl BucketOwnerFullControl;
  store some data into 's3://acltestbucket/pig/acl';
  ```

So schreiben Sie Dateien mithilfe vorgefertigter ACLs in eine Custom JAR

- Legen Sie mit Hadoop die Konfigurationsoption `fs.s3.canned.acl` mit -D-Flag fest. Das wird im Beispiel unten veranschaulicht.

  ```
  hadoop jar hadoop-examples.jar wordcount
  -Dfs.s3.canned.acl=BucketOwnerFullControl s3://mybucket/input s3://mybucket/output
  ```

Die Ausgabe Ihres Clusters komprimieren

Themen

- Kompression der Ausgabedaten
- Intermediäre Datenkompression
- Verwenden der Snappy-Bibliothek mit Amazon EMR

Kompression der Ausgabedaten

Dies komprimiert die Ausgabe Ihres Hadoop-Auftrags. Wenn Sie "TextOutputFormat" verwenden, ist das Ergebnis eine im gzip-Format komprimierte Textdatei. Wenn Sie nach "SequenceFiles" schreiben, ist das Ergebnis eine "SequenceFile", die intern komprimiert wird. Dies kann aktiviert werden, indem Sie die Konfigurationseinstellung "mapred.output.compress" auf "true" setzen.

Wenn Sie einen Streaming-Auftrag ausführen, können Sie dies aktivieren, indem Sie dem Streaming-Auftrag diese Argumente übergeben.

```
-jobconf mapred.output.compress=true
```

Sie können auch mit einer Bootstrap-Aktion alle Auftragsausgaben automatisch komprimieren. So können Sie dies mit dem Ruby-Client ausführen:

```
--bootstrap-actions s3://elasticmapreduce/bootstrap-actions/configure-hadoop \
--args "-s,mapred.output.compress=true"
```

Wenn Sie eine Custom Jar schreiben, können Sie die Ausgabekompression mit folgender Zeile bei der Erstellung Ihres Auftrags aktivieren:

```
FileOutputFormat.setCompressOutput(conf, true);
```

Intermediäre Datenkompression

Wenn Ihr Auftrag eine erhebliche Menge Daten von den Mappern zu den Reducern verlagert, können Sie eine Leistungsverbesserung durch Aktivierung der intermediären Kompression feststellen. Sie komprimieren die Zuweisungsausgabe und dekomprimieren sie, wenn sie auf dem Core-Knoten eingeht. Die Konfigurationseinstellung ist "mapred.compress.map.output". Sie können sie ähnlich wie die Ausgabekompression aktivieren.

Wenn Sie eine Custom Jar schreiben, verwenden Sie den folgenden Befehl:

```
conf.setCompressMapOutput(true);
```

Verwenden der Snappy-Bibliothek mit Amazon EMR

Snappy ist eine Komprimierungs- und Dekomprimierungsbibliothek, die für höhere Geschwindigkeit optimiert ist. Es ist in Amazon-EMR-AMI-Version 2.0 und höher verfügbar und wird standardmäßig für die intermediäre Kompression verwendet. Weitere Informationen zu Snappy finden Sie unter http://code.google.com/p/snappy/.

Primärknoten planen und konfigurieren

Wenn Sie einen Amazon-EMR-Cluster starten, können Sie festlegen, ob Ihr Cluster einen oder drei Primärknoten besitzt. Das Starten eines Clusters mit drei Primärknoten wird nur von Amazon EMR Version 5.23.0 und höher unterstützt. Amazon EMR kann EC2-Platzierungsgruppen nutzen, um sicherzustellen, dass Primärknoten auf unterschiedlicher zugrunde liegender Hardware platziert werden, um die Cluster-Verfügbarkeit weiter zu verbessern. Weitere Informationen finden Sie unter Amazon-EMR-Integration mit EC2-Platzierungsgruppen.

Ein Amazon-EMR-Cluster mit mehreren Primärknoten bietet die folgenden Hauptvorteile:

- Der Primärknoten ist nicht länger eine einzelne Fehlerquelle. Wenn ein Primärknoten ausfällt, verwendet der Cluster die beiden anderen Primärknoten und wird ohne Unterbrechung weiter ausgeführt. In der Zwischenzeit ersetzt Amazon EMR den ausgefallenen Primärknoten automatisch durch einen neuen Primärknoten mit derselben Konfiguration und denselben Bootstrap-Aktionen.
- Amazon EMR unterstützt die Hadoop-Feature für hohe Verfügbarkeit von HDFS NameNode und YARN ResourceManager sowie die Funktionen für hohe Verfügbarkeit einiger weiterer Open-Source-Anwendungen.

Weitere Informationen darüber, wie ein Amazon-EMR-Cluster mit mehreren Primärknoten Open-Source-Anwendungen und andere Amazon-EMR-Features unterstützt, finden Sie unter Unterstützte Anwendungen und Features.

> **Note**
>
> Der Cluster kann sich nur in einer einzigen Availability Zone oder einem einzigen Subnetz befinden.

Dieser Abschnitt enthält Informationen zu unterstützten Anwendungen und Features eines Amazon-EMR-Clusters mit mehreren Primärknoten sowie Konfigurationsdetails, bewährte Methoden und Überlegungen zum Starten des Clusters.

Themen

- Unterstützte Anwendungen und Features
- Amazon-EMR-Clustern mit mehreren Primärknoten starten
- Amazon-EMR-Integration mit EC2-Platzierungsgruppen
- Überlegungen und bewährte Methoden

Unterstützte Anwendungen und Features

In diesem Thema finden Sie Informationen zu den Hadoop-Features für hohe Verfügbarkeit von HDFS NameNode und YARN ResourceManager in einem Amazon-EMR-Cluster und wie die Feature für hohe Verfügbarkeit mit Open-Source-Anwendungen und weiteren Amazon-EMR-Features funktionieren.

Hohe Verfügbarkeit – HDFS

Ein Amazon-EMR-Cluster mit mehreren Primärknoten aktiviert das Hochverfügbarkeitsfeature HDFS NameNode in Hadoop. Weitere Informationen finden Sie unter HDFS – hohe Verfügbarkeit.

In einem Amazon-EMR-Cluster werden zwei oder mehr separate Knoten als NameNodes konfiguriert. Ein NameNode hat den Zustand `active` und der andere NameNode hat den Zustand `standby`. Wenn der Knoten mit `active` NameNode im Zustand ausfällt, startet Amazon EMR einen automatischen HDFS-Failover-Prozess. Der Knoten mit `standby` NameNode wechselt in den

Zustand `active` und übernimmt alle Client-Operationen im Cluster. Amazon EMR ersetzt den Knoten durch einen neuen, der dann als `standby` erneut beitritt.

> **Note**
>
> In den Amazon-EMR-Versionen 5.23.0 bis einschließlich 5.30.1 wird HDFS NameNode nur auf zwei der drei Primärknoten ausgeführt.

Wenn Sie feststellen müssen, welcher NameNode den Zustand `active` hat, können Sie über SSH eine Verbindung mit einem Primärknoten im Cluster herstellen und den folgenden Befehl ausführen:

```
hdfs haadmin -getAllServiceState
```

Die Ausgabe listet die Knoten auf, den NameNode-Installationsort und ihren Status. Zum Beispiel

```
ip-##-#-#-##1.ec2.internal:8020 active
ip-##-#-#-##2.ec2.internal:8020 standby
ip-##-#-#-##3.ec2.internal:8020 standby
```

Hohe Verfügbarkeit – YARN ResourceManager

Ein Amazon-EMR-Cluster mit mehreren Primärknoten aktiviert das Hochverfügbarkeitsfeature YARN ResourceManager in Hadoop. Weitere Informationen finden Sie unter ResourceManager – hohe Verfügbarkeit.

In einem Amazon-EMR-Cluster mit mehreren Primärknoten wird YARN ResourceManager auf allen drei Primärknoten ausgeführt. Ein ResourceManager hat den Zustand `active` und die anderen beiden ResourceManager haben den Zustand `standby`. Wenn der Primärknoten mit dem ResourceManager im Zustand `active` ausfällt, startet Amazon EMR einen automatischen Failover-Prozess. Ein Primärknoten mit einem ResourceManager im Zustand `standby` übernimmt alle Operationen. Amazon EMR ersetzt den ausgefallenen Primärknoten durch einen neuen Primärknoten, der dann dem ResourceManager-Quorum als `standby` wieder beitritt.

Sie können eine Verbindung mit „http://*`master-public-dns-name`*:8088/cluster“ für alle Primärknoten herstellen. Hierdurch werden Sie automatisch zum ResourceManager im Zustand `active` geleitet. Um zu ermitteln, welcher ResourceManager den Zustand `active` hat, verwenden Sie SSH, um eine Verbindung mit einem Primärknoten im Cluster herzustellen. Führen Sie

anschließend den folgenden Befehl aus, um die Liste der drei Primärknoten und deren Status abzurufen:

```
yarn rmadmin -getAllServiceState
```

Unterstützte Anwendungen in einem Amazon-EMR-Cluster mit mehreren Primärknoten

Sie können die folgenden Anwendungen auf einem Amazon-EMR-Cluster mit mehreren Primärknoten installieren und ausführen. Für jede Anwendung variiert der Failover-Prozess des Primärknotens.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Flink	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Flink-Aufträge auf Amazon EMR werden als YARN-Anwendungen ausgeführt. Die JobManager von Flink werden als ApplicationMasters von YARN auf Core-Knoten ausgeführt. Der JobManager ist vom Failover-Prozess des Primärknotens nicht betroffen. Wenn Sie Amazon-EMR-Version 5.27.0 oder früher verwenden, ist der JobManager eine einzelne Fehlerquelle. Wenn JobManager fehlschlägt, gehen alle Auftragsstatus verloren und die laufenden Aufträge werden nicht fortgesetzt. Sie können JobManager-Hochverfügbarkeit aktivieren, indem Sie die Anzahl der Anwendungsversuche sowie Checkpointing konfigurieren und ZooKeeper als Zustandsspeicher für Flink aktivieren. Weitere Informationen finden Sie unter Konfigurieren von Flink auf einem Amazon-EMR-Cluster mit mehreren Primärknoten. Ab Amazon-EMR-Version 5.28.0 ist keine manuelle Konfiguration erforderlich, um die hohe Verfügbarkeit von JobManager zu ermöglichen.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Ganglia	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Ganglia ist auf allen Primärknoten verfügbar . Daher kann Ganglia während des Failover-Prozesses für den Primärknoten weiter ausgeführt werden.
Hadoop	Hohe Verfügbarkeit	HDFS NameNode und YARN ResourceM anager führen bei einem Ausfall des aktiven Primärknotens automatisch einen Failover zum Standby-Knoten aus.
HBase	Hohe Verfügbarkeit	HBase führt bei einem Ausfall des Primärkno tens automatisch einen Failover zum Standby-Knoten aus. Wenn Sie eine Verbindung zu HBase über einen REST- oder Thrift-Server hergestel lt haben, müssen Sie bei einem Ausfall des Primärknotens zu einem anderen Primärknoten wechseln.
HCatalog	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	HCatalog basiert auf einem Hive-Metastore. Dieser befindet sich außerhalb des Clusters. HCatalog bleibt während des Failover-Prozesses für den Primärknoten verfügbar.
JupyterHub	Hohe Verfügbarkeit	JupyterHub wird auf allen drei Primär-In stances installiert. Es wird dringend empfohlen , die Notebook-Persistenz zu konfigurieren, um Notebookverlust bei einem Ausfall des Primärknotens zu verhindern. Weitere Informati onen finden Sie unter Konfigurieren von Persistenz für Notebooks in Amazon S3.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Livy	Hohe Verfügbarkeit	Livy wird auf allen drei Primärknoten installiert. Bei einem Ausfall des aktiven Primärknotens verlieren Sie den Zugriff auf die aktuelle Livy-Sitzung und müssen eine neue Livy-Sitzung auf einem anderen Primärknoten oder auf dem neuen Ersatzknoten erstellen.
Mahout	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Da Mahout keinen Daemon besitzt, hat der Failover-Prozess für den Primärknoten keine Auswirkungen.
MXNet	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Da MXNet keinen Daemon besitzt, hat der Failover-Prozess für den Primärknoten keine Auswirkungen.
Phoenix	Hochverfügbarkeit	Phoenix QueryServer wird nur auf einem der drei Primärknoten ausgeführt. Phoenix ist auf allen drei Mastern zum Herstellen einer Verbindung mit dem Phoenix QueryServer konfiguriert. Sie können die private IP des Phoenix QueryServer anhand der `/etc/phoenix/conf/phoenix-env.sh` -Datei finden
Pig	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Da Pig keinen Daemon besitzt, hat der Failover-Prozess für den Primärknoten keine Auswirkungen.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Spark	Hohe Verfügbarkeit	Alle Spark-Anwendungen werden in YARN-Containern ausgeführt und reagieren auf den Failover-Prozess für einen Primärknoten auf die gleiche Weise wie YARN-Hochverfügbar keitsfeatures.
Sqoop	Hohe Verfügbarkeit	Standardmäßig speichern sqoop-job und sqoop-metastore Daten (Auftragsbeschreib ungen) auf der lokalen Festplatte des Masters, der den Befehl ausführt. Wenn Sie Metastore-Daten in einer externen Datenbank speichern möchten, schlagen Sie bitte in der Apache Sqoop-Dokumentation nach.
Tez	Hohe Verfügbarkeit	Da Tez Container auf YARN ausgeführt werden, verhält sich Tez während des Failover-Prozesses für den Primärknoten wie YARN.
TensorFlow	Verfügbarkeit nicht durch Failover für den Primärknoten betroffen	Da TensorFlow keinen Daemon besitzt, hat der Failover-Prozess für den Primärknoten keine Auswirkungen.
Zeppelin	Hohe Verfügbarkeit	Zeppelin wird auf allen drei Primärknoten installiert. Zeppelin speichert Notizen und Interpreterkonfigurationen standardmäßig in HDFS, um Datenverlust zu verhindern. Interpret ersitzungen sind über alle drei Primär-Instances vollständig isoliert. Sitzungsdaten gehen beim Master-Ausfall verloren. Es wird empfohlen, dieselbe Notiz nicht gleichzeitig auf verschied enen Primär-Instances zu ändern.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
ZooKeeper	Hohe Verfügbarkeit	ZooKeeper ist die Grundlage der HDFS-Funktion für automatische Failover. ZooKeeper stellt einen hoch verfügbaren Service für die Verwaltung und Koordination von Daten, die Benachrichtigung von Clients über Änderungen dieser Daten und die Überwachung von Clients auf Fehler bereit. Weitere Informationen finden Sie unter HDFS-Funktion für automatische Failover.

Um die folgenden Anwendungen in einem Amazon-EMR-Cluster mit mehreren Primärknoten auszuführen, müssen Sie eine externe Datenbank konfigurieren. Die externe Datenbank befindet sich außerhalb des Clusters. Daher sind Daten während des Failover-Prozesses für den Primärknoten persistent. Für die folgenden Anwendungen werden die Servicekomponenten während des Primärknoten-Failoverprozesses automatisch wiederhergestellt, aktive Aufträge können jedoch fehlschlagen und müssen erneut versucht werden.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Hive	Hohe Verfügbarkeit, jedoch ausschließlich für Service-Komponenten	Ein externer Metastore für Hive ist erforderlich. Dies muss ein externer MySQL-Metastore sein, da PostgreSQL für Multi-Master-Cluster nicht unterstützt wird. Weiter Informationen finden Sie unter Konfigurieren eines externen Metastores für Hive.
Hue	Hohe Verfügbarkeit, jedoch ausschließlich für Service-Komponenten	Eine externe Datenbank für Hue ist erforderlich. Weitere Informationen finden Sie unter Verwenden von Hue mit einer Remote-Datenbank in Amazon RDS.

Anwendung	Verfügbarkeit während Failover für den Primärknoten	Hinweise
Oozie	Hohe Verfügbarkeit, jedoch ausschließlich für Service-Komponenten	Eine externe Datenbank für Oozie ist erforderlich. Weitere Informationen finden Sie unter Verwenden von Oozie mit einer Remote-Datenbank in Amazon RDS. Oozie-Server und Oozie-Client sind auf allen drei Primärknoten installiert. Die oozie-clients sind so konfiguriert, dass sie standardmäßig eine Verbindung mit dem richtigen oozie-server herstellen.
PrestoDB oder PrestoSQL/Trino	Hohe Verfügbarkeit, jedoch ausschließlich für Service-Komponenten	Ein externer Hive-Metastore für PrestoDB (PrestoSQL auf Amazon EMR 6.1.0-6.3.0 oder Trino auf Amazon EMR 6.4.0 und höher) ist erforderlich. Sie können Presto mit dem AWS-Glue-Datenkatalog oder eine externe MySQL-Datenbank für Hive verwenden. Die Presto-CLI ist auf allen drei Primärknoten installiert, sodass Sie damit von jedem der Primärknoten aus auf den Presto Coordinator zugreifen können. Der Presto Coordinator ist nur auf einem Primärknoten installiert. Sie können den DNS-Namen des Primärknotens ermitteln, auf dem der Presto Coordinator installiert ist, indem Sie die Amazon-`describe-cluster` -EMR-API aufrufen und den zurückgegebenen Wert des `MasterPublicDnsName` -Felds in der Antwort lesen.

> **Note**
>
> Beim Ausfall eines Primärknoten wird die Verbindung Ihrer Java Database Connectivity (JDBC) oder Open Database Connectivity (ODBC) mit dem Primärknoten beendet. Sie können eine Verbindung mit einem der verbleibenden Primärknoten herstellen und Ihre Arbeit fortsetzen, da der Hive-Metastore-Daemon auf allen Primärknoten ausgeführt wird. Sie können auch warten, bis der ausgefallene Primärknoten ersetzt wird.

So funktionieren Amazon-EMR-Feature in einem Cluster mit mehreren Primärknoten

Herstellen von Verbindungen mit Primärknoten über SSH

Sie können mit jedem der drei Primärknoten in einem Amazon-EMR-Cluster auf die gleiche Art Verbindungen über SSH herstellen, wie Sie Verbindungen mit einem einzelnen Primärknoten herstellen. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Beim Ausfall eines Primärknotens wird Ihre Verbindung mit diesem Primärknoten beendet. Um Ihre Arbeit fortzusetzen, können Sie eine Verbindung mit einem der beiden anderen Primärknoten herstellen. Alternativ können Sie auf den neuen Primärknoten zugreifen, nachdem Amazon EMR den ausgefallenen Primärknoten durch einen neuen Primärknoten ersetzt hat.

> **Note**
>
> Die private IP-Adresse des ersetzenden Primärknoten ist mit der privaten IP-Adresse des vorherigen Primärknotens identisch. Die öffentliche IP-Adresse des ersetzenden Primärknotens wird möglicherweise geändert. Sie können die neue IP-Adressen in der Konsole oder über den Befehl `describe-cluster` in der AWS-CLI abrufen. NameNode wird nur auf zwei der drei Primärknoten ausgeführt. Sie können jedoch `hdfs`-CLI-Befehle ausführen und Aufgaben ausführen, um auf allen drei Primärknoten auf HDFS zuzugreifen.

Arbeiten mit Schritten in einem Amazon-EMR-Cluster mit mehreren Primärknoten

Sie können Schritte an einen Amazon-EMR-Cluster mit mehreren Primärknoten auf die gleiche Weise übermitteln, wie Sie mit Schritten in einem Cluster mit einem einzelnen Primärknoten arbeiten. Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.

Im Folgenden finden Sie Überlegungen zur Arbeit mit Schritten in einem Amazon-EMR-Cluster mit mehreren Primärknoten:

- Beim Ausfall eines Primärknotens werden die Schritte, die auf dem Primärknoten ausgeführt werden, als FAILED (fehlgeschlagen) markiert. Alle lokal geschriebenen Daten gehen verloren. Der Status FAILED gibt jedoch möglicherweise nicht den tatsächlichen Zustand der Schritte wider.
- Wenn ein Schritt, der ausgeführt wurde, als der Primärknoten ausfiel, eine YARN-Anwendung gestartet hatte, kann der Schritt aufgrund des automatischen Failover-Prozesses für den Primärknoten weiter ausgeführt und erfolgreich abgeschlossen werden.
- Sie sollten den Status von Schritten anhand der Ausgaben der Aufgaben überprüfen. MapReduce-Aufgaben verwenden beispielsweise `_SUCCESS`-Datei, um zu ermitteln, ob eine Aufgabe erfolgreich abgeschlossen wurde.
- Sie sollten den Parameter ActionOnFailure auf CONTINUE oder CANCEL_AND_WAIT und nicht auf TERMINATE_JOB_FLOW oder TERMINATE_CLUSTER festlegen.

Automatischer Beendigungsschutz

Amazon EMR aktiviert automatisch den Kündigungsschutz für alle Cluster mit mehreren Primärknoten und überschreibt alle Einstellungen für die Schrittausführung, die Sie bei der Erstellung des Clusters angeben. Sie können den Kündigungsschutz deaktivieren, nachdem der Cluster gestartet wurde. Siehe Konfigurieren des Beendigungsschutzes für aktive Cluster. Um einen Cluster mit mehreren Primärknoten herunterzufahren, müssen Sie zunächst die Clusterattribute ändern, um den Kündigungsschutz zu deaktivieren. Detaillierte Anweisungen finden Sie unter Amazon-EMR-Clustern mit mehreren Primärknoten beenden.

Weitere Informationen zum Beendigungsschutz finden Sie unter Verwenden des Beendigungsschutzes.

Nicht unterstützte Feature in einem Amazon-EMR-Cluster mit mehreren Primärknoten

Die folgenden Amazon-EMR-Feature sind derzeit in einem Amazon-EMR-Cluster mit mehreren Primärknoten nicht verfügbar:

- EMR-Notebooks
- Instance-Flotten
- Zugriff auf den permanenten Spark History Server mit nur einem Klick
- Persistente Anwendungsbenutzeroberflächen

- Der Ein-Klick-Zugriff auf persistente Anwendungsbenutzeroberflächen ist derzeit nicht für Amazon-EMR-Cluster mit mehreren Primärknoten oder für AWS in Lake Formation integrierte Amazon-EMR-Cluster verfügbar.

> **Note**
>
> Um in Ihrem Cluster Kerberos-Authentifizierung zu verwenden, müssen Sie einen externen KDC konfigurieren.
> Ab Amazon-EMR-Version 5.27.0 können Sie die transparente HDFS-Verschlüsselung auf einem Amazon-EMR-Cluster mit mehreren Primärknoten konfigurieren. Weitere Informationen finden Sie unter Transparente Verschlüsselung in HDFS in Amazon EMR.

Amazon-EMR-Clustern mit mehreren Primärknoten starten

Dieses Thema enthält Konfigurationsdetails und Beispiele für den Start eines Amazon-EMR-Clusters mit mehreren Primärknoten.

> **Note**
>
> Amazon EMR aktiviert automatisch den Kündigungsschutz für alle Cluster mit mehreren Primärknoten und überschreibt alle Einstellungen für die automatische Terminierung, die Sie bei der Erstellung des Clusters angeben. Um einen Cluster mit mehreren Primärknoten herunterzufahren, müssen Sie zunächst die Clusterattribute ändern, um den Kündigungsschutz zu deaktivieren. Detaillierte Anweisungen finden Sie unter Amazon-EMR-Clustern mit mehreren Primärknoten beenden.

Voraussetzungen

- Sie können einen Amazon-EMR-Cluster mit mehreren Primärknoten in öffentlichen und privaten VPC-Subnetzen starten. EC2-Classic wird nicht unterstützt. Um einen Amazon-EMR-Cluster mit mehreren Primärknoten in einem öffentlichen Subnetz zu starten, müssen Sie den Instances in diesem Subnetz den Empfang einer öffentlichen IP-Adresse ermöglichen, indem Sie in der Konsole IPv4 automatisch zuweisen auswählen oder den folgenden Befehl ausführen. Ersetzen Sie *22XXXX01* durch Ihre Subnetz-ID.

```
aws ec2 modify-subnet-attribute --subnet-id subnet-22XXXX01 --map-public-ip-on-launch
```

- Um Hive, Hue oder Oozie auf einem Amazon-EMR-Cluster mit mehreren Primärknoten auszuführen, müssen Sie einen externen Metastore erstellen. Weitere Informationen finden Sie unter Konfigurieren eines externen Metastores für Hive, Verwenden von Hue mit einer Remote-Datenbank in Amazon RDS oder Apache Oozie.
- Um in Ihrem Cluster Kerberos-Authentifizierung zu verwenden, müssen Sie einen externen KDC konfigurieren. Weitere Informationen finden Sie unter Konfigurieren von Kerberos auf Amazon EMR.

Amazon-EMR-Clustern mit mehreren Primärknoten starten

Sie müssen für die Instance-Gruppe des Primärknotens den Wert „drei“ für die Zahl der Instances angeben, wenn Sie einen Amazon-EMR-Cluster mit mehreren Primärknoten starten. Die folgenden Beispiele zeigen, wie Sie den Cluster mit einem Standard- oder benutzerdefinierten AMI starten.

> **Note**
>
> Sie müssen die Subnetz-ID angeben, wenn Sie einen Amazon-EMR-Cluster mit mehreren Primärknoten mithilfe der AWS CLI starten. Ersetzen Sie in den folgenden Beispielen *22XXXX01* durch die ID Ihres Subnetzes.

Example – Starten eines Amazon-EMR-Clusters mit mehreren Primärknoten unter Verwendung eines Standard-AMI

```
aws emr create-cluster \
--name "ha-cluster" \
--release-label emr-5.36.1 \
--instance-groups InstanceGroupType=MASTER,InstanceCount=3,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=4,InstanceType=m5.xlarge \
--ec2-attributes
 KeyName=ec2_key_pair_name,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=subnet-22XXXX01
 \
--service-role EMR_DefaultRole \
--applications Name=Hadoop Name=Spark
```

Example – Starten eines Amazon-EMR-Clusters mit mehreren Primärknoten mithilfe eines benutzerdefinierten AMI

```
aws emr create-cluster \
--name "custom-ami-ha-cluster" \
--release-label emr-5.36.1 \
--instance-groups InstanceGroupType=MASTER,InstanceCount=3,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=4,InstanceType=m5.xlarge \
--ec2-attributes
 KeyName=ec2_key_pair_name,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=subnet-22XXXX01
 \
--service-role EMR_DefaultRole \
--applications Name=Hadoop Name=Spark \
--custom-ami-id ami-MyAmiID
```

Example – Starten eines Amazon-EMR-Clusters mit mehreren Primärknoten mit einem externen Hive-Metastore

Um Hive auf einem Amazon-EMR-Cluster mit mehreren Primärknoten auszuführen, müssen Sie einen externen Metastore für Hive angeben, wie das folgende Beispiel zeigt:

1. Erstellen Sie eine temporäre hiveConfiguration.json-Datei, die die Anmeldeinformationen für Ihren Hive-Metastore enthält.

   ```
   [
     {
       "Classification": "hive-site",
       "Properties": {
         "javax.jdo.option.ConnectionURL": "jdbc:mysql:\/\/hostname:3306\/hive?
   createDatabaseIfNotExist=true",
         "javax.jdo.option.ConnectionDriverName": "org.mariadb.jdbc.Driver",
         "javax.jdo.option.ConnectionUserName": "username",
         "javax.jdo.option.ConnectionPassword": "password"
       }
     }
   ]
   ```

2. Starten Sie den Cluster mit dem Hive-Metastore.

   ```
   aws emr create-cluster \
   --name "ha-cluster-with-hive-metastore" \
   --release-label emr-5.36.1 \
   ```

```
--instance-groups InstanceGroupType=MASTER,InstanceCount=3,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=4,InstanceType=m5.xlarge \
--ec2-attributes
 KeyName=ec2_key_pair_name,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=subnet-
22XXXX01 \
--service-role EMR_DefaultRole \
--applications Name=Hadoop Name= Spark Name=Hive \
--configurations ./hiveConfiguration.json
```

Amazon-EMR-Clustern mit mehreren Primärknoten beenden

Um einen Amazon-EMR-Cluster mit mehreren Primärknoten zu beenden, müssen Sie den Beendigungsschutz deaktivieren, bevor Sie den Cluster beenden, wie das folgende Beispiel zeigt. Ersetzen Sie *j-3KVTXXXXXX7UG* durch die ID Ihres Clusters.

```
aws emr modify-cluster-attributes --cluster-id j-3KVTXXXXXX7UG --no-termination-
protected
aws emr terminate-clusters --cluster-id j-3KVTXXXXXX7UG
```

Amazon-EMR-Integration mit EC2-Platzierungsgruppen

Wenn Sie einen Amazon-EMR-Cluster mit mehreren Primärknoten auf Amazon EC2 starten, haben Sie die Möglichkeit, Platzierungsgruppenstrategien zu verwenden, um festzulegen, wie die Primärknoten-Instances zum Schutz vor Hardwareausfällen bereitgestellt werden sollen.

Platzierungsgruppenstrategien werden ab Amazon-EMR-Version 5.23.0 als Option für Cluster mit mehreren Primärknoten unterstützt. Derzeit werden nur Primärkotentypen von der Platzierungsgruppenstrategie unterstützt, und die SPREAD-Strategie wird auf diese Primärknoten angewendet. Bei dieser SPREAD-Strategie wird eine kleine Gruppe von Instances auf separater zugrundeliegender Hardware platziert, um den Verlust mehrerer Primärknoten im Falle eines Hardwarefehlers zu verhindern. Beachten Sie, dass eine Anforderung zum Starten einer Instance fehlschlagen kann, wenn es nicht genügend eindeutige Hardware zur Erfüllung der Anforderung gibt. Weitere Informationen zu EC2-Platzierungs-Strategien und Einschränkungen finden Sie unter Platzierungsgruppen im EC2-Benutzerhandbuch für Linux-Instances.

In Amazon EC2 gibt es ein anfängliches Limit von 500 Clustern mit Platzierungsgruppenstrategie, die pro AWS-Region gestartet werden können. Wenden Sie sich an den AWS-Support, um eine Erhöhung der Anzahl der zulässigen Platzierungsgruppen zu beantragen. Sie können die von Amazon EMR erstellten EC2-Platzierungsgruppen identifizieren, indem Sie das Schlüssel-Wert-Paar

verfolgen, das Amazon EMR mit der Amazon-EMR-Platzierungsgruppenstrategie verknüpft. Weitere Informationen zu EC2-Cluster-Instance-Tags finden Sie unter Anzeigen von Cluster-Instances in Amazon EC2.

Die von der Platzierungsgruppe verwaltete Richtlinie an die Amazon-EMR-Rolle anhängen

Die Platzierungsgruppenstrategie erfordert eine verwaltete Richtlinie namens `AmazonElasticMapReducePlacementGroupPolicy`, die es Amazon EMR ermöglicht, Platzierungsgruppen in Amazon EC2 zu erstellen, zu löschen und zu beschreiben. Sie müssen `AmazonElasticMapReducePlacementGroupPolicy` an die Servicerolle für Amazon EMR anhängen, bevor Sie einen Amazon-EMR-Multiple-Master-Cluster starten.

Sie können die von `AmazonEMRServicePolicy_v2` verwaltete Richtlinie alternativ der Amazon-EMR-Servicerolle anstelle der verwalteten Richtlinie für die Platzierungsgruppe zuordnen. `AmazonEMRServicePolicy_v2` ermöglicht den gleichen Zugriff auf Platzierungsgruppen in Amazon EC2 wie `AmazonElasticMapReducePlacementGroupPolicy`. Weitere Informationen finden Sie unter Servicerolle für Amazon EMR (EMR-Rolle).

Bei der von `AmazonElasticMapReducePlacementGroupPolicy` verwalteten Richtlinie handelt es sich um den folgenden JSON-Text, der von Amazon EMR erstellt und verwaltet wird.

> **Note**
>
> Da die von `AmazonElasticMapReducePlacementGroupPolicy` verwaltete Richtlinie automatisch aktualisiert wird, ist die hier angezeigte Richtlinie möglicherweise veraltet. Verwenden Sie die AWS-Managementkonsole, um die aktuelle Richtlinie anzuzeigen.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Resource":"*",
         "Effect":"Allow",
         "Action":[
            "ec2:DeletePlacementGroup",
            "ec2:DescribePlacementGroups"
         ]
      },
```

```
      {
         "Resource":"arn:aws:ec2:*:*:placement-group/pg-*",
         "Effect":"Allow",
         "Action":[
            "ec2:CreatePlacementGroup"
         ]
      }
   ]
}
```

Einen Amazon-EMR-Multi-Master-Cluster mit Platzierungsgruppenstrategie starten

Um einen Amazon-EMR-Multi-Master-Cluster mit einer Platzierungsgruppenstrategie zu starten, fügen Sie die von der Platzierungsgruppe verwaltete Richtlinie `AmazonElasticMapReducePlacementGroupPolicy` der Amazon-EMR-Rolle hinzu. Weitere Informationen finden Sie unter Die von der Platzierungsgruppe verwaltete Richtlinie an die Amazon-EMR-Rolle anhängen.

Jedes Mal, wenn Sie diese Rolle verwenden, um einen Amazon-EMR-Multi-Master-Cluster zu starten, versucht Amazon EMR, einen Cluster zu starten, wobei die `SPREAD`-Strategie auf seine Primärknoten angewendet wird. Wenn Sie eine Rolle verwenden, der nicht die von der Platzierungsgruppe verwaltete Richtlinie `AmazonElasticMapReducePlacementGroupPolicy` zugeordnet ist, versucht Amazon EMR, einen Amazon EMR-Multiple-Master-Cluster ohne Platzierungsgruppenstrategie zu starten.

Wenn Sie einen Amazon-EMR-Multi-Master-Cluster mit dem `placement-group-configs`-Parameter mithilfe der Amazon EMRAPI oder CLI starten, startet Amazon EMR den Cluster nur, wenn der Amazon EMRrole die Richtlinie `AmazonElasticMapReducePlacementGroupPolicy` für die Verwaltung der Platzierungsgruppe zugewiesen ist. Wenn die Amazon EMRrole die Richtlinie nicht angehängt hat, schlägt der Start des Amazon-EMR-Multiple-Master-Clusters fehl.

Example – Starten eines Amazon-EMR-Multi-Master-Clusters mit Platzierungsgruppenstrategie mithilfe der Amazon EMRAPI.

Wenn Sie die Aktion RunJobFlow verwenden, um einen Amazon-EMR-Multimaster-Cluster zu erstellen, legen Sie die `PlacementGroupConfigs`-Eigenschaft wie folgt fest. Derzeit wird die `MASTER`-Instance-Rolle automatisch `SPREAD` als Platzierungsgruppenstrategie verwendet.

```
{
   "Name":"ha-cluster",
```

```
   "PlacementGroupConfigs":[
      {
         "InstanceRole":"MASTER"
      }
   ],
   "ReleaseLabel":"emr-5.30.1",
   "Instances":{
      "ec2SubnetId":"subnet-22XXXX01",
      "ec2KeyName":"ec2_key_pair_name",
      "InstanceGroups":[
         {
            "InstanceCount":3,
            "InstanceRole":"MASTER",
            "InstanceType":"m5.xlarge"
         },
         {
            "InstanceCount":4,
            "InstanceRole":"CORE",
            "InstanceType":"m5.xlarge"
         }
      ]
   },
   "JobFlowRole":"EMR_EC2_DefaultRole",
   "ServiceRole":"EMR_DefaultRole"
}
```

- Ersetzen Sie *ha-cluster* durch den Namen Ihres Hochverfügbarkeitsclusters.
- Ersetzen Sie *subnet-22XXXX01* durch Ihre Subnetz-ID.
- Ersetzen Sie *ec2_key_pair_name* durch den Namen Ihres EC2-Schlüsselpaars für diesen Cluster. Das EC2-Schlüsselpaar ist optional und nur erforderlich, wenn Sie für den Zugriff auf Ihren Cluster SSH verwenden möchten.

Example – Starten eines Clusters mit mehreren Primärknoten mit einer Platzierungsgruppenstrategie mithilfe der Amazon-EMR-CLI.

```
aws emr create-cluster \
--name "ha-cluster" \
--placement-group-configs InstanceRole=MASTER \
--release-label emr-5.30.1 \
--instance-groups InstanceGroupType=MASTER,InstanceCount=3,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=4,InstanceType=m5.xlarge \
```

```
--ec2-attributes
 KeyName=ec2_key_pair_name,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=subnet-22XXXX01
 \
--service-role EMR_DefaultRole \
--applications Name=Hadoop Name=Spark
```

- Ersetzen Sie *`ha-cluster`* durch den Namen Ihres Hochverfügbarkeitsclusters.
- Ersetzen Sie *`subnet-22XXXX01`* durch Ihre Subnetz-ID.
- Ersetzen Sie *`ec2_key_pair_name`* durch den Namen Ihres EC2-Schlüsselpaars für diesen Cluster. Das EC2-Schlüsselpaar ist optional und nur erforderlich, wenn Sie für den Zugriff auf Ihren Cluster SSH verwenden möchten.

Starten Sie einen Cluster mit mehreren Primärknoten ohne eine Platzierungsgruppenstrategie

Damit ein Cluster mit mehreren Primärknoten ohne die Platzierungsgruppenstrategie starten kann, müssen Sie einen der folgenden Schritte ausführen:

- Entfernen Sie die von der Platzierungsgruppe verwaltete Richtlinie `AmazonElasticMapReducePlacementGroupPolicy` aus der Amazon-EMR-Rolle oder
- Starten Sie einen Cluster mit mehreren Primärknoten, wobei der `placement-group-configs`-Parameter Amazon EMRAPI oder CLI `NONE` als Platzierungsgruppenstrategie verwendet.

Example – Starten eines Clusters mit mehreren Primärknoten ohne Platzierungsgruppenstrategie mithilfe der Amazon EMRAPI.

Wenn Sie die Aktion „RunJobFlow“ zum Erstellen eines Clusters mit mehreren Primärknoten verwenden, legen Sie die `PlacementGroupConfigs`-Eigenschaft wie folgt fest.

```
{
   "Name":"ha-cluster",
   "PlacementGroupConfigs":[
      {
         "InstanceRole":"MASTER",
         "PlacementStrategy":"NONE"
      }
   ],
   "ReleaseLabel":"emr-5.30.1",
```

```
   "Instances":{
      "ec2SubnetId":"subnet-22XXXX01",
      "ec2KeyName":"ec2_key_pair_name",
      "InstanceGroups":[
         {
            "InstanceCount":3,
            "InstanceRole":"MASTER",
            "InstanceType":"m5.xlarge"
         },
         {
            "InstanceCount":4,
            "InstanceRole":"CORE",
            "InstanceType":"m5.xlarge"
         }
      ]
   },
   "JobFlowRole":"EMR_EC2_DefaultRole",
   "ServiceRole":"EMR_DefaultRole"
}
```

- Ersetzen Sie *ha-cluster* durch den Namen Ihres Hochverfügbarkeitsclusters.
- Ersetzen Sie *subnet-22XXXX01* durch Ihre Subnetz-ID.
- Ersetzen Sie *ec2_key_pair_name* durch den Namen Ihres EC2-Schlüsselpaars für diesen Cluster. Das EC2-Schlüsselpaar ist optional und nur erforderlich, wenn Sie für den Zugriff auf Ihren Cluster SSH verwenden möchten.

Example – Starten eines Clusters mit mehreren Primärknoten ohne Platzierungsgruppenstrategie mithilfe der Amazon EMRCLI.

```
aws emr create-cluster \
--name "ha-cluster" \
--placement-group-configs InstanceRole=MASTER,PlacementStrategy=NONE \
--release-label emr-5.30.1 \
--instance-groups InstanceGroupType=MASTER,InstanceCount=3,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=4,InstanceType=m5.xlarge \
--ec2-attributes
 KeyName=ec2_key_pair_name,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=subnet-22XXXX01
 \
--service-role EMR_DefaultRole \
--applications Name=Hadoop Name=Spark
```

- Ersetzen Sie *ha-cluster* durch den Namen Ihres Hochverfügbarkeitsclusters.
- Ersetzen Sie *subnet-22XXXX01* durch Ihre Subnetz-ID.
- Ersetzen Sie *ec2_key_pair_name* durch den Namen Ihres EC2-Schlüsselpaars für diesen Cluster. Das EC2-Schlüsselpaar ist optional und nur erforderlich, wenn Sie für den Zugriff auf Ihren Cluster SSH verwenden möchten.

Überprüfen Sie die Konfiguration der Platzierungsgruppenstrategie, die an den Cluster mit mehreren Primärknoten angehängt ist

Sie können die Amazon EMR-Cluster-API verwenden, um die Konfiguration der Platzierungsgruppenstrategie anzuzeigen, die dem Cluster mit mehreren Primärknoten zugeordnet ist.

Example

```
aws emr describe-cluster --cluster-id "j-xxxxx"
{
   "Cluster":{
      "Id":"j-xxxxx",
      ...
      ...
      "PlacementGroups":[
         {
            "InstanceRole":"MASTER",
            "PlacementStrategy":"SPREAD"
         }
      ]
   }
}
```

Überlegungen und bewährte Methoden

Einschränkungen eines Amazon EMR-Clusters mit mehreren Primärknoten:

- Sie können keinen Amazon-EMR-Cluster mit mehreren Primärknoten mit Instance-Flotten verwenden. Weitere Informationen zu den Amazon-EMR-Funktionen, die mit mehreren Primärknoten funktionieren, finden Sie unter Unterstützte Anwendungen und Features.
- Wenn zwei Primärknoten gleichzeitig ausfallen, kann Amazon EMR den Cluster nicht wiederherstellen.

- Amazon-EMR-Cluster mit mehreren Primärknoten sind gegenüber Ausfällen von Availability Zones nicht tolerant. Beim Ausfall einer Availability Zone verlieren Sie den Zugriff auf den EMR-Cluster.
- Amazon EMR garantiert keine Hochverfügbarkeitsfeatures von Open-Source-Anwendungen, die nicht in Unterstützte Anwendungen in einem Amazon-EMR-Cluster mit mehreren Primärknoten angegeben sind.
- In den Amazon-EMR-Versionen 5.23.0 bis 5.30.1 wird HDFS NameNode nur auf zwei der drei Primärknoten ausgeführt.

Überlegungen für das Konfigurieren von Subnetzen:

- Ein Amazon-EMR-Cluster mit mehreren Primärknoten kann sich nur in einer Availability Zone oder einem Subnetz befinden. Amazon EMR kann einen ausgefallenen Primärknoten nicht ersetzen, wenn das Subnetz zum Zeitpunkt des Failover-Prozesses vollständig ausgelastet oder überabonniert ist. Um dieses Szenario zu vermeiden, sollten Sie für einen Amazon-EMR-Cluster ein vollständiges Subnetz reservieren. Darüber hinaus sollten Sie sicherstellen, dass im Subnetz eine ausreichende Zahl von privaten IP-Adressen verfügbar ist.

Überlegungen für das Konfigurieren von Core-Knoten:

- Um sicherzustellen, dass die Core-Knoten-Instance-Gruppe ebenfalls hoch verfügbar ist, sollten Sie mindestens vier Core-Knoten starten. Wenn Sie sich entscheiden, einen kleineren Cluster mit drei oder weniger Core-Knoten zu starten, legen Sie `dfs.replication parameter` auf mindestens 2 fest, damit HDFS über eine ausreichende DFS-Replikation verfügt. Weitere Informationen finden Sie unter HDFS-Konfiguration.

> ⚠ Warning
>
> 1. Das Festlegen von `dfs.replication` auf 1 auf Clustern mit weniger als vier Knoten kann zu einem HDFS-Datenverlust führen, wenn ein einzelner Knoten ausfällt. Wir empfehlen, für Produktionsworkloads einen Cluster mit mindestens vier Core-Knoten zu verwenden.
> 2. Amazon EMR erlaubt Clustern nicht, Core-Knoten unter `dfs.replication` zu skalieren. Bei `dfs.replication = 2` z. B. beträgt die Mindestanzahl von Core-Knoten 2.

3. Wenn Sie verwaltete Skalierung oder Auto-Scaling verwenden oder die Größe Ihres Clusters manuell ändern möchten, empfehlen wir Ihnen, `dfs.replication` auf 2 oder höher einzustellen.

Überlegungen zum Einrichten von Alarmen für Metriken:

- Amazon EMR stellt zurzeit keine anwendungsspezifischen Metriken zu HDFS oder YARN bereit. Sie sollten Alarme einrichten, um die Instance-Zahl der Primärknoten zu überwachen. Sie können die Alarme mittels der folgenden Amazon-CloudWatch-Metriken konfigurieren: `MultiMasterInstanceGroupNodesRunning`, `MultiMasterInstanceGroupNodesRunningPercentage` oder `MultiMasterInstanceGroupNodesRequested`. Sie werden bei Ausfall und Ersetzung eines Primärknotens benachrichtigt.
  - Wenn `MultiMasterInstanceGroupNodesRunningPercentage` kleiner als 1,0 und größer als 0,5 ist, ist im Cluster möglicherweise ein Primärknoten ausgefallen. In diesem Fall versucht Amazon EMR, einen Primärknoten zu ersetzen.
  - Wenn `MultiMasterInstanceGroupNodesRunningPercentage` kleiner als 0,5 ist, sind im Cluster möglicherweise zwei Primärknoten ausgefallen. In diesem Fall ist das Quorum verloren und der Cluster kann nicht wiederhergestellt werden. Sie müssen Daten manuell aus diesem Cluster migrieren.

  Weitere Informationen finden Sie unter Einrichten von Alarmen für Metriken.

EMR-Cluster auf AWS Outposts

Ab Amazon-EMR-Version 5.28.0 können Sie EMR-Cluster erstellen und auf AWS Outposts ausführen. AWS Outposts ermöglicht native AWS-Services, Infrastrukturen und -Betriebsmodelle in On-Premises-Einrichtungen. Sie können in AWS Outposts Outposts-Umgebungen die gleichen AWS APIs und Tools sowie die gleiche Infrastruktur wie in der AWS Cloud verwenden. Amazon EMR auf AWS Outposts ist ideal für Workloads mit geringer Latenz, die in unmittelbarer Nähe zu On-Premises-Daten und Anwendungen ausgeführt werden müssen Weitere Informationen zu AWS Outposts finden Sie im AWS Outposts-Benutzerhandbuch.

Voraussetzungen

Im Folgenden sind die Voraussetzungen für die Verwendung von Amazon EMR in AWS Outposts aufgeführt:

- AWS Outposts muss in Ihrem On-Premises-Rechenzentrum installiert und konfiguriert sein.
- Sie müssen über eine zuverlässige Netzwerkverbindung zwischen Ihrer Outpost-Umgebung und einer AWS-Region verfügen.
- Sie müssen über ausreichende Kapazität für EMR-unterstützte Instance-Typen in Ihren Outpost verfügen.

Einschränkungen

Im Folgenden sind die Einschränkungen für die Verwendung von Amazon EMR auf AWS Outposts aufgeführt:

- On-Demand-Instances sind die einzige unterstützte Option für Amazon-EC2-Instances. Spot Instances sind für Amazon EMR auf AWS Outposts nicht verfügbar.
- Wenn Sie zusätzliche Amazon-EBS-Speichervolumes benötigen, wird nur GP2 (General Purpose SSD) unterstützt.
- S3-Buckets, die Objekte in einem von Ihnen angegebenen AWS-Region speichern, sind die einzige unterstützte S3-Option für Amazon EMR auf Outposts. S3 in Outposts wird für Amazon EMR in AWS Outposts nicht unterstützt.
- Nur die folgenden Instance-Typen werden von Amazon EMR auf AWS Outposts unterstützt:

Instance class	Instance-Typen
Allgemeine Zwecke	`m5.xlarge |m5.2xlarge | m5.4xlarge |m5.12xlarge | m5.24xlarge |m5d.xlarge | m5d.2xlarge | m5d.4xlarge | m5d.12xlarge |m5d.24xlarge`
Für Datenverarbeitung optimiert	`c5.xlarge |c5.2xlarge | c5.4xlarge |c5.18xlarge | c5d.xlarge |c5d.2xlarge | c5d.4xlarge | c5d.18xlarge`
RAM-optimiert	

Instance class	Instance-Typen
	`r5.xlarge | r5.2xlarge | r5.4xlarge | r5.12xlarge | r5d.xlarge | r5d.2xlarge | r5d.4xlarge | r5d.12xlarge | r5d.24xlarge`
Speicheroptimiert	`i3en.xlarge | i3en.2xlarge | i3en.3xlarge | i3en.6xlarge | i3en.12xlarge | i3en.24xlarge`

Überlegungen zur Netzwerkkonnektivität

- Wenn die Netzwerkverbindung zwischen Ihrem Outpost und seiner AWS-Region verloren geht, werden Ihre Cluster weiterhin ausgeführt. Sie können jedoch keine neuen Cluster erstellen oder neue Aktionen für vorhandene Cluster ausführen, bis die Verbindung wiederhergestellt wurde. Bei Instance-Fehlern wird die Instance nicht automatisch ersetzt. Zudem werden Aktionen wie das Hinzufügen von Schritten zu einem ausgeführten Cluster, das Überprüfen des Schrittausführungsstatus und das Senden von CloudWatch-Metriken und -Ereignissen verzögert.
- Wir empfehlen, dass Sie für eine zuverlässige und hochverfügbare Netzwerkkonnektivität zwischen Ihrem Outpost und der AWS-Region sorgen. Wenn die Netzwerkkonnektivität zwischen Ihrem Outpost und seiner AWS-Region länger als ein paar Stunden unterbrochen wird, werden Cluster mit aktiviertem Beendigungsschutz weiter ausgeführt und Cluster mit deaktiviertem Beendigungsschutz beendet.
- Falls die Netzwerkkonnektivität aufgrund einer routinemäßigen Wartung beeinträchtigt wird, empfehlen wir die proaktive Aktivierung des Beendigungsschutzes. Generell bedeutet die Unterbrechung der Konnektivität, dass externe Abhängigkeiten, die nicht lokal im Outpost oder Kundennetzwerk sind, nicht zugänglich sind. Dazu gehören Amazon S3, DynamoDB, das mit EMRFS Consistency View verwendet wird, und Amazon RDS, wenn eine Instance in der Region für einen Amazon-EMR-Cluster mit mehreren Primärknoten verwendet wird.

Erstellen eines Amazon-EMR-Clusters auf einem AWS Outposts

Erstellen eines Amazon-EMR-Clusters auf einem AWS Outposts ähnelt dem Erstellen eines Amazon-EMR-Clusters in der AWS-Cloud. Wenn Sie einen Amazon-EMR-Cluster auf einem AWS Outposts erstellen, müssen Sie ein Amazon-EC2-Subnetz angeben, das Ihrem Outpost zugeordnet ist.

Eine Amazon VPC kann sich über alle Availability Zones in einer AWS-Region erstrecken. AWS Outposts sind Erweiterungen von Availability Zones und Sie können eine Amazon VPC in einem Konto auf mehrere Availability Zones und zugeordnete Outposts-Standorte erweitern. Wenn Sie den Outpost konfigurieren, ordnen Sie ihm ein Subnetz zu, um Ihre regionale VPC-Umgebung auf Ihre On-Premises-Einrichtung zu erweitern. Outpost-Instances und verwandte Services werden als Teil Ihrer regionalen VPC angezeigt, ähnlich einer Availability Zone mit verknüpften Subnetzen. Weitere Informationen finden Sie im AWS Outposts-Benutzerhandbuch.

Konsole

Um mit der AWS Management Console einen neuen Amazon-EMR-Cluster auf AWS Outposts zu erstellen, geben Sie ein Amazon-EC2-Subnetz an, das Ihrem Outpost zugeordnet ist.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So erstellen Sie einen Cluster in AWS Outposts mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Clusterkonfiguration die Option Instance-Gruppen oder Instance-Flotten aus. Wählen Sie dann im Dropdownmenü EC2-Instance-Typ auswählen einen Instance-Typ aus oder wählen Sie Aktionen und anschließend EBS-Volumes hinzufügen aus. Amazon EMR in AWS Outposts unterstützt begrenzte Amazon-EBS-Volumes und Instance-Typen.
4. Wählen Sie unter Netzwerk ein EC2-Subnetz mit einer Outpost-ID in diesem Format aus: op-123456789.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So erstellen Sie einen Cluster in AWS Outposts mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Wählen Sie unter Software Configuration (Softwarekonfiguration) für Release (Version) 5.28.0 oder höher aus.
5. Wählen Sie unter Hardwarekonfiguration für EC2-Subnetz ein EC2-Subnetz mit einer Outpost-ID im folgenden Format aus: op-123456789.
6. Wählen Sie den Instance-Typ oder fügen Sie Amazon-EBS-Speichervolumes für einheitliche Instance-Gruppen oder Instance-Flotten hinzu. Amazon EMR in AWS Outposts unterstützt begrenzte Amazon-EBS-Volumes und Instance-Typen.

CLI

So erstellen Sie einen Cluster in AWS Outposts mit der AWS CLI

- Um mit der AWS CLI einen neuen Amazon-EMR-Cluster auf AWS Outposts zu erstellen, geben Sie ein EC2-Subnetz an, das Ihrem Outpost zugeordnet ist, wie im folgenden Beispiel. Ersetzen Sie *subnet-22XXXX01* durch Ihre eigene EC2-Subnetz-ID.

```
aws emr create-cluster \
--name "Outpost cluster" \
--release-label emr-5.36.1 \
--applications Name=Spark \
--ec2-attributes KeyName=myKey SubnetId=subnet-22XXXX01 \
--instance-type m5.xlarge --instance-count 3 --use-default-roles
```

EMR-Cluster in AWS Local Zones

Ab Amazon-EMR-Version 5.28.0 können Sie Amazon-EMR-Cluster in einem AWS-Local-Zones-Subnetz als logische Erweiterung einer AWS-Region erstellen und ausführen, die Local Zones unterstützt. Durch eine Local Zone können sich Amazon-EMR-Features und eine Teilmenge von

AWS-Services, wie Datenverarbeitungs- und Speicher-Services, näher am Benutzer befinden, um bei vor Ort ausgeführten Anwendungen einen Zugriff mit sehr niedriger Latenz zu ermöglichen. Eine Liste der verfügbaren Local Zones finden Sie unter AWS Local Zones. Informationen zum Zugriff auf verfügbare AWS Local Zones finden Sie unter Regionen, Availability Zones und Local Zones.

Unterstützte Instance-Typen

Die folgenden Instance-Typen sind für Amazon-EMR-Cluster auf Local Zones verfügbar. Die Verfügbarkeit des Instance-Typs kann je nach Region variieren.

Instance class	Instance-Typen
Allgemeine Zwecke	m5.xlarge | m5.2xlarge | m5.4xlarge | m5.12xlarge | m5.24xlarge | m5d.xlarge | m5d.2xlarge | m5d.4xlarge | m5d.12xlarge | m5d.24xlarge
Für Datenverarbeitung optimiert	c5.xlarge | c5.2xlarge | c5.4xlarge | c5.9xlarge | c5.18xlarge | c5d.xlarge | c5d.2xlarge | c5d.4xlarge| c5d.9xlarge | c5d.18xlarge
RAM-optimiert	r5.xlarge | r5.2xlarge | r5.4xlarge | r5.12xlarge | r5d.xlarge | r5d.2xlarge | r5d.4xlarge | r5d.12xlarge | r5d.24xlarge
Speicheroptimiert	i3en.xlarge | i3en.2xlarge | i3en.3xlarge | i3en.6xlarge | i3en.12xlarge | i3en.24xlarge

Erstellen eines Amazon-EMR-Clusters auf Local Zones

Erstellen Sie einen Amazon-EMR-Cluster in AWS Local Zones, indem Sie den Amazon-EMR-Cluster in einem Amazon-VPC-Subnetz starten, das mit einer Local Zone verknüpft ist. Sie können auf den Cluster mit dem Local-Zone-Namen zugreifen, z. B. us-west-2-lax-1a in der USA West (Oregon)-Konsole.

Local Zones unterstützen derzeit keine Amazon-EMR-Notebooks oder direkte Verbindungen mit Amazon EMR mittels der VPC-Endpunkt-Schnittstelle (AWS PrivateLink).

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Einen Cluster in einer Local Zone mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Netzwerk ein EC2-Subnetz mit einer Local-Zone-ID in diesem Format aus: subnet 123abc | us-west-2-lax-1a.
4. Wählen Sie den Instance-Typ oder fügen Sie Amazon-EBS-Speichervolumes für einheitliche Instance-Gruppen oder Instance-Flotten hinzu.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So erstellen Sie einen Cluster in einer Local Zone mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Wählen Sie unter Software Configuration (Softwarekonfiguration) für Release (Version) 5.28.0 oder höher aus.
5. Wählen Sie unter Hardwarekonfiguration für EC2-Subnetz ein Subnetz mit einer Local-Zone-ID im folgenden Format aus: subnet 123abc | us-west-2-lax-1a.

6. Fügen Sie Amazon-EBS-Speichervolumes für einheitliche Instance-Gruppen oder Instance-Flotten hinzu und wählen Sie einen Instance-Typ aus.

CLI

Einen Cluster in einer Local Zone mit AWS CLI

- Verwenden Sie den Befehl „create-cluster“ zusammen mit der SubnetzID für die Local Zone, wie im folgenden Beispiel gezeigt. Ersetzen Sie subnet-22XXXX1234567 durch die Local-Zone-SubnetzID und ersetzen Sie ggf. andere Optionen. Weitere Informationen finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr/create-cluster.html.

```
aws emr create-cluster \
--name "Local Zones cluster" \
--release-label emr-5.29.0 \
--applications Name=Spark \
--ec2-attributes KeyName=myKey,SubnetId=subnet-22XXXX1234567 \
--instance-type m5.xlarge --instance-count 3 --use-default-roles
```

Docker konfigurieren

Amazon EMR 6.x unterstützt Hadoop 3, wodurch der YARN NodeManager Container entweder direkt auf dem Amazon-EMR-Cluster oder in einem Docker-Container starten kann. Docker-Container bieten benutzerdefinierte Ausführungsumgebungen, in denen Anwendungscode ausgeführt wird. Die benutzerdefinierte Ausführungsumgebung wird von der Ausführungsumgebung vom YARN NodeManager und anderer Anwendungen isoliert.

Docker-Container können spezielle Bibliotheken enthalten, die von der Anwendung verwendet werden, und sie können verschiedene Versionen von systemeigenen Tools und Bibliotheken wie R und Python bereitstellen. Sie können die vertrauten Docker-Tools verwenden, um Bibliotheken und Laufzeitabhängigkeiten für Ihre Anwendungen zu definieren.

Amazon-EMR-6.x-Cluster sind standardmäßig so konfiguriert, dass YARN Anwendungen wie Spark mit Docker-Containern ausführen kann. Um die Containerkonfiguration anzupassen, bearbeiten Sie die Docker-Unterstützungsoptionen, die in den im `/etc/hadoop/conf`-Verzeichnis verfügbaren Dateien „`yarn-site.xml`“ und „`container-executor.cfg`“ definiert sind. Weitere Informationen zu den einzelnen Konfigurationsoptionen und deren Verwendung finden Sie unter Starten von Anwendungen mithilfe von Docker-Containern.

Sie können Docker verwenden, wenn Sie eine Aufgabe absenden. Verwenden Sie die folgenden Variablen, um die Docker-Laufzeit und das Docker-Image anzugeben.

- `YARN_CONTAINER_RUNTIME_TYPE=docker`
- `YARN_CONTAINER_RUNTIME_DOCKER_IMAGE={DOCKER_IMAGE_NAME}`

Wenn Sie Docker-Container verwenden, um Ihre YARN-Anwendungen auszuführen, lädt YARN das Docker-Image herunter, das Sie beim Absenden der Aufgabe angeben. Damit YARN dieses Docker-Image auflösen kann, muss es mit einer Docker-Registrierung konfiguriert werden. Die Konfigurationsoptionen für eine Docker-Registrierung hängen davon ab, ob Sie den Cluster über ein öffentliches oder privates Subnetz bereitstellen.

Docker-Registrierungen

Eine Docker-Registrierung ist ein Speicher- und Verteilungssystem für Docker-Images. Für Amazon EMR empfehlen wir die Verwendung von Amazon ECR, einer vollständig verwalteten Docker-Container-Registrierung, mit der Sie Ihre eigenen benutzerdefinierten Images erstellen und diese in einer hochverfügbaren und skalierbaren Architektur hosten können.

Überlegungen zur Bereitstellung

Für Docker-Registrierungen ist Netzwerkzugriff von jedem Host im Cluster erforderlich. Dies liegt daran, dass jeder Host Images aus der Docker-Registrierung herunterlädt, wenn Ihre YARN-Anwendung auf dem Cluster ausgeführt wird. Diese Anforderungen an die Netzwerkkonnektivität können die Auswahl der Docker-Registrierung einschränken, je nachdem, ob Sie Ihren Amazon-EMR-Cluster in einem öffentlichen oder privaten Subnetz bereitstellen.

Public subnet (Öffentliches Subnetz)

Wenn EMR-Cluster in einem öffentlichen Subnetz bereitgestellt werden, können die Knoten, auf denen YARN NodeManager ausgeführt wird, direkt auf jede über das Internet verfügbare Registrierung zugreifen.

Privates Subnetz

Wenn EMR-Cluster in einem privaten Subnetz bereitgestellt werden, haben die Knoten, auf denen YARN NodeManager ausgeführt wird, keinen direkten Zugriff auf das Internet. Docker-Images können in Amazon ECR gehostet und über AWS PrivateLink abgerufen werden.

Weitere Informationen zur Verwendung von AWS PrivateLink zum Ermöglichen des Zugriffs auf Amazon ECR in einem privaten Subnetzszenario finden Sie unter Einrichten von AWS PrivateLink für Amazon ECS und Amazon ECR.

Konfigurieren von Docker-Registrierungen

Um Docker-Registrierungen mit Amazon EMR verwenden zu können, müssen Sie Docker so konfigurieren, dass sie der spezifischen Registrierung vertrauen, die Sie zum Auflösen von Docker-Images verwenden möchten. Die Standardvertrauensregistrierungen sind „local“ (privat) und „centos“. Wenn Sie andere öffentliche Repositorys oder Amazon ECR verwenden möchten, können Sie `docker.trusted.registries`-Einstellungen in `/etc/hadoop/conf/container-executor.cfg` außer Kraft setzen, indem Sie die EMR-Klassifikations-API mit dem `container-executor`-Klassifizierungsschlüssel verwenden.

Das folgende Beispiel zeigt, wie Sie den Cluster so konfigurieren, dass er sowohl einem öffentlichen Repository mit dem Namen „`your-public-repo`“, als auch einem ECR-Registrierungsendpunkt vertraut, `123456789123.dkr.ecr.us-east-1.amazonaws.com`. Wenn Sie ECR verwenden, ersetzen Sie diesen Endpunkt durch Ihren spezifischen ECR-Endpunkt.

```
[
  {
    "Classification": "container-executor",
    "Configurations": [
        {
            "Classification": "docker",
            "Properties": {
                "docker.trusted.registries": "local,centos,your-public-
repo,123456789123.dkr.ecr.us-east-1.amazonaws.com",
                "docker.privileged-containers.registries": "local,centos,your-public-
repo,123456789123.dkr.ecr.us-east-1.amazonaws.com"
            }
        }
    ]
  }
]
```

Wenn Sie einen Amazon-EMR-6.0.0-Cluster mit dieser Konfiguration mittels AWS Command Line Interface (AWS CLI) starten möchten, erstellen Sie eine Datei namens `container-executor.json` mit dem Inhalt des ontainer-executor der vorherigen JSON-Konfiguration. Verwenden Sie dann die folgenden Befehle, um den Cluster zu starten.

```
export KEYPAIR=<Name of your Amazon EC2 key-pair>
export SUBNET_ID=<ID of the subnet to which to deploy the cluster>
export INSTANCE_TYPE=<Name of the instance type to use>
export REGION=<Region to which to deploy the cluster>

aws emr create-cluster \
    --name "EMR-6.0.0" \
    --region $REGION \
    --release-label emr-6.0.0 \
    --applications Name=Hadoop Name=Spark \
    --service-role EMR_DefaultRole \
    --ec2-attributes KeyName=$KEYPAIR,InstanceProfile=EMR_EC2_DefaultRole,SubnetId=
$SUBNET_ID \
    --instance-groups InstanceGroupType=MASTER,InstanceCount=1,InstanceType=
$INSTANCE_TYPE InstanceGroupType=CORE,InstanceCount=2,InstanceType=$INSTANCE_TYPE \
    --configuration file://container-executor.json
```

YARN für den Zugriff auf Amazon ECR auf EMR 6.0.0 und früher konfigurieren

Wenn Sie neu bei Amazon ECR sind, folgen Sie den Anweisungen unter Erste Schritte mit Amazon ECR und stellen Sie sicher, dass Sie von jeder Instance in Ihrem Amazon-EMR-Cluster Zugriff auf Amazon ECR haben.

Um unter EMR 6.0.0 und früher auf Amazon ECR mit dem Docker-Befehl zuzugreifen, müssen Sie zunächst Anmeldeinformationen generieren. Wenn Sie überprüfen möchten, ob YARN auf Images von Amazon ECR zugreifen kann, verwenden Sie die Container-Umgebungsvariable `YARN_CONTAINER_RUNTIME_DOCKER_CLIENT_CONFIG`, um einen Verweis auf die von Ihnen generierten Anmeldeinformationen zu übergeben.

Führen Sie den folgenden Befehl auf einem der Core-Knoten aus, um die Anmeldezeile für Ihr ECR-Konto zu erhalten.

```
aws ecr get-login --region us-east-1 --no-include-email
```

Der `get-login`-Befehl generiert den korrekten Docker-CLI-Befehl zum Erstellen von Anmeldeinformationen. Kopieren Sie die Ausgabe von `get-login` und führen Sie sie aus.

```
sudo docker login -u AWS -p <password> https://<account-id>.dkr.ecr.us-
east-1.amazonaws.com
```

Mit diesem Befehl wird eine `config.json`-Datei im `/root/.docker`-Ordner generiert. Kopieren Sie diese Datei in HDFS, damit sie von den an den Cluster übermittelten Aufgaben zur Authentifizierung bei Amazon ECR verwendet werden kann.

Führen Sie die folgenden Befehle aus, um die `config.json`-Datei in Ihr Startverzeichnis zu kopieren.

```
mkdir -p ~/.docker
sudo cp /root/.docker/config.json ~/.docker/config.json
sudo chmod 644 ~/.docker/config.json
```

Führen Sie die folgenden Befehle aus, um die config.json-Datei in HDFS festzulegen, damit sie von Aufgaben verwendet werden kann, die auf dem Cluster ausgeführt werden.

```
hadoop fs -put ~/.docker/config.json /user/hadoop/
```

YARN kann auf ECR als Docker-Image-Registrierung zugreifen und Container während der Aufgabenausführung abrufen.

Nachdem Sie Docker-Registrierungen und YARN konfiguriert haben, können Sie YARN-Anwendungen mit Docker-Containern ausführen. Weitere Informationen finden Sie unter Ausführen von Spark-Anwendungen mit Docker mithilfe von Amazon EMR 6.0.0.

In EMR 6.1.0 und höher müssen Sie die Authentifizierung für Amazon ECR nicht manuell einrichten. Wenn im `container-executor`-Klassifikationsschlüssel eine Amazon-ECR-Registrierung erkannt wird, wird das automatische Amazon-ECR-Authentifizierungsfeature aktiviert, und YARN wickelt den Authentifizierungsprozess ab, wenn Sie einen Spark-Auftrag mit einem ECR-Image einreichen. Sie können überprüfen, ob die automatische Authentifizierung aktiviert ist, indem Sie in `yarn.nodemanager.runtime.linux.docker.ecr-auto-authentication.enabled` der YARN-Seite einchecken. Die automatische Authentifizierung ist aktiviert und die YARN-Authentifizierungseinstellung ist auf `true` gesetzt, wenn die eine ECR-Registrierungs-URL `docker.trusted.registries` enthält.

Voraussetzungen für die Verwendung der automatischen Authentifizierung bei Amazon ECR

- EMR Version 6.1.0 oder höher
- Die in der Konfiguration enthaltene ECR-Registrierung befindet sich in derselben Region wie der Cluster

- IAM-Rolle mit Berechtigungen zum Abrufen des Autorisierungstoken und zum Abrufen eines beliebigen Images

Weitere Informationen finden Sie unter Einrichten mit Amazon ECS.

Wie aktiviere ich die automatische Authentifizierung

Folgen Sie Konfigurieren von Docker-Registrierungen , um eine Amazon-ECR-Registrierung als vertrauenswürdige Registrierung festzulegen, und stellen Sie sicher, dass sich das Amazon-ECR-Repository und der Cluster in derselben Region befinden.

Um dieses Feature auch dann zu aktivieren, wenn die ECR-Registrierung nicht in der vertrauenswürdigen Registrierung festgelegt ist, verwenden Sie die Konfigurationsklassifizierung, um `yarn.nodemanager.runtime.linux.docker.ecr-auto-authentication.enabled` auf `true` festzulegen.

Wie deaktiviere ich die automatische Authentifizierung

Standardmäßig ist die automatische Authentifizierung deaktiviert, wenn in der vertrauenswürdigen Registrierung keine Amazon-ECR-Registrierung erkannt wird.

Um die automatische Authentifizierung zu deaktivieren, auch wenn die Amazon-ECR-Registrierung in der vertrauenswürdigen Registrierung festgelegt ist, verwenden Sie die Konfigurationsklassifizierung, um `yarn.nodemanager.runtime.linux.docker.ecr-auto-authentication.enabled` auf `false` festzulegen.

Wie überprüft man, ob die automatische Authentifizierung in einem Cluster aktiviert ist

Verwenden Sie einen Text-Editor wie `vi` auf dem Hauptknoten, um den Inhalt der Datei `vi /etc/hadoop/conf.empty/yarn-site.xml` anzuzeigen. Überprüfen Sie den Wert von `yarn.nodemanager.runtime.linux.docker.ecr-auto-authentication.enabled`.

Steuern der Cluster-Beendigung

In diesem Abschnitt werden Ihre Optionen zum Herunterfahren von Amazon-EMR-Clustern beschrieben. Es behandelt automatische Kündigung und Kündigungsschutz sowie deren Interaktion mit anderen Amazon-EMR-Features.

Sie können einen Amazon-EMR-Cluster folgendermaßen herunterfahren:

- Kündigung nach der Ausführung des letzten Schritts – Erstellen Sie einen vorübergehenden Cluster, der nach Abschluss aller Schritte heruntergefahren wird.
- Automatische Kündigung (nach Inaktivität) – Erstellen Sie einen Cluster mit einer automatischen Terminierungsrichtlinie, der nach einer bestimmten Leerlaufzeit heruntergefahren wird. Weitere Informationen finden Sie unter Verwenden einer Richtlinie zur automatischen Beendigung.
- Manuelles Beenden – Erstellen Sie einen Cluster mit langer Laufzeit, der so lange läuft, bis Sie ihn bewusst beenden. Informationen zum manuellen Beenden eines Clusters finden Sie unter Einen Cluster beenden.

Sie können auch einen Kündigungsschutz für einen Cluster einrichten, um zu verhindern, dass EC2-Instances versehentlich oder versehentlich heruntergefahren werden.

Wenn Amazon EMR Ihren Cluster herunterfährt, werden alle Amazon-EC2-Instances im Cluster heruntergefahren. Daten im Instance-Speicher und auf EBS-Volumes sind nicht mehr verfügbar und können nicht wiederhergestellt werden. Es ist von kritischer Bedeutung, das Beenden von Clustern zu verstehen und zu kontrollieren, um eine Strategie für die Verwaltung und Bewahrung von Daten erstellen zu können, bei der die Daten zu Amazon S3 geschrieben und die Kosten abgewogen werden.

Themen

- Konfigurieren eines Clusters zum Fortfahren oder Beenden nach der Schrittausführung
- Verwenden einer Richtlinie zur automatischen Beendigung
- Verwenden des Beendigungsschutzes

Konfigurieren eines Clusters zum Fortfahren oder Beenden nach der Schrittausführung

In diesem Thema werden die Unterschiede zwischen der Verwendung eines Clusters mit langer Laufzeit und der Erstellung eines transienten Clusters erläutert, der nach der Ausführung des letzten Schritts heruntergefahren wird. Außerdem wird beschrieben, wie die Schrittausführung für einen Cluster konfiguriert wird.

So erstellen Sie einen langlebigen Cluster

Standardmäßig sind Cluster, die Sie mit der Konsole erstellen oder AWS CLI, die eine lange Laufzeit haben. Cluster mit langer Laufzeit laufen weiter, akzeptieren Arbeit und es fallen Gebühren an, bis Sie Maßnahmen ergreifen, um sie herunterzufahren.

Ein Cluster mit langer Laufzeit ist in folgenden Situationen wirksam:

- Wenn Sie interaktiv oder automatisch Daten abfragen müssen.
- Wenn Sie kontinuierlich mit Big-Data-Anwendungen interagieren müssen, die auf dem Cluster gehostet werden.
- Wenn Sie regelmäßig einen Datensatz verarbeiten, der so groß oder so häufig ist, dass es ineffizient ist, jedes Mal neue Cluster zu starten und Daten zu laden.

Sie können auch einen Kündigungsschutz für einen Cluster mit langer Laufzeit einrichten, um zu verhindern, dass EC2-Instances versehentlich oder versehentlich heruntergefahren werden. Weitere Informationen finden Sie unter Verwenden des Beendigungsschutzes.

> **Note**
>
> Amazon EMR aktiviert automatisch den Kündigungsschutz für alle Cluster mit mehreren Primärknoten und überschreibt alle Einstellungen für die Schrittausführung, die Sie bei der Erstellung des Clusters angeben. Sie können den Kündigungsschutz deaktivieren, nachdem der Cluster gestartet wurde. Siehe Konfigurieren des Beendigungsschutzes für aktive Cluster. Um einen Cluster mit mehreren Primärknoten herunterzufahren, müssen Sie zunächst die Clusterattribute ändern, um den Kündigungsschutz zu deaktivieren. Detaillierte Anweisungen finden Sie unter Amazon-EMR-Clustern mit mehreren Primärknoten beenden.

Einen Cluster so konfigurieren, dass er nach der Ausführung des Schritts beendet wird

Wenn Sie die Beendigung nach der Schrittausführung konfigurieren, startet der Cluster, führt Bootstrap-Aktionen aus und führt dann die von Ihnen angegebenen Schritte aus. Sobald der letzte Schritt abgeschlossen ist, beendet Amazon EMR die Amazon-EC2-Instances des Clusters. Bei Clustern, die Sie mit der Amazon-EMR-API starten, ist die Schrittausführung standardmäßig aktiviert.

Die Beendigung nach der Schrittausführung ist für Cluster wirksam, die eine periodische Verarbeitungsaufgabe ausführen, beispielsweise einen täglichen Datenverarbeitungslauf. Mit der

schrittweisen Ausführung können Sie außerdem sicherstellen, dass Ihnen nur die Zeit in Rechnung gestellt wird, die für die Verarbeitung Ihrer Daten erforderlich ist. Weitere Informationen zu den Schritten finden Sie unter Übermitteln von Arbeit an einen Cluster.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So aktivieren Sie die Schritt-Ausführung mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Schritte die Option Schritt hinzufügen aus. Geben Sie im Dialogfeld Schritt hinzufügen die entsprechenden Feldwerte ein. Die Optionen unterscheiden sich je nach Schritttyp. Um Ihren Schritt hinzuzufügen und das Dialogfeld zu verlassen, wählen Sie Schritt hinzufügen.
4. Aktivieren Sie unter Clusterbeendigung das Kontrollkästchen Cluster nach Abschluss des letzten Schritts beenden.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So aktivieren Sie die Schritt-Ausführung mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Step execution (Schrittausführung) aus.

4. Wählen Sie weitere Einstellungen wie für Ihre Anwendung erforderlich und dann Create cluster (Cluster erstellen) aus.

AWS CLI

So aktivieren Sie die Schritt-Ausführung mit AWS CLI

- Geben Sie den `--auto-terminate`-Parameter an, wenn Sie den `create-cluster`-Befehl verwenden, um einen vorübergehenden Cluster zu erstellen.

  Das folgende Beispiel veranschaulicht die Verwendung des `--auto-terminate`-Parameters. Sie können den folgenden Befehl eingeben und *myKey* durch den Namen Ihres EC2-Schlüsselpaars ersetzen.

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "Test cluster" --release-label emr-5.36.1 \
--applications Name=Hive Name=Pig --use-default-roles --ec2-attributes
 KeyName=myKey \
--steps Type=PIG,Name="Pig Program",ActionOnFailure=CONTINUE,\
Args=[-f,s3://mybucket/scripts/pigscript.pig,-p,\
INPUT=s3://mybucket/inputdata/,-p,OUTPUT=s3://mybucket/outputdata/,\
$INPUT=s3://mybucket/inputdata/,$OUTPUT=s3://mybucket/outputdata/]
--instance-type m5.xlarge --instance-count 3 --auto-terminate
```

API

So deaktivieren Sie die Scritt-Ausführung mit der Amazon-EMR-API

- Wenn Sie die Aktion RunJobFlow verwenden, um einen Cluster zu erstellen, legen Sie die Eigenschaft KeepJobFlowAliveWhenNoSteps- auf `true` fest.

Verwenden einer Richtlinie zur automatischen Beendigung

Mit einer Richtlinie zur automatischen Terminierung können Sie die Clusterbereinigung orchestrieren, ohne ungenutzte Cluster überwachen und manuell beenden zu müssen. Wenn Sie einem Cluster eine automatische Terminierungsrichtlinie hinzufügen, geben Sie die Leerlaufzeit an, nach der der Cluster automatisch heruntergefahren werden soll.

Je nach Release-Version verwendet Amazon EMR unterschiedliche Kriterien, um einen Cluster als inaktiv zu kennzeichnen. In der folgenden Tabelle wird beschrieben, wie Amazon EMR den Cluster-Leerlauf bestimmt.

Wenn Sie …	Ein Cluster gilt als inaktiv, wenn …
Amazon-EMR-Versionen 5.34.0 und höher und 6.4.0 und höher	• Es gibt keine aktiven YARN-Anwendungen • Die HDFS-Auslastung liegt unter 10 % • Es gibt keine aktiven EMR-Notebook- oder EMR-Studio-Verbindungen • Es werden keine Benutzeroberflächen für Cluster-Anwendungen verwendet
Amazon-EMR-Versionen 5.30.0 – 5.33.0 und 6.1.0 – 6.3.0	• Es gibt keine aktiven YARN-Anwendungen • Der Cluster hat keine aktiven Spark–Aufträge **Note** Amazon EMR markiert einen Cluster als inaktiv und beendet den Cluster möglicherweise automatisch, auch wenn Sie über einen aktiven Python3-Kernel verfügen. Das liegt daran, dass bei der Ausführung eines Python3-K ernels kein Spark-Job auf dem Cluster

Wenn Sie …	Ein Cluster gilt als inaktiv, wenn …
	gesendet wird. Um die automatische Terminierung mit einem Python3-Kernel zu verwenden, empfehlen wir die Verwendung von Amazon-EMR-Version 6.4.0 oder höher.

> **Note**
>
> Amazon-EMR-Versionen 6.4.0 und höher unterstützen eine Cluster-Datei zur Erkennung von Aktivitäten auf dem Primärknoten: `/emr/metricscollector/isbusy`. Wenn Sie einen Cluster verwenden, um Shell-Skripts oder Nicht-YARN-Anwendungen auszuführen, können Sie Amazon EMR regelmäßig bearbeiten oder `isbusy` aktualisieren, um Amazon EMR mitzuteilen, dass sich der Cluster nicht im Leerlauf befindet.

Sie können beim Erstellen eines Clusters eine automatische Terminierungsrichtlinie anhängen oder einem vorhandenen Cluster eine Richtlinie hinzufügen. Um die automatische Kündigung zu ändern oder zu deaktivieren, können Sie die Richtlinie aktualisieren oder entfernen.

Überlegungen

Berücksichtigen Sie die folgenden Features und Einschränkungen, bevor Sie eine Richtlinie zum automatischen Beenden verwenden:

- In Asien-Pazifik (Jakarta) ist die automatische Terminierung von Amazon EMR mit Amazon EMR 6.14.0 und höher verfügbar.
- Im Folgenden AWS-Regionen ist die automatische Kündigung von Amazon EMR mit Amazon EMR 5.30.0 und 6.1.0 und höher verfügbar:

  USA Ost (Nord-Virginia und Ohio), USA West (Oregon und Nord-Kalifornien), Südamerika (São Paulo), Europa (Frankfurt, Irland, London, Mailand, Paris und Stockholm), Kanada (Zentral), Asien-Pazifik (Hongkong, Mumbai, Seoul, Singapur, Sydney und Tokio), Naher Osten (Bahrain), Afrika (Kapstadt), AWS GovCloud (US-Ost), AWS GovCloud (US-West), China (Peking) betrieben von Sinnet, China (Ningxia), betrieben von NWCD.

- Das Leerlauf-Timeout ist standardmäßig auf 60 Minuten (eine Stunde) eingestellt, wenn Sie keinen Wert angeben. Sie können ein minimales Timeout für den Leerlauf von einer Minute und ein maximales Timeout für den Leerlauf von 7 Tagen angeben.
- Bei Amazon-EMR-Versionen 6.4.0 und höher ist die automatische Terminierung standardmäßig aktiviert, wenn Sie mit der Amazon-EMR-Konsole einen neuen Cluster erstellen.
- Amazon EMR veröffentlicht hochauflösende Amazon CloudWatch-Metriken, wenn Sie die automatische Beendigung für einen Cluster aktivieren. Sie können diese Metriken verwenden, um Cluster-Aktivität und Inaktivität zu verfolgen. Weitere Informationen finden Sie unter Cluster-Kapazitätsmetriken.
- Die automatische Terminierung wird nicht unterstützt, wenn Sie Anwendungen verwenden, die nicht auf Yarn basieren, wie Presto, Trino oder HBase.
- Um die automatische Terminierung zu verwenden, muss der Metrics-Collector-Prozess in der Lage sein, eine Verbindung zum öffentlichen API-Endpunkt für die automatische Terminierung in API Gateway herzustellen. Wenn Sie einen privaten DNS-Namen mit Amazon Virtual Private Cloud verwenden, funktioniert die automatische Terminierung nicht ordnungsgemäß. Um sicherzustellen, dass die automatische Beendigung funktioniert, empfehlen wir Ihnen, eine der folgenden Maßnahmen zu ergreifen:
  - Entfernen Sie den VPC-Endpunkt der API-Gateway-Schnittstelle aus Ihrer Amazon VPC.
  - Folgen Sie den Anweisungen unter Warum erhalte ich den Fehler HTTP 403 Forbidden, wenn ich von einer VPC aus eine Verbindung zu meinen API-Gateway-APIs herstelle?, um die Einstellung des privaten DNS-Namens zu deaktivieren.
  - Starten Sie Ihren Cluster stattdessen in einem privaten Subnetz. Weitere Informationen finden Sie im Thema Private Subnetze.
- (EMR 5.30.0 und höher) Wenn Sie die Standardregel Allow All Outbound für die primäre Sicherheitsgruppe auf 0.0.0.0/ entfernen, müssen Sie Ihrer Sicherheitsgruppe eine Regel hinzufügen, die ausgehende TCP-Konnektivität für den Servicezugriff auf Port 9443 zulässt. Die Sicherheitsgruppe für den Servicezugriff muss eingehenden Datenverkehr über TCP- und UDP-Port 53 von Ihrer primären Sicherheitsgruppe zulassen. Weitere Informationen über die Konfiguration von Sicherheitsgruppen finden Sie unter Von Amazon EMR verwaltete Sicherheitsgruppe für die primäre Instance (private Subnetze).

Berechtigungen zur Verwendung der automatischen Beendigung

Bevor Sie Richtlinien zur automatischen Kündigung für Amazon EMR anwenden und verwalten können, müssen Sie die in der folgenden Beispiel-IAM-Berechtigungsrichtlinie aufgeführten Berechtigungen den IAM-Ressourcen zuordnen, die Ihren EMR-Cluster verwalten.

```
{
  "Version": "2012-10-17",
  "Statement": {
      "Sid": "AllowAutoTerminationPolicyActions",
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:PutAutoTerminationPolicy",
        "elasticmapreduce:GetAutoTerminationPolicy",
        "elasticmapreduce:RemoveAutoTerminationPolicy"
      ],
      "Resource": "<your-resources>"
    }
}
```

Eine Richtlinie zur automatischen Beendigung anhängen, aktualisieren oder entfernen

Dieser Abschnitt enthält Anweisungen, die Ihnen helfen, eine Richtlinie zur automatischen Beendigung an einen Amazon-EMR-Cluster anzuhängen, zu aktualisieren oder zu entfernen. Bevor Sie mit Richtlinien zur automatischen Beendigung arbeiten, stellen Sie sicher, dass Sie über die erforderlichen IAM-Berechtigungen verfügen. Siehe Berechtigungen zur Verwendung der automatischen Beendigung.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Wie Sie eine automatische Beendigungsrichtlinie anzuhängen, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Clusterbeendigung die Option Cluster nach Leerlauf beenden aus.
4. Geben Sie die Anzahl der Stunden und Minuten im Leerlauf an, die vergehen können, bis der Cluster automatisch beendet wird. Die standardmäßige Leerlaufzeit beträgt eine Stunde.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Um eine automatische Terminierungsrichtlinie auf einem laufenden Cluster mit der neuen Konsole anzuhängen, zu aktualisieren oder zu entfernen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Suchen Sie auf der Registerkarte Eigenschaften der Cluster-Detailseite nach Clusterbeendigung und wählen Sie Bearbeiten aus.
4. Wählen oder deaktivieren Sie Automatische Beendigung aktivieren, um das Feature ein- oder auszuschalten. Wenn Sie die automatische Terminierung aktivieren, geben Sie die Anzahl der Stunden und Minuten im Leerlauf an, die vergehen können, bis der Cluster automatisch beendet wird. Wählen Sie dann zur Bestätigung Änderungen speichern aus.

Old console

Um eine automatische Terminierungsrichtlinie anzuhängen, wenn Sie einen Cluster mit der alten Konsole erstellen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie unter Hardwarekonfiguration die Option Automatische Beendigung aus.
4. Geben Sie die Anzahl der Stunden und Minuten im Leerlauf an, nach denen der Cluster automatisch beendet werden soll. Die standardmäßige Leerlaufzeit beträgt eine Stunde.
5. Wählen Sie weitere Einstellungen wie für Ihre Anwendung erforderlich und dann Create cluster (Cluster erstellen) aus.

Um eine automatische Terminierungsrichtlinie auf einem laufenden Cluster mit der alten Konsole anzuhängen, zu aktualisieren oder zu entfernen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Cluster und wählen Sie den Cluster aus, den Sie aktualisieren möchten.
3. Wählen Sie auf der Cluster-Detailseite die Registerkarte Hardware.
4. Wählen oder deaktivieren Sie Automatische Beendigung aktivieren, um das Feature ein- oder auszuschalten. Wenn Sie die automatische Beendigung aktivieren, geben Sie die Anzahl der Leerlaufzeiten und Minuten an, nach denen der Cluster automatisch beendet werden soll.

AWS CLI

Bevor Sie beginnen

Bevor Sie mit Richtlinien zur automatischen Kündigung arbeiten, empfehlen wir Ihnen, auf die neueste Version von AWS CLI zu aktualisieren. Anweisungen finden Sie unter Installieren, Aktualisieren und Deinstallieren von AWS CLI.

Um eine automatische Beendigungsrichtlinie anzuhängen oder zu aktualisieren, verwenden Sie AWS CLI

- Sie können den `aws emr put-auto-termination-policy`-Befehl verwenden, um eine automatische Beendigungssrichtlinie für einen Cluster anzuhängen oder zu aktualisieren.

  Im folgenden Beispiel werden 3 600 Sekunden für *`IdleTimeout`* angegeben. Wenn Sie *`IdleTimeout`* nicht angeben, verwendet das System standardmäßig eine Stunde.

  ```
  aws emr put-auto-termination-policy \
  --cluster-id <your-cluster-id> \
  --auto-termination-policy IdleTimeout=3600
  ```

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

  Sie können auch einen Wert für `--auto-termination-policy` angeben, wenn Sie den `aws emr create-cluster`-Befehl verwenden. Weitere Informationen zu den Amazon-EMR-Befehlen finden Sie unter AWS CLI in der AWS CLI-Befehlsreferenz.

Um eine automatische Beendigungsrichtlinie zu entfernen mit dem AWS CLI

- Verwenden Sie den `aws emr remove-auto-termination-policy`-Befehl, um eine automatische Beendigungsrichtlinie aus einem Cluster zu entfernen. Weitere Informationen zu den Amazon-EMR-Befehlen finden Sie unter AWS CLI in der AWS CLI-Befehlsreferenz.

  ```
  aws emr remove-auto-termination-policy --cluster-id <your-cluster-id>
  ```

Verwenden des Beendigungsschutzes

Wenn der Beendigungsschutz für einen langlebigen Cluster aktiviert ist, können Sie den Cluster weiter beenden, müssen jedoch zunächst den Beendigungsschutz explizit aus dem Cluster entfernen. So wird sichergestellt, dass EC2-Instances nicht versehentlich oder aufgrund eines

Fehlers heruntergefahren werden. Der Beendigungsschutz ist besonders nützlich, wenn Ihr Cluster Daten auf lokalen Datenträgern gespeichert hat, die Sie vor dem Beenden der Instances wiederherstellen müssen. Sie können den Beendigungsschutz aktivieren, wenn Sie einen Cluster erstellen. Sie können die Einstellung auf einem ausgeführten Cluster ändern.

Wenn der Beendigungsschutz aktiviert ist, funktioniert die Aktion `TerminateJobFlows` in der Amazon-EMR-API nicht. Benutzer können den Cluster nicht über diese API oder den Befehl `terminate-clusters` in der AWS CLI beenden. Die API gibt einen Fehler zurück und die CLI wird mit einem Rückgabecode ungleich null beendet. Wenn Sie die Amazon-EMR-Konsole verwenden, um einen Cluster zu beenden, werden Sie zu einem zusätzlichen Schritt aufgefordert, um den Beendigungsschutz zu deaktivieren.

> **Warning**
>
> Der Kündigungsschutz garantiert nicht, dass Daten im Falle eines menschlichen Fehlers oder einer Behelfslösung erhalten bleiben, z. B. wenn ein Neustartbefehl von der Befehlszeile aus ausgegeben wird, während eine SSH-Verbindung mit der Instance besteht, wenn eine Anwendung oder ein Skript, das auf der Instance ausgeführt wird, einen Neustartbefehl ausgibt oder wenn die Amazon-EC2- oder Amazon-EMR-API verwendet wird, um den Kündigungsschutz zu deaktivieren. Selbst wenn der Beendigungsschutz aktiviert ist, können im Instance-Speicher gespeicherte Daten, einschließlich HDFS-Daten, verloren gehen. Schreiben Sie die Datenausgabe an Amazon-S3-Standorte und erstellen Sie Backup-Strategien, die Ihren Anforderungen an die Geschäftskontinuität entsprechen.

Der Beendigungsschutz wirkt sich nicht auf Ihre Fähigkeit aus, Cluster-Ressourcen mit einer der folgenden Aktionen zu skalieren:

- Manuelles Ändern der Größe eines Clusters über die AWS Management Console oder AWS CLI. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters.
- Entfernen von Instances aus einer Core- oder Aufgaben-Instance-Gruppe unter Verwendung einer Abwärtsskalierungsrichtlinie mit Auto Scaling. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .
- Entfernen von Instances aus einer Instance-Flotte durch Reduzierung der Zielkapazität. Weitere Informationen finden Sie unter Instance-Flotten-Optionen.

Beendigungsschutz und Amazon EC2

Für einen Amazon-EMR-Cluster mit aktiviertem Beendigungsschutz ist das Attribut `disableAPITermination` für alle Amazon-EC2-Instances im Cluster festgelegt. Wenn eine Kündigungsanfrage von Amazon EMR stammt und die Amazon-EMR- und Amazon-EC2-Einstellungen für eine Instance in Konflikt geraten, überschreibt die Amazon-EMR-Einstellung die Amazon-EC2-Einstellung. Wenn Sie beispielsweise die Amazon-EC2-Konsole verwenden, um den Beendigungsschutz auf einer Amazon-EC2-Instance in einem Cluster zu aktivieren, bei dem der Beendigungsschutz deaktiviert ist, verwenden Sie die Amazon-EMR-Konsole, AWS CLI-Befehle für Amazon EMR oder die Amazon-EMR-API, um den Cluster zu beenden, setzt Amazon EMR `DisableApiTermination` auf `false` und beendet die Instance zusammen mit anderen Instances.

> **Important**
>
> Wenn eine Instance als Teil eines Amazon-EMR-Clusters mit Beendigungsschutz erstellt wird und die Amazon-EC2-API- oder AWS CLI-Befehle zum Ändern der Instance verwendet werden, sodass `DisableApiTermination` `false` ist, und die Amazon-EC2-API oder die AWS CLI-Befehle anschließend die Aktion `TerminateInstances` ausführen, wird die Amazon-EC2-Instance beendet.

Beendigungsschutz und instabile YARN-Knoten

Amazon EMR prüft regelmäßig den Status von Apache Hadoop YARN-Knoten, die in Amazon EC2 auf Core- und Aufgaben-Instances in einem Cluster ausgeführt werden. Der Status wird durch den NodeManager Checker Service gemeldet. Wenn ein Knoten `UNHEALTHY` meldet, sperrt der Amazon-EMR-Instance-Controller den Knoten und weist diesem erst dann wieder YARN-Container zu, wenn er wieder stabil ist. Ein häufiger Grund für instabile Knoten ist eine Datenträgernutzung von mehr als 90 %. Weitere Informationen zum Identifizieren und Wiederherstellen instabiler Knoten finden Sie unter Ressourcenfehler.

Wenn der Knoten länger als 45 Minuten im Zustand `UNHEALTHY` bleibt, ergreift Amazon EMR die folgenden Maßnahmen, abhängig vom Status des Beendigungsschutzes.

Termination protection	Ergebnis
Aktiviert (empfohlen)	

Termination protection	Ergebnis
	Amazon-EC2-Core-Instances befinden sich weiterhin in einem Status auf der Ablehnung sliste und werden weiterhin auf die Clusterka pazität angerechnet. Sie können eine Verbindung mit der Amazon-EC2-Core-In stance zu Konfigurations- und Datenwied erherstellungszwecke herstellen und die Größe Ihres Clusters anpassen, um Kapazität hinzuzufügen. Weitere Informationen finden Sie unter Ressourcenfehler. Fehlerhafte Aufgabenknoten sind vom Beendigungsschutz ausgenommen und werden beendet.

Termination protection	Ergebnis
Disabled	Die Amazon-EC2-Instance wird beendet. Amazon EMR stellt eine neue Instance basierend auf der angegebenen Anzahl von Instances in der Instance-Gruppe oder der Zielkapazität für Instance-Flotten bereit. Wenn alle Core-Knoten länger als 45 Minuten im Zustand `UNHEALTHY` sind, wird der Cluster beendet. Der Cluster meldet den Status `NO_SLAVES_LEFT` . **Important** Möglicherweise gehen HDFS-Daten verloren, wenn eine Core-Instance aufgrund eines instabilen Status beendet wird. Wenn der Knoten Blöcke gespeichert hat, die nicht zu anderen Knoten repliziert wurden, gehen diese Blöcke verloren, was zu Datenverlusten führen könnte. Sie sollten den Beendigungsschutz verwenden, um Verbindungen mit Instances herstellen und Daten wiederherstellen zu können, wenn notwendig.

Beendigungsschutz und Schrittausführung

Wenn Sie die Schrittausführung aktivieren und gleichzeitig den Beendigungsschutz aktivieren, ignoriert Amazon EMR den Beendigungsschutz.

Wenn Sie Schritte an einen Cluster übermitteln, können Sie die Eigenschaft `ActionOnFailure` festlegen, um zu bestimmen, was passiert, wenn die Ausführung eines Schritts aufgrund eines Fehlers nicht abgeschlossen werden kann. Die möglichen Werte für diese Einstellung sind

TERMINATE_CLUSTER (TERMINATE_JOB_FLOW mit früheren Versionen), CANCEL_AND_WAIT und CONTINUE. Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.

Wenn ein Schritt fehlschlägt, für den ActionOnFailure auf CANCEL_AND_WAIT festgelegt wurde, und die Schrittausführung aktiviert ist, wird der Cluster ohne Ausführung der nachfolgenden Schritte beendet.

Wenn ein Schritt fehlschlägt, für den ActionOnFailure auf TERMINATE_CLUSTER festgelegt wurde, können Sie anhand der folgenden Tabelle mit Einstellungen das Ergebnis ermitteln.

ActionOnFailure	Schrittausführung	Termination protection	Ergebnis
TERMINATE_CLUSTER	Enabled	Disabled	Cluster wird beendet
	Enabled	Enabled	Cluster wird beendet
	Disabled	Enabled	Cluster wird weiter ausgeführt
	Disabled	Disabled	Cluster wird beendet

Beendigungsschutz und Spot Instances

Der Amazon-EMR-Beendigungsschutz verhindert nicht, dass eine Amazon-EC2-Spot Instance beendet wird, wenn der Spot-Preis den Spot-Höchstpreis überschreitet.

Konfigurieren des Beendigungsschutzes beim Starten eines Clusters

Sie können den Beendigungsschutz aktivieren oder deaktivieren, wenn Sie einen Cluster über die Konsole, AWS CLI oder API starten.

Die Standardeinstellung für den Beendigungsschutz ist davon abhängig, wie Sie den Cluster starten:

- Amazon-EMR-Konsole (neu) – Beendigungsschutz ist standardmäßig aktiviert.
- Amazon-EMR-Konsole (alt) Schnelloptionen – Beendigungsschutz ist standardmäßig deaktiviert.
- Amazon-EMR-Konsole (alt) erweiterte Optionen – Beendigungsschutz ist standardmäßig aktiviert.

- AWS CLI `aws emr create-cluster`– Der Beendigungsschutz ist deaktiviert, sofern `--termination-protected` nicht anders angegeben.
- Befehl RunJobFlow der Amazon-EMR-API – Beendigungsschutz ist deaktiviert, sofern der `TerminationProtected` boolesche Wert nicht auf `true` gesetzt ist.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Beendigungsschutz aktivieren oder deaktivieren, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie für EMR-Release-Version die Option emr-6.6.0 oder höher aus.
4. Vergewissern Sie sich, dass unter Clusterbeendigung die Option Beendigungsschutz verwenden vorausgewählt ist, oder löschen Sie die Auswahl, um ihn auszuschalten.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Beendigungsschutz aktivieren oder deaktivieren, wenn Sie einen Cluster mit der alten Konsole erstellen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).

3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Stellen Sie sicher, dass in Step 3: General Cluster Settings (Schritt 3: Allgemeine Cluster-Einstellungen) in General Options (Allgemeine Optionen) die Option Termination protection (Beendigungsschutz) ausgewählt ist, wenn Sie den Beendigungsschutz aktivieren möchten. Deaktivieren Sie die Option, um den Beendigungsschutz zu deaktivieren.
5. Wählen Sie weitere Einstellungen wie für Ihre Anwendung erforderlich und anschließend Next (Weiter) aus. Stellen Sie die Konfigurierung des Clusters fertig.

AWS CLI

Beendigungsschutz aktivieren oder deaktivieren, wenn Sie einen Cluster mit AWS CLI

- Sie können einen Cluster mit aktiviertem Beendigungsschutz über die AWS CLI erstellen, indem Sie den Befehl `create-cluster` mit dem Parameter `--termination-protected` verwenden. Der Beendigungsschutz ist standardmäßig deaktiviert.

  Im folgenden Beispiel wird ein Cluster mit aktiviertem Beendigungsschutz erstellt:

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

  ```
  aws emr create-cluster --name "TerminationProtectedCluster" --release-
  label emr-5.36.1 \
  --applications Name=Hadoop Name=Hive Name=Pig \
  --use-default-roles --ec2-attributes KeyName=myKey --instance-type m5.xlarge \
  --instance-count 3 --termination-protected
  ```

  Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Konfigurieren des Beendigungsschutzes für aktive Cluster

Sie können den Beendigungsschutz für einen aktiven Cluster mithilfe der Konsole oder AWS CLI konfigurieren.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Beendigungsschutz für einen laufenden Cluster mit der neuen Konsole aktivieren oder deaktivieren

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Suchen Sie auf der Registerkarte Eigenschaften der Cluster-Detailseite nach Clusterbeendigung und wählen Sie Bearbeiten aus.
4. Aktivieren oder deaktivieren Sie das Kontrollkästchen Beendigungsschutz verwenden, um das Feature ein- oder auszuschalten. Wählen Sie dann zur Bestätigung Änderungen speichern aus.

Old console

Beendigungsschutz für einen laufenden Cluster mit der alten Konsole aktivieren oder deaktivieren

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie auf der Seite Clusters (Cluster) den Wert für Name (Name) Ihres Clusters aus.
3. Wählen Sie auf der Registerkarte Summary (Übersicht) in Termination protection (Beendigungsschutz) die Option Change (Ändern) aus.

4. Um den Beendigungsschutz zu aktivieren, wählen Sie On (Ein) aus. Um den Beendigungsschutz zu deaktivieren, wählen Sie Off (Aus) aus. Wählen Sie dann das grüne Häkchen aus, um die Auswahl zu bestätigen.

AWS CLI

Beendigungsschutz für einen laufenden Cluster mit AWS CLI aktivieren oder deaktivieren

- Um den Beendigungsschutz für einen ausgeführten Cluster über die AWS CLI zu aktivieren, verwenden Sie den Befehl `modify-cluster-attributes` mit dem Parameter `--termination-protected`. Um ihn zu deaktivieren, verwenden Sie den Parameter `--no-termination-protected`.

  Im folgenden Beispiel wird der Beendigungsschutz für das Cluster mit der ID *j-3KVTXXXXXX7UG* aktiviert:

  ```
  aws emr modify-cluster-attributes --cluster-id j-3KVTXXXXXX7UG --termination-protected
  ```

  Im folgenden Beispiel wird der Beendigungsschutz für dasselbe Cluster deaktiviert:

  ```
  aws emr modify-cluster-attributes --cluster-id j-3KVTXXXXXX7UG --no-termination-protected
  ```

Arbeiten mit Amazon-Linux-AMIs in Amazon EMR

Amazon Machine Images (AMIs) von Amazon Linux

Amazon EMR verwendet ein Amazon Machine Image (AMI) von Amazon Linux, um Amazon-EC2-Instances zu initialisieren, wenn Sie einen Cluster erstellen und starten. Das AMI enthält das Amazon-Linux-Betriebssystem, weitere Software und die für die einzelnen Instances zum Hosten Ihrer Cluster-Anwendungen erforderlichen Konfigurationen.

Wenn Sie einen Cluster erstellen, verwendet Amazon EMR standardmäßig ein Amazon-Linux-Standard-AMI, das speziell für die von Ihnen verwendete Amazon-EMR-Version erstellt wurde. Weitere Informationen zum standardmäßigen Amazon Linux AMI finden Sie unter Verwenden des Standard-Amazon-Linux-AMI für Amazon EMR. Wenn Sie Amazon EMR 5.7.0 oder höher

verwenden, können Sie für Amazon EMR ein benutzerdefiniertes Amazon Linux AMI anstelle des standardmäßigen Amazon Linux AMI angeben. Ein benutzerdefiniertes AMI ermöglicht Ihnen das Verschlüsseln des Root-Gerät-Datenträgers und das Anpassen von Anwendungen und Konfigurationen als Alternative zu Bootstrap-Aktionen. Sie können ein benutzerdefiniertes AMI für jeden Instance-Typ in der Instance-Gruppen- oder Instance-Flottenkonfiguration eines Amazon-EMR-Clusters angeben. Die Unterstützung mehrerer benutzerdefinierter AMIs gibt Ihnen die Flexibilität, mehr als einen Architekturtyp in einem Cluster zu verwenden. Siehe Verwenden eines benutzerdefinierten AMI.

Amazon EMR fügt automatisch ein Amazon-EBS-Allzweck-SSD-Volume als Root-Gerät für alle AMIs an. Die Verwendung eines EBS-gestützten AMI verbessert die Leistung. Die Amazon-EBS-Kosten werden anteilig nach Stunde berechnet. Dies erfolgt auf der Grundlage der monatlichen Amazon-EBS-Gebühren für gp2-Volumes in der Region, in der der Cluster ausgeführt wird. Die Kosten pro Stunde für das Root-Volume in jeder Cluster-Instance in einer Region, in der 0,10 USD/GB/Monat berechnet werden, betragen beispielsweise ungefähr 0,00139 USD pro Stunde (0,10 USD/GB/Monat, dividiert durch 30 Tage, dividiert durch 24 Stunden mal 10 GB). Unabhängig davon, ob Sie das Amazon-Linux-Standard-AMI oder ein benutzerdefiniertes Amazon–Linux-AMI verwenden, können Sie die Größe des Amazon-EBS-Root-Gerät-Datenträgers mit 10–100 GiB angeben.

Weitere Informationen zu Amazon-Linux-AMIs finden Sie unter Amazon Machine Images (AMI). Weitere Informationen zum Instance-Speicher für Amazon-EMR-Instances finden Sie unter Instance-Speicher.

Verwenden des Standard-Amazon-Linux-AMI für Amazon EMR

Jede Amazon-EMR-Version verwendet ein standardmäßiges Amazon Linux AMI für Amazon EMR, es sei denn, Sie geben ein benutzerdefiniertes AMI an. Ab den Versionen Amazon EMR 5.36 und Amazon EMR 6.6 besteht das Standardverhalten für die Aktualisierung von Amazon Linux 2 (AL2) in einem Amazon-EMR-Standard-AMI darin, automatisch die neueste AL2-Version für das standardmäßige Amazon-EMR-AMI anzuwenden.

Automatische Amazon-Linux-2-Updates für Amazon-EMR-Versionen

Wenn Sie einen Cluster mit der neuesten Patch-Version von Amazon EMR 5.36 oder höher oder 6.6 oder höher starten, verwendet Amazon EMR die neueste Amazon-Linux-2-Version für das standardmäßige Amazon-EMR-AMI. Beispiele:

- Wenn es eine Version `x.x.0` und `x.x.1` gibt, erhält die `x.x.0`-Version beim `x.x.1`-Start keine AMI-Updates mehr.

- Ebenso erhält `x.x.1` beim Start von `x.x.2` keine AMI-Updates mehr.
- Später, wenn `x.y.0` veröffentlicht wird, erhält `x.x.[latest]` weiterhin AMI-Updates mit `x.y.[latest]`.

Um zu sehen, ob Sie die neueste Patch-Version verwenden, die durch die Zahl nach dem zweiten Dezimalpunkt (`6.8.1`) für eine Amazon-EMR-Version gekennzeichnet ist, sehen Sie sich die verfügbaren Versionen im Amazon-EMR-Versionshandbuch an, überprüfen Sie das Drop-down-Menü für Amazon-EMR-Versionen, wenn Sie einen Cluster in der Konsole erstellen, oder verwenden Sie die `ListReleaseLabels`-API- oder `list-release-labels`-CLI-Aktion. Um auf dem Laufenden zu bleiben, wenn wir eine neue Amazon-EMR-Version veröffentlichen, abonnieren Sie den RSS-Feed auf der Seite Was ist neu? im Versionshandbuch.

Wenn Sie möchten, können Sie Ihren Cluster mit der Amazon-Linux-Version starten, mit der die Amazon-EMR-Version zuerst ausgeliefert wurde. Weitere Informationen zum Spezifizieren der Amazon-Linux-Version für Ihren Cluster finden Sie unter Änderung der Amazon-Linux-Version beim Erstellen eines Clusters.

Standard-Amazon-Linux-Versionen

In der folgenden Tabelle sind Amazon-Linux-Informationen für die neueste Patch-Version von Amazon EMR 6.x, Version 6.6 und höher, aufgeführt.

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230727.0	4.14.320	14. August 2023	`us-east-1` , `us-east-2` , `us-west-1` , `us-west-2` , `eu-north-1` , `eu-west-1` , `eu-west-2` , `eu-west-3` , `eu-central-1` , `eu-central-2` (6.10+), `eu-south-1` ,

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
			`eu-south-2` (6.10+), `ap-east-1`, `ap-south-1`, `ap-south-2` (6.10+), `ap-southeast-3`, `ap-southeast-4` (6.8+ and 5.36.1), `ap-northeast-1`, `ap-northeast-2`, `ap-northeast-3`, `ap-southeast-1`, `ap-southeast-2`, `af-south-1`, `sa-east-1`, `me-central-1` (6.10+), `me-south-1`, `ca-central-1`, `il-central-1` (6.9+ and 5.36.1)

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230719.0	4.14.320	02. August 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 (6.10+), eu-south-1 , eu-south-2 (6.10+), ap-east-1 , ap-south-1 , ap-south-2 (6.10+), ap-southeast-3 , ap-southeast-4 (6.8+ and 5.36.1), ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 (6.10+), me-south-1 , ca-central-1 , il-central-1 (6.9+ and 5.36.1)

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230628.0	4.14.318	12. Juli 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 (6.10+), eu-south-1 , eu-south-2 (6.10+), ap-east-1 , ap-south-1 , ap-south-2 (6.10+), ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 (6.10+), me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230612.0	4.14.314	23. Juni 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 (6.10+), eu-south-1 , eu-south-2 (6.10+), ap-east-1 , ap-south-1 , ap-south-2 (6.10+), ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 (6.10+), me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230504.1	4.14.313	16. Mai 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 (6.10+), eu-south-1 , eu-south-2 (6.10+), ap-east-1 , ap-south-1 , ap-south-2 (6.10+), ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230418.0	4.14.311	3. Mai 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 (6,10 only), eu-south-1 , eu-south-2 (6,10 only), ap-east-1 , ap-south-1 , ap-south-2 (6,10 only), ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230404.1	4.14.311	18. April 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 , eu-south-1 , eu-south-2 , ap-east-1 , ap-south-1 , ap-south-2 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1
2.0.20230404.0	4.14.311	10. April 2023	us-east-1 , eu-west-3

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230320.0	4.14.309	30. März 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 , eu-south-1 , eu-south-2 , ap-east-1 , ap-south-1 , ap-south-2 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230307.0	4.14.305	15. März 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 , eu-south-1 , eu-south-2 , ap-east-1 , ap-south-1 , ap-south-2 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230207.0	4.14.304	03. März 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-central-2 , eu-south-1 , eu-south-2 , ap-east-1 , ap-south-1 , ap-south-2 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-central-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20230119.1	4.14.301	9. Februar 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20221210.1	4.14.301	12. Januar 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20221103.3	4.14.296	5. Dezember 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20221004.0	4.14.294	2. November 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20220912.1	4.14.291	7. Oktober 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1
2.0.20220805.0	4.14.287	30. August 2022	us-west-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20220719.0	4.14.287	10. August 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20220426.0	4.14.281	10. Juni 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelease Label (Amazon Linux-Version)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.20220406.1	4.14.275	2. Mai 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

In der folgenden Tabelle sind Amazon-Linux-Informationen für die neueste Patch-Version von Amazon EMR 5.x, Version 5.36 und höher, aufgeführt.

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2023 504.1	4.14.313	16. Mai 2023	USA Ost (Nord-Virginia), USA Ost (Ohio), USA West (Nordkalifornien), USA West (Oregon), Kanada (Zentral), Europa (Stockhol m), Europa (Irland), Europa (London), Europa (Paris), Europa (Frankfurt), Europa (Mailand), Asien-Pazifik (Hongkong), Asien-Paz ifik (Mumbai), Asien-Paz ifik (Jakarta), Asien-Paz ifik (Tokio), Asien-Paz ifik (Seoul), Asien-Pazifik (Osaka), Asien-Pazifik (Singapur), Asien-Pazifik (Sydney), Afrika (Kapstadt), Südamerika (São Paulo), Naher Osten (Bahrain), Naher Osten (VAE)
2.0.2023 418.0	4.14.311	3. Mai 2023	USA Ost (Nord-Virginia), USA Ost (Ohio), USA West (Nordkalifornien), USA West (Oregon), Kanada (Zentral), Europa (Stockhol m), Europa (Irland), Europa (London), Europa (Paris), Europa (Frankfurt), Europa

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
			(Mailand), Asien-Pazifik (Hongkong), Asien-Paz ifik (Mumbai), Asien-Paz ifik (Jakarta), Asien-Paz ifik (Tokio), Asien-Paz ifik (Seoul), Asien-Pazifik (Osaka), Asien-Pazifik (Singapur), Asien-Pazifik (Sydney), Afrika (Kapstadt), Südamerika (São Paulo), Naher Osten (Bahrain), Naher Osten (VAE)

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2023 404.1	4.14.311	18. April 2023	USA Ost (Nord-Virginia), USA Ost (Ohio), USA West (Nordkalifornien), USA West (Oregon), Kanada (Zentral), Europa (Stockhol m), Europa (Irland), Europa (London), Europa (Paris), Europa (Frankfurt), Europa (Mailand), Asien-Pazifik (Hongkong), Asien-Paz ifik (Mumbai), Asien-Paz ifik (Jakarta), Asien-Paz ifik (Tokio), Asien-Paz ifik (Seoul), Asien-Pazifik (Osaka), Asien-Pazifik (Singapur), Asien-Pazifik (Sydney), Afrika (Kapstadt), Südamerika (São Paulo), Naher Osten (Bahrain)
2.0.2023 404.0	4.14.311	10. April 2023	USA Ost (Nord-Virginia), Europa (Paris)

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2023 320.0	4.14.309	30. März 2023	USA Ost (Nord-Virginia), USA Ost (Ohio), USA West (Nordkalifornien), USA West (Oregon), Kanada (Zentral), Europa (Stockhol m), Europa (Irland), Europa (London), Europa (Paris), Europa (Frankfurt), Europa (Mailand), Asien-Pazifik (Hongkong), Asien-Paz ifik (Mumbai), Asien-Paz ifik (Jakarta), Asien-Paz ifik (Tokio), Asien-Paz ifik (Seoul), Asien-Pazifik (Osaka), Asien-Pazifik (Singapur), Asien-Pazifik (Sydney), Afrika (Kapstadt), Südamerika (São Paulo), Naher Osten (Bahrain)

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2023 307.0	4.14.305	15. März 2023	USA Ost (Nord-Virginia), USA Ost (Ohio), USA West (Nordkalifornien), USA West (Oregon), Kanada (Zentral), Europa (Stockhol m), Europa (Irland), Europa (London), Europa (Paris), Europa (Frankfurt), Europa (Mailand), Asien-Pazifik (Hongkong), Asien-Paz ifik (Mumbai), Asien-Paz ifik (Jakarta), Asien-Paz ifik (Tokio), Asien-Paz ifik (Seoul), Asien-Pazifik (Osaka), Asien-Pazifik (Singapur), Asien-Pazifik (Sydney), Afrika (Kapstadt), Südamerika (São Paulo), Naher Osten (Bahrain)

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2023 207.0	4.14.304	03. März 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-centra l-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southe ast-3 , ap-northe ast-1 , ap-northe ast-2 , ap-northe ast-3 , ap-southe ast-1 , ap-southe ast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2022 210.1	4.14.301	12. Januar 2023	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-centra l-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southe ast-3 , ap-northe ast-1 , ap-northe ast-2 , ap-northe ast-3 , ap-southe ast-1 , ap-southe ast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2022 103.3	4.14.296	5. Dezember 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2022 004.0	4.14.294	2. November 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-centra l-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southe ast-3 , ap-northe ast-1 , ap-northe ast-2 , ap-northe ast-3 , ap-southe ast-1 , ap-southe ast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2022 912.1	4.14.291	7. Oktober 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-central-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southeast-3 , ap-northeast-1 , ap-northeast-2 , ap-northeast-3 , ap-southeast-1 , ap-southeast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1
2.0.2022 719.0	4.14.287	10. August 2022	us-west-1 , eu-west-3 , eu-north-1 , eu-central-1 , ap-south-1 , me-south-1

OsRelea Label (Amazon Linux-Vers ion)	Amazon-Linux-Kernversion	Verfügbarkeitsdatum	Unterstützte Regionen
2.0.2022 426.0	4.14.281	14. Juni 2022	us-east-1 , us-east-2 , us-west-1 , us-west-2 , eu-north-1 , eu-west-1 , eu-west-2 , eu-west-3 , eu-centra l-1 , eu-south-1 , ap-east-1 , ap-south-1 , ap-southe ast-3 , ap-northe ast-1 , ap-northe ast-2 , ap-northe ast-3 , ap-southe ast-1 , ap-southe ast-2 , af-south-1 , sa-east-1 , me-south-1 , ca-central-1

Überlegungen zu Softwareupdates

Beachten Sie die folgenden Standardverhaltensweisen bei Softwareupdates:

Amazon EMR 5.35.0 und niedriger und 6.5.0 und niedriger – Amazon-Linux-AMI ist an die Amazon-EMR-Release-Version „gesperrt“

Für Amazon EMR 5.35.0 und niedriger sowie 6.5.0 und niedriger basiert das Standard-AMI auf dem aktuellsten Amazon-Linux-AMI, das zum Zeitpunkt der Amazon-EMR-Veröffentlichung verfügbar war. Das AMI wurde auf Kompatibilität mit den in dieser Version enthaltenen Big-Data-Anwendungen und Amazon-EMR-Features getestet.

Jede Amazon EMR 5.35.0 und niedrigere sowie Amazon-EMR-Release-Version 6.5.0 und niedriger ist zur Wahrung der Kompatibilität an die jeweils zugewiesene Amazon-Linux-AMI-Version „gesperrt“. Das bedeutet, dass niedrigere Amazon-Linux-AMI-Versionen für niedrigere Amazon-EMR-Release-Versionen verwendet werden, auch wenn neuere Amazon-Linux-AMIs verfügbar werden. Aus diesem Grund empfehlen wir Ihnen, die neueste Amazon-EMR-Version zu verwenden, es sei denn, Sie benötigen aus Kompatibilitätsgründen eine niedrigere Version und können nicht migrieren. Wenn Sie aus Kompatibilitätsgründen eine frühere Version von Amazon EMR verwenden müssen, sollten Sie stets die neueste Version in einer Reihe verwenden. Wenn Sie beispielsweise die Reihe 5.12 verwenden müssen, sollten Sie 5.12.2 und nicht 5.12.0 oder 5.12.1 verwenden. Wenn in einer Reihe eine neue Version verfügbar wird, sollten Sie eine Migration Ihrer Anwendungen auf die neue Version in Betracht ziehen.

Weitere Informationen zum Verhalten bei automatischen Updates, das mit Amazon EMR 5.36.0 und höher und 6.6.0 und höher eingeführt wurde, finden Sie unter Automatische Amazon-Linux-2-Updates für Amazon-EMR-Versionen.

Das standardmäßige Startverhalten schließt Kernel-Updates aus

Wenn eine Amazon-EC2-Instance in einem Cluster, der auf dem standardmäßigen Amazon-Linux-AMI für Amazon EMR basiert, zum ersten Mal gestartet wird, überprüft sie die aktivierten Paket-Repositorys für Amazon Linux und Amazon EMR auf Software-Updates, die für die AMI-Version gelten. Wie bei anderen Amazon-EC2-Instances auch, werden kritische und wichtige Sicherheitsupdates aus diesen Repositorys automatisch installiert. Wenn Sie jedoch eine ältere Version von Amazon-Linux-AMI verwenden, wird das neueste Sicherheitsupdate möglicherweise nicht automatisch installiert. Dies liegt daran, dass die von EMR referenzierten Repositorys für jede Version von Amazon-Linux-AMI repariert sind. Beachten Sie, dass Ihre Netzwerkkonfiguration den HTTP- und HTTPS-Ausgang zu Amazon-Linux-Repositorys in Amazon S3 zulassen muss, da andernfalls Sicherheitsupdates nicht erfolgreich sein werden. Weitere Informationen finden Sie unter Paket-Repository im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Standardmäßig sind andere Softwarepakete und Kernel-Updates, die einen Neustart erfordern, einschließlich NVIDIA und CUDA, vom automatischen Download beim ersten Start ausgeschlossen.

> **Important**
>
> Amazon-EMR-Cluster, auf denen Amazon-Linux- oder Amazon-Linux-2-AMIs (Amazon Linux Machine Images) ausgeführt werden, verwenden das Standardverhalten von Amazon Linux und laden wichtige und kritische Kernel-Updates, die einen Neustart erfordern, nicht automatisch herunter und installieren sie. Dies ist dasselbe Verhalten wie bei anderen

Amazon-EC2-Instances, auf denen das standardmäßige Amazon-Linux-AMI ausgeführt wird. Wenn neue Amazon-Linux-Softwareupdates, die einen Neustart erfordern (wie Kernel-, NVIDIA- und CUDA-Updates), nach der Veröffentlichung einer Amazon-EMR-Version verfügbar werden, laden Amazon-EMR-Cluster-Instances, auf denen das Standard-AMI ausgeführt wird, diese Updates nicht automatisch herunter und installieren sie. Um Kernel-Updates zu erhalten, können Sie Ihr Amazon-EMR-AMI so anpassen, dass es das neueste Amazon-Linux-AMI verwendet.

Der Cluster wird mit oder ohne Updates gestartet

Beachten Sie, dass die Cluster-Instance ihren Start trotzdem abschließt, wenn Softwareupdates nicht installiert werden können, weil Paket-Repositorys beim ersten Clusterstart nicht erreichbar sind. Beispielsweise sind Repositorys möglicherweise nicht erreichbar, weil S3 vorübergehend nicht verfügbar ist, oder Sie haben möglicherweise VPC- oder Firewallregeln so konfiguriert, dass sie den Zugriff blockieren.

`sudo yum update` nicht ausführen

Wenn Sie eine Verbindung mit einer Cluster-Instance über SSH herstellen, enthalten die ersten Zeilen der Bildschirmausgabe einen Link zu den Versionshinweisen für das von der Instance verwendete Amazon-Linux-AMI, einen Hinweis auf die jeweils aktuelle Amazon-Linux-AMI-Version, einen Hinweis auf die Anzahl der für das Update verfügbaren Pakete in den aktivierten Repositorys und eine Anweisung für die Ausführung von `sudo yum update`.

Important

Es wird nachdrücklich davon abgeraten, `sudo yum update` auf Cluster-Instances auszuführen, weder über eine SSH-Verbindung noch über eine Bootstrap-Aktion. Dies kann zu Inkompatibilitäten führen, da alle Pakete unterschiedslos installiert werden.

Bewährte Methoden für Softwareupdates

Bewährte Methoden für die Verwaltung von Software-Updates

- Wenn Sie eine ältere Version von Amazon EMR verwenden, sollten Sie eine Migration auf die neueste Version in Betracht ziehen und testen, bevor Sie Softwarepakete aktualisieren.

- Wenn Sie auf eine höhere Version migrieren oder Softwarepakete upgraden, sollten Sie die Implementierung zunächst in einer Umgebung außerhalb der Produktion testen. Die Option zum Klonen von Clustern über die Amazon-EMR-Managementkonsole ist für diese Zwecke nützlich.
- Sie sollten die Software-Updates für Ihre Anwendungen und Ihre Version des Amazon-Linux-AMI einzeln bewerten. Testen und installieren Sie nur Pakete in Produktionsumgebungen, die Ihrer Meinung nach für Sicherheit, Anwendungsfunktionalität oder Leistung unbedingt notwendig sind.
- Achten Sie im Amazon-Linux-Sicherheitszentrum auf Updates.
- Vermeiden Sie die Installation von Paketen über SSH-Verbindungen mit einzelnen Cluster-Instances. Verwenden Sie stattdessen eine Bootstrap-Aktion, um Pakete auf allen Cluster-Instances wie notwendig zu installieren und zu aktualisieren. Hierzu müssen Sie einen Cluster beenden und neu starten. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.

Verwenden eines benutzerdefinierten AMI

Wenn Sie Amazon EMR 5.7.0 oder höher verwenden, können Sie für Amazon EMR ein benutzerdefiniertes Amazon Linux AMI anstelle des standardmäßigen Amazon Linux AMI angeben. Ein benutzerdefiniertes AMI ist nützlich, wenn Sie Folgendes durchführen möchten:

- Installieren Sie Anwendungen vorab und führen Sie weitere Anpassungen aus, statt Bootstrap-Aktionen zu verwenden. Dies kann die Cluster-Startzeit verbessern und den Startup-Workflow optimieren. Weitere Informationen sowie ein Beispiel finden Sie unter Erstellen eines benutzerdefinierten Amazon-Linux-AMI aus einer vorkonfigurierten Instance.
- Implementierung komplexerer Cluster- und Knoten-Konfigurationen als von Bootstrap-Aktionen zugelassen.
- Verschlüsseln Sie die EBS-Root-Gerät-Datenträger (Start-Volumes) von EC2-Instances in Ihrem Cluster, wenn Sie eine frühere Amazon-EMR-Version als 5.24.0 verwenden. Wie beim Standard-AMI beträgt die Mindestgröße des Root-Volumes für ein benutzerdefiniertes AMI 10 GiB. Weitere Informationen finden Sie unter Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon-EBS-Root-Gerät-Datenträger.

> **Note**
>
> Ab Amazon-EMR-Version 5.24.0 können Sie eine Sicherheitskonfigurationsoption zum Verschlüsseln von EBS-Root-Geräten und Speicher-Volumes verwenden, wenn Sie

AWS KMS als Ihren Schlüsselanbieter angeben. Weitere Informationen finden Sie unter Verschlüsselung lokaler Datenträger.

Ein benutzerdefiniertes AMI muss in derselben AWS-Region vorhanden sein, in der Sie den Cluster erstellen. Es sollte auch der EC2-Instance-Architektur entsprechen. Eine m5.xlarge-Instance hat beispielsweise eine x86_64-Architektur. Um ein m5.xlarge mithilfe eines benutzerdefinierten AMI bereitzustellen, sollte Ihr benutzerdefiniertes AMI daher auch über eine x86_64-Architektur verfügen. Ebenso sollte Ihr benutzerdefiniertes AMI eine arm64-Architektur haben, um eine m6g.xlarge-Instance bereitzustellen, die über eine arm64-Architektur verfügt. Weitere Informationen zum Herstellen einer Verbindung mit einer Linux-Instance finden Sie unter Herstellen einer Verbindung mit Ihrer Linux-Instance im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Important

Amazon-EMR-Cluster, auf denen Amazon-Linux- oder Amazon-Linux-2-AMIs (Amazon Linux Machine Images) ausgeführt werden, verwenden das Standardverhalten von Amazon Linux und laden wichtige und kritische Kernel-Updates, die einen Neustart erfordern, nicht automatisch herunter und installieren sie. Dies ist dasselbe Verhalten wie bei anderen Amazon-EC2-Instances, auf denen das standardmäßige Amazon-Linux-AMI ausgeführt wird. Wenn neue Amazon-Linux-Softwareupdates, die einen Neustart erfordern (wie Kernel-, NVIDIA- und CUDA-Updates), nach der Veröffentlichung einer Amazon-EMR-Version verfügbar werden, laden Amazon-EMR-Cluster-Instances, auf denen das Standard-AMI ausgeführt wird, diese Updates nicht automatisch herunter und installieren sie. Um Kernel-Updates zu erhalten, können Sie Ihr Amazon-EMR-AMI so anpassen, dass es das neueste Amazon-Linux-AMI verwendet.

Erstellen eines benutzerdefinierten Amazon-Linux-AMI aus einer vorkonfigurierten Instance

Die grundlegenden Schritte für das Vorinstallieren von Software und das Ausführen weiterer Konfigurationen zur Erstellung eines benutzerdefinierten Amazon-Linux-AMI für Amazon EMR sind:

- Starten Sie eine Instance über das Amazon-Linux-Basis-AMI.
- Stellen Sie eine Verbindung mit der Instance her, um Software zu installieren und andere Anpassungen vorzunehmen.

- Erstellen Sie ein neues Abbild (AMI-Snapshot) der Instance, die Sie konfiguriert haben.

Nachdem Sie das Abbild auf der Grundlage Ihrer benutzerdefinierten Instance erstellt haben, können Sie es auf ein verschlüsseltes Ziel kopieren, wie im Abschnitt Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon-EBS-Root-Gerät-Datenträger beschrieben.

Tutorial: Erstellen eines AMI aus einer Instance mit installierter eigener Software

So starten Sie eine EC2-Instance auf der Grundlage des neuesten Amazon Linux-AMI

1. Verwenden Sie die AWS CLI, um den folgenden Befehl auszuführen, mit dem eine Instance aus einem vorhandenen AMI erstellt wird. Ersetzen Sie *MyKeyName* mit dem Schlüsselpaar, das Sie für die Verbindung mit der Instance verwenden, und *MyAmiId* mit der ID eines geeigneten Amazon Linux AMI. Die neuesten AMI-IDs finden Sie unter Amazon Linux AMI.

   > **Note**
   >
   > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

   ```
   aws ec2 run-instances --image-id MyAmiID \
   --count 1 --instance-type m5.xlarge \
   --key-name MyKeyName --region us-west-2
   ```

   Der Ausgabewert `InstanceId` wird im nächsten Schritt als *MyInstanceId* verwendet.

2. Führen Sie den Befehl aus:

   ```
   aws ec2 describe-instances --instance-ids MyInstanceId
   ```

   Der Ausgabewert `PublicDnsName` wird im nächsten Schritt verwendet, um eine Verbindung mit der Instance herzustellen.

So stellen Sie eine Verbindung mit der Instance her und installieren Software

1. Verwenden Sie eine SSH-Verbindung, mit der Sie Shell-Befehle auf Ihrer Linux-Instance ausführen können. Weitere Informationen finden Sie unter Herstellen einer Verbindung mit Ihrer Linux-Instance mit SSH im Amazon-EC2-Benutzerhandbuch für Linux-Instances.
2. Führen Sie alle erforderlichen Anpassungen durch. Beispiele:

```
sudo yum install MySoftwarePackage
sudo pip install MySoftwarePackage
```

So erstellen Sie einen Snapshot vom benutzerdefinierten Abbild

- Nachdem Sie die Instance angepasst haben, erstellen Sie mithilfe des Befehls `create-image` ein AMI von der Instance.

```
aws ec2 create-image --no-dry-run --instance-id MyInstanceId --name MyEmrCustomAmi
```

Der Ausgabewert `imageID` wird verwendet, wenn Sie den Cluster starten oder einen verschlüsselten Snapshot erstellen. Weitere Informationen finden Sie unter Ein einzelnes benutzerdefiniertes AMI in einem EMR-Cluster verwenden und Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon-EBS-Root-Gerät-Datenträger.

So verwenden Sie ein benutzerdefiniertes AMI in einem Amazon-EMR-Cluster

Sie können ein benutzerdefiniertes AMI verwenden, um einen Amazon-EMR-Cluster auf zwei Arten bereitzustellen:

- Verwenden Sie ein einziges benutzerdefiniertes AMI für alle EC2-Instances im Cluster.
- Verwenden Sie unterschiedliche benutzerdefinierte AMIs für die verschiedenen EC2-Instance-Typen, die im Cluster verwendet werden.

Sie können bei der Bereitstellung eines EMR-Clusters nur eine der beiden Optionen verwenden, und Sie können sie nicht mehr ändern, nachdem der Cluster gestartet wurde.

Überlegungen zur Verwendung einzelner oder mehrerer benutzerdefinierter AMIs in einem Amazon-EMR-Cluster

Überlegungen	Einfaches benutzerdefiniertes AMI	Mehrere benutzerdefinierte AMIs
Verwenden Sie sowohl x86- als auch Graviton2-Prozessoren mit benutzerdefinierten AMIs im selben Cluster	✗ Nicht unterstützt	✓ Wird unterstützt
Die AMI-Anpassung variiert je nach Instance-Typ	✗ Nicht unterstützt	✓ Wird unterstützt
Ändern Sie benutzerdefinierte AMIs, wenn Sie einem laufenden Cluster neue Aufgaben-Instance-Gruppen/-Flotten hinzufügen. Hinweis: Sie können das benutzerdefinierte AMI vorhandener Instance-Gruppen/Flotten nicht ändern.	✗ Nicht unterstützt	✓ Wird unterstützt
AWS Console verwenden, um einen Cluster zu starten	✓ Wird unterstützt	✗ Nicht unterstützt
AWS CloudFormation verwenden, um einen Cluster zu starten	✓ Wird unterstützt	✓ Wird unterstützt

Ein einzelnes benutzerdefiniertes AMI in einem EMR-Cluster verwenden

Verwenden Sie eine der folgenden Optionen, um eine benutzerdefinierte AMI-ID anzugeben, wenn Sie einen Cluster erstellen:

- AWS Management Console
- AWS CLI
- Amazon-EMR-SDK
- Amazon-EMR-API RunJobFlow

- AWS CloudFormation (siehe die `CustomAmiID`-Eigenschaft in Cluster InstanceGroupConfig, Cluster InstanceTypeConfig, Resource InstanceGroupConfig, oder Resource InstanceFleetConfig-InstanceTypeConfig)

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So geben Sie ein einzelnes benutzerdefiniertes AMI mit der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Suchen Sie unter Name und Anwendungen nach Betriebssystemoptionen. Wählen Sie Benutzerdefiniertes AMI und geben Sie Ihre AMI-ID in das Feld Benutzerdefiniertes AMI ein.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So geben Sie ein einzelnes benutzerdefiniertes AMI mit der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.
3. Wählen Sie unter Softwarekonfiguration die Version emr-5.7.0 oder höher als Veröffentlichung und anschließend wie erforderlich weitere Optionen für Ihre Anwendung aus. Wählen Sie Next (Weiter).

4. Wählen Sie unter Hardware Configuration (Hardwarekonfiguration) für Ihre Anwendung geeignete Werte und anschließend Next (Weiter) aus.
5. Geben Sie unter Zusätzliche Optionen für Benutzerdefinierte AMI-ID einen Wert ein und stellen Sie sicher, dass die Option Alle installierten Pakete beim Neustart aktualisieren ausgewählt ist. Weitere Informationen zum Ändern der Update-Option finden Sie unter Verwalten von Updates für AMI-Paket-Repositorys.
6. Wählen Sie zum Starten des Clusters Next (Weiter) aus und legen Sie weitere Konfigurationsoptionen fest.

AWS CLI

So geben Sie ein einzelnes benutzerdefiniertes AMI mit AWS CLI an

- Verwenden Sie den Parameter `--custom-ami-id` zum Angeben der AMI-ID, wenn Sie den Befehl `aws emr create-cluster` ausführen.

  Im folgenden Beispiel wird ein Cluster angegeben, der ein einzelnes benutzerdefiniertes AMI mit einem 20 GiB-Boot-Volume verwendet. Weitere Informationen finden Sie unter Größenangabe des Amazon-EBS-Root-Gerät-Datenträgers.

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "Cluster with My Custom AMI" \
--custom-ami-id MyAmiID --ebs-root-volume-size 20 \
--release-label emr-5.7.0 --use-default-roles \
--instance-count 2 --instance-type m5.xlarge
```

Mehrere benutzerdefinierte AMIs in einem Amazon-EMR-Cluster verwenden

Verwenden Sie eine der folgenden Optionen, um einen Cluster mit mehreren benutzerdefinierten AMIs zu erstellen:

- AWS-CLI-Version 1.20.21 oder höher
- AWS-SDK
- Amazon EMR RunJobFlow in der Amazon-EMR-API-Referenz
- AWS CloudFormation (siehe die `CustomAmiID`-Eigenschaft in Cluster InstanceGroupConfig, Cluster InstanceTypeConfig, Resource InstanceGroupConfig, oder Resource InstanceFleetConfig-InstanceTypeConfig)

Die AWS-Managementkonsole unterstützt derzeit nicht die Erstellung eines Clusters mit mehreren benutzerdefinierten AMIs.

Example – Verwenden Sie die AWS-CLI, um einen Instance-Gruppen-Cluster mit mehreren benutzerdefinierten AMIs zu erstellen

Mit der AWS-CLI-Version 1.20.21 oder höher können Sie dem gesamten Cluster ein einzelnes benutzerdefiniertes AMI zuweisen, oder Sie können jedem Instance-Knoten in Ihrem Cluster mehrere benutzerdefinierte AMIs zuweisen.

Das folgende Beispiel zeigt einen einheitlichen Instancegruppen-Cluster, der mit zwei Instance-Typen (m5.xlarge) erstellt wurde, die für alle Knotentypen (Haupt, Core, Aufgabe) verwendet werden. Jeder Knoten hat mehrere benutzerdefinierte AMIs. Das Beispiel veranschaulicht mehrere Features der Konfiguration mit mehreren benutzerdefinierten AMIs:

- Auf Cluster-Ebene ist kein benutzerdefiniertes AMI zugewiesen. Dadurch sollen Konflikte zwischen den mehreren benutzerdefinierten AMIs und einem einzelnen benutzerdefinierten AMI vermieden werden, die dazu führen würden, dass der Clusterstart fehlschlägt.
- Der Cluster kann über mehrere benutzerdefinierte AMIs für Haupt-, Core- und einzelne Aufgabenknoten verfügen. Dies ermöglicht individuelle AMI-Anpassungen, wie z. B. vorinstallierte Anwendungen, ausgefeilte Cluster-Konfigurationen und verschlüsselte Amazon EBS-Root-Geräte-Volumes.
- Der Core-Knoten der Instance-Gruppe kann nur einen Instance-Typ und ein entsprechendes benutzerdefiniertes AMI haben. Ebenso kann der Hauptknoten nur einen Instance-Typ und ein entsprechendes benutzerdefiniertes AMI haben.

- Der Cluster kann mehrere Aufgabenknoten haben.

```
aws emr create-cluster --instance-groups
InstanceGroupType=MASTER,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-123456
InstanceGroupType=CORE,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-234567
InstanceGroupType=TASK,InstanceType=m6g.xlarge,InstanceCount=1,CustomAmiId=ami-345678
InstanceGroupType=TASK,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-456789
```

Example – Verwenden Sie die AWS CLI-Version 1.20.21 oder höher, um einem laufenden Instance-Gruppen-Cluster mit mehreren Instancetypen und mehreren benutzerdefinierten AMIs einen Aufgabenknoten hinzuzufügen

Mit der AWS-CLI-Version 1.20.21 oder höher können Sie einer Instance-Gruppe, die Sie einem laufenden Cluster hinzufügen, mehrere benutzerdefinierte AMIs hinzufügen. Das `CustomAmiId`-Argument kann zusammen mit dem `add-instance-groups`-Befehl verwendet werden, wie im folgenden Beispiel gezeigt. Beachten Sie, dass dieselbe mehrfache benutzerdefinierte AMI-ID (ami-123456) in mehr als einem Knoten verwendet wird.

```
aws emr create-cluster --instance-groups
InstanceGroupType=MASTER,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-123456
InstanceGroupType=CORE,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-123456
InstanceGroupType=TASK,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-234567

{
    "ClusterId": "j-123456",
    ...
}

aws emr add-instance-groups --cluster-id j-123456 --instance-groups
 InstanceGroupType=Task,InstanceType=m6g.xlarge,InstanceCount=1,CustomAmiId=ami-345678
```

Example – Verwenden Sie die AWS-CLI-Version 1.20.21 oder höher, um einen Instance-Flottencluster, mehrere benutzerdefinierte AMIs, mehrere Instance-Typen, On-Demand-Master, On-Demand-Core, mehrere Core- und Aufgabenknoten zu erstellen

```
aws emr create-cluster --instance-fleets
InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge
 CustomAmiId=ami-123456}']
InstanceFleetType=CORE,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge,C
{InstanceType=m6g.xlarge, CustomAmiId=ami-345678}']
```

```
InstanceFleetType=TASK,TargetSpotCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge,Custo
{InstanceType=m6g.xlarge, CustomAmiId=ami-567890}']
```

Example – Verwenden Sie die AWS-CLI-Version 1.20.21 oder höher, um Aufgabenknoten zu einem laufenden Cluster mit mehreren Instance-Typen und mehreren benutzerdefinierten AMIs hinzuzufügen

```
aws emr create-cluster --instance-fleets
InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge
 CustomAmiId=ami-123456}']
InstanceFleetType=CORE,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge,C
{InstanceType=m6g.xlarge, CustomAmiId=ami-345678}']

{
    "ClusterId": "j-123456",
    ...
}

aws emr add-instance-fleet --cluster-id j-123456 --instance-fleet
InstanceFleetType=TASK,TargetSpotCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge,Custo
{InstanceType=m6g.xlarge, CustomAmiId=ami-345678}']
```

Verwalten von Updates für AMI-Paket-Repositorys

Standardmäßig stellen Amazon-Linux-AMIs beim Erststart eine Verbindung mit Paket-Repositorys her, um Sicherheitsupdates zu installieren, bevor die anderen Dienste starten. Je nach Ihren Anforderungen können Sie diese Aktualisierungen deaktivieren, wenn Sie ein benutzerdefiniertes AMI für Amazon EMR angeben. Die Option zum Deaktivieren dieser Funktion steht ist nur verfügbar, wenn Sie ein benutzerdefiniertes AMI verwenden. Standardmäßig werden Amazon-Linux-Kernel-Updates und andere Softwarepakete, die einen Neustart erfordern, nicht aktualisiert. Beachten Sie, dass Ihre Netzwerkkonfiguration den HTTP- und HTTPS-Ausgang zu Amazon-Linux-Repositorys in Amazon S3 zulassen muss, da andernfalls Sicherheitsupdates nicht erfolgreich sein werden.

> **Warning**
>
> Wir empfehlen dringend, dass Sie beim Neustart alle installierten Pakete aktualisieren, wenn Sie ein benutzerdefiniertes AMI angeben. Wenn Sie keine Pakete aktualisieren, entstehen zusätzliche Sicherheitsrisiken.

Über die AWS Management Console können Sie die Option für die Deaktivierung von Updates auswählen, wenn Sie Benutzerdefinierte AMI auswählen.

Über die AWS CLI können Sie `--repo-upgrade-on-boot NONE` und `--custom-ami-id` auswählen, wenn Sie den Befehl create-cluster verwenden.

Bei Verwendung der Amazon-EMR-API können Sie `NONE` für den Parameter RepoUpgradeOnBoot angeben.

Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon-EBS-Root-Gerät-Datenträger

Um den Amazon-EBS-Root-Gerät-Datenträger eines Amazon-Linux-AMI für Amazon EMR zu verschlüsseln, kopieren Sie ein Snapshot-Abbild von einem unverschlüsselten AMI zu einem verschlüsselten Ziel. Weitere Informationen zur Angabe verschlüsselter Volumes finden Sie unter Amazon EBS-Verschlüsselung im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Als Quell-AMI für den Snapshot können Sie das Amazon-Linux-Basis-AMI verwenden. Sie können auch einen Snapshot von einem AMI kopieren, das vom angepassten Amazon-Linux-AMI abgeleitet wurde.

> **Note**
>
> Ab Amazon-EMR-Version 5.24.0 können Sie eine Sicherheitskonfigurationsoption zum Verschlüsseln von EBS-Root-Geräten und Speicher-Volumes verwenden, wenn Sie AWS KMS als Ihren Schlüsselanbieter angeben. Weitere Informationen finden Sie unter Verschlüsselung lokaler Datenträger.

Sie können einen externen Schlüsselanbieter oder einen AWS-KMS-Schlüssel verwenden, um das EBS-Root-Volume zu verschlüsseln. Die von Amazon EMR verwendete Servicerolle (normalerweise die Standard-`EMR_DefaultRole`) muss mindestens zum Verschlüsseln und Entschlüsseln des Volumes berechtigt sein, damit Amazon EMR einen Cluster mit dem AMI erstellen kann. Wenn Sie AWS KMS als Schlüsselanbieter verwenden, müssen die folgenden Aktionen erlaubt sein:

- `kms:encrypt`
- `kms:decrypt`
- `kms:ReEncrypt*`
- `kms:CreateGrant`

- kms:GenerateDataKeyWithoutPlaintext"
- kms:DescribeKey"

Hierfür fügen Sie am einfachsten die Rolle als Schlüsselbenutzer wie im folgenden Tutorial beschrieben hinzu. Die folgende Richtlinienanweisung dient als Beispiel für den Fall, dass Sie Rollenrichtlinien anpassen müssen.

```
{
"Version": "2012-10-17",
"Statement": [
   {
   "Sid": "EmrDiskEncryptionPolicy",
   "Effect": "Allow",
   "Action": [
      "kms:Encrypt",
      "kms:Decrypt",
      "kms:ReEncrypt*",
      "kms:CreateGrant",
      "kms:GenerateDataKeyWithoutPlaintext",
      "kms:DescribeKey"
      ],
   "Resource": [
      "*"
      ]
   }
]
}
```

Tutorial: Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Root-Gerät-Datenträger mithilfe eines KMS-Schlüssels

Im ersten Schritt dieses Beispiels muss der ARN eines KMS-Schlüssels ermittelt oder neu erstellt werden. Weitere Informationen zum Erstellen von -Schlüsseln finden Sie unter Erstellen von Schlüsseln im AWS Key Management Service-Entwicklerhandbuch. Im folgenden Verfahren wird gezeigt, wie Sie als Schlüsselbenutzer die Standard-Servicerolle `EMR_DefaultRole` zur Schlüsselrichtlinie hinzufügen. Notieren Sie sich den ARN-Wert für den Schlüssel, wenn Sie ihn erstellen oder bearbeiten. Sie verwenden den ARN später, wenn Sie das AMI erstellen.

So fügen Sie die Servicerolle für Amazon EC2 zur Liste der Benutzer von Verschlüsselungsschlüsseln mithilfe der Konsole hinzu

1. Melden Sie sich bei der AWS Management Console an und öffnen Sie die AWS Key Management Service (AWS KMS)-Konsole unter https://console.aws.amazon.com/kms.
2. Wenn Sie die AWS-Region ändern möchten, verwenden Sie die Regionsauswahl in der oberen rechten Ecke der Seite.
3. Wählen Sie den Alias des zu verwendenden KMS-Schlüssel aus.
4. Wählen Sie auf der Seite mit den Schlüsseldetails unter Key Users (Schlüsselbenutzer(die Option Add (Hinzufügen) aus.
5. Wählen Sie im Dialogfeld Anfügen die Amazon-EMR-Servicerolle aus. Der Name der Standardrolle lautet `EMR_DefaultRole`.
6. Wählen Sie Attach (Anfügen) aus.

So erstellen Sie ein verschlüsseltes AMI mit der AWS CLI

- Erstellen Sie mittels des Befehls `aws ec2 copy-image` aus der AWS CLI ein AMI mit einem verschlüsselten EBS-Root-Gerät-Datenträger -Volume und dem von Ihnen geänderten Schlüssel. Ersetzen Sie den angegebenen Wert `--kms-key-id` durch den vollständigen ARN des Schlüssels, den Sie zuvor erstellt oder geändert haben.

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws ec2 copy-image --source-image-id MyAmiId \
--source-region us-west-2 --name MyEncryptedEMRAmi \
--encrypted --kms-key-id arn:aws:kms:us-west-2:12345678910:key/xxxxxxxx-xxxx-xxxx-xxxx-xxxxxxxxxxxx
```

Die Ausgabe des Befehls enthält die ID des AMI, das Sie erstellt haben, welches Sie angeben können, wenn Sie einen Cluster erstellen. Weitere Informationen finden Sie unter Ein einzelnes

benutzerdefiniertes AMI in einem EMR-Cluster verwenden. Sie können dieses AMI auch anpassen, indem Sie Software installieren und andere Konfigurationen durchführen. Weitere Informationen finden Sie unter Erstellen eines benutzerdefinierten Amazon-Linux-AMI aus einer vorkonfigurierten Instance.

Bewährte Methoden und Überlegungen

Wenn Sie ein benutzerdefiniertes AMI für Amazon EMR erstellen, sollten Sie Folgendes bedenken:

- Amazon EMR 5.30.0 und höher sowie die Amazon-EMR-6.x-Serie basieren auf Amazon Linux 2. Für diese Amazon-EMR-Versionen müssen Sie Images auf Basis von Amazon Linux 2 für benutzerdefinierte AMIs verwenden. Informationen zum Suchen eines benutzerdefinierten Basis-AMI finden Sie unter Suchen eines Linux-AMI.
- Für Amazon-EMR-Versionen vor 5.30.0 und 6.x werden Amazon Linux 2 AMIs nicht unterstützt.
- Sie müssen ein 64-Bit-Amazon-Linux-AMI verwenden. Ein 32-Bit-AMI wird nicht unterstützt.
- Amazon-Linux-AMIs mit mehreren Amazon-EBS-Volumes werden nicht unterstützt.
- Legen Sie Ihrer Anpassung das neueste von EBS gestützte Amazon Linux AMI zugrunde. Die Liste der Amazon Linux AMIs und der zugehörigen AMI-IDs finden Sie unter Amazon Linux AMI.
- Kopieren Sie keinen Snapshot einer vorhandenen Amazon-EMR-Instance, um ein benutzerdefiniertes AMI zu erstellen. Das verursacht Fehler.
- Es werden nur die mit Amazon EMR kompatiblen HVM-Virtualisierungstypen und Instances unterstützt. Stellen Sie sicher, dass Sie während der AMI-Anpassung ein HVM-Abbild und einen Instance-Typ auswählen, das bzw. der mit Amazon EMR kompatibel ist. Kompatible Instances und Virtualisierungstypen finden Sie unter Unterstützte Instance-Typen.
- Die Servicerolle muss über Startberechtigungen für das AMI verfügen. Das AMI muss also entweder öffentlich sein, oder Sie müssen der Eigentümer des AMI sein, oder das AMI wurde vom Eigentümer für Sie freigegeben.
- Wenn Sie Benutzer im AMI erstellen, deren Namen mit Anwendungsnamen übereinstimmen (z. B. `hadoop`, `hdfs`, `yarn` oder `spark`), führt das zu Fehlern.
- Der Inhalt von `/tmp`, `/var` und `/emr` – sofern im AMI vorhanden – wird während des Startup entsprechend nach `/mnt/tmp`, `/mnt/var` und `/mnt/emr` verschoben. Dateien werden beibehalten; bei großen Mengen an Daten kann jedoch der Startup länger als erwartet dauern.
- Wenn Sie ein benutzerdefiniertes Amazon-Linux-AMI verwenden, das auf einem Amazon-Linux-AMI mit einem Erstellungsdatum vom 8.11.2018 basiert, kann der Oozie-Server nicht gestartet werden. Wenn Sie Oozie verwenden, erstellen Sie ein benutzerdefiniertes AMI, das auf einer

Amazon-Linux-AMI-ID mit einem anderen Erstellungsdatum basiert. Sie können den folgenden AWS CLI-Befehl verwenden, um eine Liste der Image-IDs für alle HVM-Amazon-Linux-AMIs mit einer Version 2018.03 zusammen mit dem Veröffentlichungsdatum zurückzugeben, sodass Sie ein geeignetes Amazon-Linux-AMI als Basis auswählen können. Ersetzen Sie MyRegion durch Ihre Region-ID, z. B. us-west-2.

```
aws ec2 --region MyRegion describe-images --owner amazon --query 'Images[?
Name!=`null`]|[?starts_with(Name, `amzn-ami-hvm-2018.03`) == `true`].
[CreationDate,ImageId,Name]' --output text | sort -rk1
```

- In Fällen, in denen Sie eine VPC mit einem nicht standardmäßigen Domainnamen und AmazonProvidedDNS verwenden, sollten Sie die `rotate`-Option in der DNS-Konfiguration des Betriebssystems nicht verwenden.

Weitere Informationen finden Sie unter Erstellen von Amazon EBS-backed AMIs im Amazon-EC2-Benutzerhandbuch für Linux Instances.

Änderung der Amazon-Linux-Version beim Erstellen eines Clusters

Wenn Sie einen Cluster mit Amazon EMR 6.6.0 oder höher starten, verwendet er automatisch die neueste Amazon-Linux-2-Version, die für das standardmäßige Amazon-EMR-AMI validiert wurde. Sie können eine andere Amazon Linux-Version für Ihren Cluster mit der Amazon-EMR-Konsole oder dem AWS CLI angeben.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Um die Amazon-Linux-Version zu ändern, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.

3. Wählen Sie für EMR-Version die Option emr-6.6.0 oder höher aus.
4. Wählen Sie unter Betriebssystemoptionen die Amazon-Linux-Version und aktivieren Sie das Kontrollkästchen Aktuelle Amazon-Linux-Updates automatisch anwenden.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Um die Amazon-Linux-Version zu ändern, wenn Sie einen Cluster mit der alten Konsole erstellen

1. Öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/elasticmapreduce.
2. Wählen Sie Cluster erstellen und Zu erweiterten Optionen aus.
3. Wählen Sie unter Softwarekonfiguration die Version emr-6.6.0 oder höher als Veröffentlichung und anschließend wie erforderlich weitere Optionen für Ihre Anwendung aus. Wählen Sie Next (Weiter).
4. Wählen Sie unter Hardware Configuration (Hardwarekonfiguration) für Ihre Anwendung geeignete Werte und anschließend Next (Weiter) aus.
5. Wählen Sie unter Zusätzliche Optionen die Amazon-Linux-Version und dann die Amazon-Linux-Release-Version für Ihren Cluster aus.
6. Wählen Sie zum Starten des Clusters Next (Weiter) aus und legen Sie weitere Konfigurationsoptionen fest.

AWS CLI

Um die Amazon-Linux-Version zu ändern, wenn Sie einen Cluster mit AWS CLI erstellen

- Verwenden Sie den `--os-release-label`-Parameter, um die Amazon-Linux-Version anzugeben, wenn Sie den Befehl `aws emr` create-cluster ausführen.

```
aws emr create-cluster --name "Cluster with Different Amazon Linux Release" \
--os-release-label 2.0.20210312.1 \
--release-label emr-6.6.0 --use-default-roles \
--instance-count 2 --instance-type m5.xlarge
```

Größenangabe des Amazon-EBS-Root-Gerät-Datenträgers

Diese Option ist nur mit Amazon-EMR-Versionen 4.x und höher verfügbar. Sie können beim Erstellen eines Clusters über die AWS Management Console, die AWS CLI oder die Amazon-EMR-API eine Volume-Größe zwischen 10 GiB (Standard) und 100 GB angeben. Diese Größeneinteilung gilt nur für EBS-Root-Gerät-Datenträger und wird auf alle Instances im Cluster angewendet. Sie gilt nicht für Speicher-Volumes, die Sie separat für jeden Instance-Typ beim Erstellen Ihres Clusters angeben.

Weitere Informationen zu Amazon EBS finden Sie unter Amazon-EC2-Root-Geräte-Volume.

> **Note**
>
> Wenn Sie das Standard-AMI verwenden, fügt Amazon EMR Allzweck-SSD (General Purpose SSD, gp2) als Root-Gerät-Datenträgertyp hinzu. Ein benutzerdefiniertes AMI kann einen anderen Root-Gerät-Datenträgertyp haben. Die Mindestgröße des Root-Volumes für ein benutzerdefiniertes AMI beträgt jedoch ebenfalls 10 GiB. Weitere Informationen finden Sie unter Verwenden eines benutzerdefinierten AMI.

Die Kosten des EBS-Root-Gerät-Datenträgers wird anteilig nach Stunde berechnet. Dies erfolgt auf der Grundlage der monatlichen EBS-Gebühren für den Volume-Typ in der Region, in der der Cluster ausgeführt wird. Gleiches gilt für Speicher-Volumes. Die Gebühren gelten für GB, aber da Sie die Größe des Root-Volumes in GiB angeben, sollten Sie dies bei Ihren Kostenschätzungen berücksichtigen (1 GB entspricht 0,931323 GiB). Verwenden Sie die folgende Formel, um die Kosten für EBS-Root-Gerät-Datenträger in Ihrem Cluster zu schätzen:

($EBS GB/Monat) * 0,931323 / 30 / 24 * EMR_EBSRootGiB * InstanceCount

Beispiel: Nehmen Sie einen Cluster mit einem Hauptknoten, einem Core-Knoten und einem -AMI mit einer Standardgröße des Root-Gerät-Datenträgers von 10 GiB. Wenn die EBS-Kosten in der Region 0,10 USD/GB pro Monat betragen, sind das ungefähr 0,00129 USD pro Instance pro Stunde 0,00258 USD pro Stunde für den Cluster (USD 0,10 GB-Monat dividiert durch 30 Tage, dividiert durch 24 Stunden, multipliziert mit 10 GB, multipliziert mit 2 Cluster-Instances).

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So geben Sie die Volumengröße des Amazon-EBS-Root-Geräts mit der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Gehen Sie unter Clusterkonfiguration zum Abschnitt Optionen für Clusterskalierung und -bereitstellung. Erweitern Sie den Pfeil für das EBS-Root-Volume und geben Sie einen Wert zwischen 10 GiB und 100 GiB ein.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So geben Sie die Volumengröße des Amazon-EBS-Root-Geräts mit der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Wählen Sie im Feld Softwarekonfiguration für Version Amazon-EMR-Version 4.x oder höher aus. Wählen Sie je nach Anwendung weitere Optionen aus und klicken Sie auf Weiter.
5. Geben Sie unter Hardware Configuration (Hardwarekonfiguration) in Root device EBS volume size (EBS-Volume-Größe des Root-Geräts) einen Wert zwischen 10 GiB und 100 GiB ein.

CLI

So geben Sie die Volumengröße des Amazon-EBS-Root-Geräts mit AWS CLI an

- Verwenden Sie den Parameter `--ebs-root-volume-size` des Befehls create-Cluster wie im folgenden Beispiel gezeigt.

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --release-label emr-5.7.0 \
--ebs-root-volume-size 20 --instance-groups InstanceGroupType=MASTER,\
InstanceCount=1,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=2,InstanceType=m5.xlarge
```

Konfigurieren der Cluster-Software

Wenn Sie ein Software-Release auswählen, verwendet Amazon EMR ein Amazon Machine Image (AMI) mit Amazon Linux zur Installation der Software, die Sie beim Starten Ihres Clusters ausgewählt haben (z. B. Hadoop, Spark und Hive). Amazon EMR bietet regelmäßig neue Versionen mit neuen Features, neuen Anwendungen und allgemeine Aktualisierungen. Wir empfehlen, dass Sie die neueste Version zum Starten Ihres Clusters verwenden (sofern möglich). Die neueste Version ist die Standardoption beim Starten eines Clusters über die Konsole.

Weitere Informationen zu Amazon-EMR-Versionen und den mit jeder Version verfügbaren Softwareversionen finden Sie im Amazon-EMR-Versionshandbuch. Weitere Informationen zum Bearbeiten der Standardkonfigurationen von auf Ihrem Cluster installierten Anwendungen und Software finden Sie unter Konfigurieren von Anwendungen im Amazon-EMR-Versionshandbuch. Einige Versionen der Open-Source-Komponenten von Hadoop und Spark in Amazon-EMR-Versionen nutzen Patches und Verbesserungen, die im Amazon-EMR-Versionshandbuch dokumentiert sind.

Zusätzlich zur standardmäßigen Software und den zur Installation auf Ihrem Cluster verfügbaren Anwendungen können Sie mit Bootstrap-Aktionen benutzerdefinierte Software installieren. Bootstrap-

Aktionen sind Skripts, die beim Start Ihres Clusters und beim Ausführen neue, bei der Erstellung des Clusters hinzugefügter Knoten in den Instances ausgeführt werden. Bootstrap-Aktionen sind auch nützlich, um AWS CLI -Befehle zum Kopieren von Objekten aus Amazon S3 zu den Knoten in Ihrem Cluster aufzurufen.

> **Note**
>
> Die Verwendung von Bootstrap-Aktionen unterscheidet sich in Amazon-EMR-Version 4.x und höher. Weitere Informationen zu diesen Unterschieden zu den Amazon-EMR-AMI-Versionen 2.x und 3.x finden Sie unter In 4.x eingeführte Unterschiede im Amazon-EMR-Versionshandbuch.

Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software

Sie können eine Bootstrap-Aktion verwenden, um zusätzliche Software zu installieren oder die Konfiguration von Cluster-Instances anzupassen. Bootstrap-Aktionen sind Skripts, die auf Clustern ausgeführt werden, nachdem Amazon EMR die Instance mithilfe von Amazon Machine Image (AMI) startet. Bootstrap-Aktionen werden ausgeführt, bevor Amazon EMR die Anwendungen installiert, die Sie bei der Erstellung des Clusters angeben haben und bevor die Cluster-Knoten mit der Bearbeitung der Daten beginnen. Wenn Sie einem aktiven Cluster Knoten hinzufügen, werden die Bootstrap-Aktionen auf diesen Knoten auch auf die gleiche Weise ausgeführt. Sie können benutzerdefinierte Bootstrap-Aktionen erstellen und sie beim Erstellen Ihres Clusters angeben.

Die meisten vordefinierten Bootstrap-Aktionen für die Amazon-EMR-AMI-Versionen 2.x und 3.x werden in den Versionen 4.x von Amazon EMR nicht unterstützt. Beispielsweise werden `configure-Hadoop` und `configure-daemons` in Amazon-EMR-Version 4.x nicht unterstützt. Stattdessen stellt Amazon-EMR-Version 4.x diese Funktionalität nativ bereit. Weitere Informationen zur Migration von Bootstrap-Aktionen von den Amazon-EMR-AMI-Versionen 2.x und 3.x auf Amazon-EMR-Version 4.x finden Sie unter Anpassen der Cluster- und Anwendungskonfiguration mit früheren AMI-Versionen von Amazon EMR im Amazon-EMR-Versionshandbuch.

Bootstrap-Aktionen – Grundlagen

Bootstrap-Aktionen werden standardmäßig als Hadoop-Benutzer ausgeführt. Sie können eine Bootstrap-Aktion mit Root-Berechtigungen ausführen, indem Sie `sudo` verwenden.

Alle Amazon-EMR-Verwaltungsschnittstellen unterstützen Bootstrap-Aktionen. Sie können bis zu 16 Bootstrap-Aktionen pro Cluster angeben, indem Sie mehrere `bootstrap-actions`-Parameter über die Konsole, die AWS CLI oder die API bereitstellen.

Von der Amazon-EMR-Konsole können Sie optional eine Bootstrap-Aktion beim Erstellen eines Clusters angeben.

Wenn Sie die CLI verwenden, können Sie Verweise auf Bootstrap-Aktionsskripts an Amazon EMR übergeben, indem Sie beim Erstellen des Clusters den Parameter `--bootstrap-actions` mit dem Befehl `create-cluster` hinzufügen.

```
--bootstrap-actions Path="s3://mybucket/filename",Args=[arg1,arg2]
```

Wenn die Bootstrap-Aktion einen Fehlercode ungleich null zurückgibt, wird dieser von Amazon EMR wie ein Fehler behandelt und die Instance wird beendet. Wenn zu viele Instances bei ihren Bootstrap-Aktionen fehlschlagen, beendet Amazon EMR den Cluster. Wenn nur wenige Instances ausfallen, versucht Amazon EMR, die ausgefallenen Instances neu zuzuordnen und fortzufahren. Verwenden Sie den Cluster-Fehlercode `lastStateChangeReason`, um Fehler zu identifizieren, die durch eine Bootstrap-Aktion verursacht wurden.

Eine bedingte eine Bootstrap-Aktion ausführen

Um Bootstrap-Aktionen nur auf dem Hauptknoten auszuführen, können Sie eine benutzerdefinierte Bootstrap-Aktion mit etwas Logik verwenden, um festzustellen, ob es sich bei dem Knoten um einen Hauptknoten handelt.

```
#!/bin/bash
if grep isMaster /mnt/var/lib/info/instance.json | grep false;
then
    echo "This is not master node, do nothing,exiting"
    exit 0
fi
echo "This is master, continuing to execute script"
# continue with code logic for master node below
```

Die folgende Ausgabe wird von einem Core-Knoten aus gedruckt.

```
This is not master node, do nothing, exiting
```

Die folgende Ausgabe wird vom Hauptknoten aus gedruckt.

```
This is master, continuing to execute script
```

Um diese Logik zu verwenden, laden Sie Ihre Bootstrap-Aktion, einschließlich des obigen Codes, in Ihren Amazon-S3-Bucket hoch. Fügen Sie am AWS CLI den Parameter `--bootstrap-actions` zum `aws emr create-cluster`-API-Aufruf hinzu und geben Sie den Speicherort Ihres Bootstrap-Skripts als Wert von `Path` an.

Aktionen beim Herunterfahren

Ein Bootstrap-Aktionsskript kann eine oder mehrere Shutdown-Aktionen durchführen, indem es Skripts in das Verzeichnis `/mnt/var/lib/instance-controller/public/shutdown-actions/` schreibt. Wenn ein Cluster beendet wird, werden alle Skripts in diesem Verzeichnis parallel ausgeführt. Jedes Skript muss innerhalb von 60 Sekunden ausgeführt und abgeschlossen werden.

Es wird nicht garantiert, dass Shutdown-Aktionsskripts ausgeführt werden, wenn der Knoten mit einem Fehler beendet wird.

> **Note**
>
> Bei Verwendung der Amazon-EMR-Version 4.0 und höher müssen Sie das Verzeichnis `/mnt/var/lib/instance-controller/public/shutdown-actions/` auf dem Hauptknoten manuell erstellen. Es ist standardmäßig zwar nicht vorhanden, nach Erstellung werden die Skripts in diesem Verzeichnis aber trotzdem vor dem Herunterfahren ausgeführt. Weitere Informationen zum Herstellen einer Verbindung mit dem Master-Knoten zum Erstellen von Verzeichnissen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Benutzerdefinierte Bootstrap-Aktionen verwenden

Sie können ein benutzerdefiniertes Skript erstellen, um eine angepasste Bootstrap-Aktion auszuführen. Alle Amazon-EMR-Schnittstellen können auf eine benutzerdefinierte Bootstrap-Aktion verweisen.

> **Note**
>
> Für eine optimale Leistung empfehlen wir, benutzerdefinierte Bootstrap-Aktionen, -Skripts und andere Dateien, die Sie mit Amazon EMR verwenden möchten, in einem Amazon-S3-Bucket zu speichern, der sich in derselben AWS-Region wie Ihr Cluster befindet.

Inhalt

- Benutzerdefinierte Bootstrap-Aktionen hinzufügen
- Verwenden einer benutzerdefinierten Bootstrap-Aktion zum Kopieren eines Objekts aus Amazon S3 in jeden Knoten

Benutzerdefinierte Bootstrap-Aktionen hinzufügen

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So erstellen Sie einen Cluster mit einer Bootstrap-Aktion über die neue Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Bootstrap-Aktionen die Option Hinzufügen aus, um einen Namen, einen Skriptspeicherort und optionale Argumente für Ihre Aktion anzugeben. Wählen Sie Bootstrap-Aktion hinzufügen aus.
4. Fügen Sie optional weitere Bootstrap-Aktionen hinzu.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So erstellen Sie einen Cluster mit einer benutzerdefinierten Bootstrap-Aktion über die alte Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Klicken Sie auf Go to advanced options (Zu erweiterten Optionen navigieren).
4. Wählen Sie unter „Create Cluster – Advanced Options, Steps 1 and 2 (Cluster erstellen – Erweiterte Optionen, Schritte 1 und 2)“ die gewünschten Optionen aus und fahren Sie mit Step 3: General Cluster Settings (Schritt 3: Allgemeine Cluster-Einstellungen) fort.
5. Wählen Sie unter Bootstrap Actions (Bootstrap-Aktionen) die Option Configure and add (Konfigurieren und hinzufügen) aus, um den Namen, den JAR-Speicherort und die Argumente für Ihre Bootstrap-Aktion anzugeben. Wählen Sie Add (Hinzufügen) aus.
6. Fügen Sie optional weitere Bootstrap-Aktionen hinzu.
7. Fahren Sie mit der Erstellung des Clusters fort. Ihre Bootstrap-Aktionen werden ausgeführt, nachdem der Cluster bereitgestellt und initialisiert wurde.

   Während der Primärknoten des Clusters ausgeführt wird, können Sie eine Verbindung mit dem Primärknoten herstellen und die Protokolldateien anzeigen, die vom Bootstrap-Aktionsskript im Verzeichnis `/mnt/var/log/bootstrap-actions/1` generiert wurden.

CLI

So erstellen Sie einen Cluster mit einer benutzerdefinierten Bootstrap-Aktion über die AWS CLI

Wenn Sie eine Bootstrap-Aktion über die AWS CLI hinzufügen, geben Sie `Path` und `Args` als eine durch Komma getrennte Liste an. Bei dem folgenden Beispiel wird keine Argumentliste verwendet.

- Um einen Cluster mit einer benutzerdefinierten Bootstrap-Aktion zu starten, geben Sie den folgenden Befehl ein und ersetzen *`myKey`* durch den Namen Ihres EC2-Schlüsselpaares. Fügen Sie `--bootstrap-actions` als Parameter ein und geben Sie den Speicherort Ihres Bootstrap-Skripts als Wert von `Path` an.

  - Linux-, UNIX- und Mac OS X-Benutzer:

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.0.0 \
--use-default-roles --ec2-attributes KeyName=myKey \
--applications Name=Hive Name=Pig \
--instance-count 3 --instance-type m5.xlarge \
--bootstrap-actions Path="s3://elasticmapreduce/bootstrap-actions/download.sh"
```

- Windows-Nutzer:

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.2.0 --use-
default-roles --ec2-attributes KeyName=myKey --applications Name=Hive Name=Pig
 --instance-count 3 --instance-type m5.xlarge --bootstrap-actions Path="s3://
elasticmapreduce/bootstrap-actions/download.sh"
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige Amazon-EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie `aws emr create-default-roles` ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Verwenden einer benutzerdefinierten Bootstrap-Aktion zum Kopieren eines Objekts aus Amazon S3 in jeden Knoten

Sie können mit einer Bootstrap-Aktion Objekte von Amazon S3 in jeden Knoten eines Cluster kopieren, bevor Ihre Anwendungen installiert werden. Die AWS CLI wird auf jedem Knoten eines Clusters installiert, sodass Ihre Bootstrap-Aktion AWS CLI-Befehle aufrufen kann.

Das folgende Beispiel zeigt ein einfaches Skript für eine Bootstrap-Aktion, die die Datei `myfile.jar` aus Amazon S3 zum lokalen Ordner `/mnt1/myfolder` auf jedem Cluster-Knoten kopiert. Das Skript wird mit dem Dateinamen `copymyfile.sh` in Amazon S3 mit den folgenden Inhalten gespeichert.

```
#!/bin/bash
aws s3 cp s3://mybucket/myfilefolder/myfile.jar /mnt1/myfolder
```

Wenn Sie den Cluster starten, geben Sie das Skript an. Das folgende AWS CLI-Beispiel veranschaulicht dies:

```
aws emr create-cluster --name "Test cluster" --release-label emr-5.36.1 \
--use-default-roles --ec2-attributes KeyName=myKey \
--applications Name=Hive Name=Pig \
--instance-count 3 --instance-type m5.xlarge \
--bootstrap-actions Path="s3://mybucket/myscriptfolder/copymyfile.sh"
```

Cluster-Hardware und Netzwerken konfigurieren

Eine wichtige Überlegung beim Erstellen eines Amazon-EMR-Clusters ist die Art und Weise, wie Sie Amazon-EC2-Instances und Netzwerkoptionen konfigurieren. Dieses Kapitel behandelt diese Optionen im Detail und beschreibt entsprechende bewährte Methoden und Richtlinien.

- Knotentypen – Amazon-EC2-Instances in einem EMR-Cluster sind in Knotentypen organisiert. Es gibt drei Knotentypen: Primärknoten, Core-Knoten und Aufgabenknoten. Jeder Knotentyp führt eine Reihe von Rollen aus, die durch die von Ihnen auf dem Cluster installierten verteilten Anwendungen definiert werden. Bei einem Hadoop MapReduce- oder Spark-Auftrag z. B. verarbeiten Komponenten auf Core- und Aufgabenknoten die Daten, übertragen die Ausgabe an Amazon S3 oder HDFS und melden Statusmetadaten zurück an den Primärknoten. Bei einem einzigen Knoten-Cluster werden alle Komponenten auf dem Primärknoten ausgeführt. Weitere Informationen finden Sie unter De Knotentypen verstehen: Primär-, Core- und Aufgabenknoten.
- EC2-Instances – Wenn Sie einen Cluster erstellen, treffen Sie Entscheidungen über die Amazon-EC2-Instances, auf denen jeder Knotentyp ausgeführt werden soll. Der EC2-Instance-Typ bestimmt das Verarbeitungs- und Speicherprofil des Knotens. Die Wahl der Amazon-EC2-Instance für Ihre Knoten ist wichtig, da sie das Leistungsprofil der einzelnen Knotentypen in Ihrem Cluster bestimmt. Weitere Informationen finden Sie unter Amazon-EC2-Instances konfigurieren.
- Netzwerk – Sie können Ihren Amazon-EMR-Cluster in einer VPC starten, indem Sie ein öffentliches Subnetz, ein privates Subnetz oder ein gemeinsam genutztes Subnetz verwenden. Ihre Netzwerkkonfiguration bestimmt, wie Kunden und Services Verbindungen zu Clustern herstellen können, um ihre Arbeit zu erledigen, wie Cluster mit Datenspeichern und anderen AWS-Ressourcen verbunden werden und welche Optionen Sie zur Steuerung des Datenverkehrs auf diesen Verbindungen haben. Weitere Informationen finden Sie unter Netzwerk konfigurieren.

- Instance-Gruppierung – Die Sammlung von EC2-Instances, die jeden Knotentyp hosten, wird entweder als Instance-Flotte oder als einheitliche Instance-Gruppe bezeichnet. Die Konfiguration der Instance-Gruppierung ist eine Auswahl, die Sie beim Erstellen eines Clusters treffen. Diese Auswahl bestimmt, wie Sie Ihrem Cluster Knoten hinzufügen können, während er läuft. Die Konfiguration gilt für alle Knotentypen. Er kann später nicht mehr geändert werden. Weitere Informationen finden Sie unter Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen.

  > **Note**
  >
  > Die Konfiguration der Instance-Flotten ist nur in den Amazon-EMR-Versionen 4.8.0 und höher verfügbar, mit Ausnahme von 5.0.0 und 5.0.3.

De Knotentypen verstehen: Primär-, Core- und Aufgabenknoten

In diesem Abschnitt erfahren Sie, wie Amazon EMR die einzelnen Knotentypen jeweils verwendet. Damit lernen Sie die Grundsätze der Kapazitätsplanung für Cluster kennen.

Primärknoten

Der Primärknoten verwaltet die Cluster und führt die Master-Komponenten von verteilten Anwendungen aus. Der Primärknoten führt beispielsweise den YARN ResourceManager-Service für die Verwaltung von Ressourcen für Anwendungen sowie den HDFS-NameNode-Service aus. Darüber hinaus verfolgt der Primärknoten den Status der an den Cluster übermittelten Aufgaben und überwacht den Zustand der Instance-Gruppen.

Um den Fortschritt eines Clusters zu überwachen und direkt mit Anwendungen zu interagieren, können Sie über SSH eine Verbindung mit dem Primärknoten als Hadoop-Benutzer herstellen. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden. Durch das Verbinden mit dem Primärknoten erhalten Sie direkten Zugriff auf Verzeichnisse und Dateien, wie z. B. Hadoop-Protokolldateien. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien. Sie können auch Benutzeroberflächen anzeigen, die von den Anwendungen als auf dem Primärknoten ausgeführte Websites veröffentlicht werden. Weitere Informationen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

> **Note**
>
> Ab Amazon EMR 5.23.0 können Sie einen Cluster mit drei Primärknoten starten, um die Hochverfügbarkeit von Anwendungen wie YARN Resource Manager, HDFS Name Node, Spark, Hive und Ganglia zu unterstützen. Der Primärknoten ist mit diesem Feature keine potenzielle einzelne Fehlerquelle mehr. Wenn ein Primärknoten ausfällt, führt Amazon EMR automatisch einen Failover zu einem Standby-Primärknoten aus und ersetzt den ausgefallenen Primärknoten durch einen neuen Primärknoten mit der gleichen Konfiguration und den gleichen Bootstrap-Aktionen. Weitere Informationen finden Sie unter Primärknoten planen und konfigurieren.

Core-Knoten

Core-Knoten werden vom Primärknoten verwaltet. Core-Knoten führen den DataNode-Daemon zum Koordinieren der Datenspeicherung im Rahmen des Hadoop Distributed File System (HDFS) aus. Außerdem führen sie den TaskTracker-Daemon und andere parallele Rechenaufgaben für Daten aus, die für installierte Anwendungen erforderlich sind. Ein Core-Knoten führt beispielsweise YARN NodeManager-Daemons, Hadoop MapReduce-Aufgaben und Spark Executor aus.

Es gibt nur eine Core-Instance-Gruppe oder Instance-Flotte pro Cluster, aber es können mehrere Knoten auf mehreren Amazon-EC2-Instances in der Instance-Gruppe oder Instance-Flotte laufen. Mit Instance-Gruppen können Sie Amazon-EC2-Instances hinzufügen und entfernen, während der Cluster ausgeführt wird. Sie können auch ein Auto Scaling einrichten, um Instances auf der Grundlage des Werts einer Metrik hinzuzufügen. Weitere Informationen zum Hinzufügen und Entfernen von Amazon-EC2 Instances mit der Instance-Gruppenkonfiguration finden Sie unter Clusterskalierung verwenden.

Mit Instance-Flotten können Sie Instances effektiv hinzufügen und entfernen, indem Sie die Zielkapazitäten der Instance-Flotte für On-Demand- und Spot Instances entsprechend anpassen. Weitere Informationen zu den Zielkapazitäten finden Sie unter Instance-Flotten-Optionen.

> **Warning**
>
> Das Entfernen von HDFS-Daemons aus einem Core-Knoten, der ausgeführt wird, oder das Beenden von Core-Knoten können zu Datenverlusten führen. Seien Sie beim Konfigurieren von Core-Knoten für die Verwendung von Spot Instances vorsichtig. Weitere Informationen finden Sie unter Wann sollten Sie Spot Instances verwenden?.

Aufgabenknoten

Sie können Aufgabenknoten verwenden, um die Leistung für parallele Rechenaufgaben für Daten zu erhöhen, wie z. B. Hadoop-MapReduce-Aufgaben und Spark Executor. Aufgabenknoten führen weder den DataNode-Daemon aus noch speichern sie Daten in HDFS. Wie Core-Knoten können Sie auch Aufgabenknoten zu einem Cluster hinzufügen, indem Sie Amazon-EC2-Instances in eine vorhandene einheitliche Instance-Gruppe integrieren oder die Zielkapazitäten für eine Aufgaben-Instance-Flotte ändern.

Mit der einheitlichen Instance-Gruppenkonfiguration können Sie über bis zu 48 Aufgaben-Instance-Gruppen verfügen. Die Möglichkeit, Instance-Gruppen so hinzuzufügen, ermöglicht Ihnen, Amazon-EC2-Instance-Typen und Preisoptionen, wie On-Demand-Instances und Spot Instances, zu kombinieren. Dadurch haben Sie die Flexibilität, kosteneffizient auf Workload-Anforderungen zu reagieren.

Mit der Instance-Flottenkonfiguration ist die Möglichkeit integriert, Instance-Typen und Kaufoptionen zu kombinieren, sodass nur eine Aufgaben-Instance-Flotte vorhanden ist.

Da Spot Instances häufig zum Ausführen von Aufgabenknoten verwendet werden, verfügt Amazon EMR über Standardfunktionen für die Planung von YARN-Aufträge, sodass laufende Aufträge nicht fehlschlagen, wenn Aufgabenknoten, die auf Spot Instances ausgeführt werden, beendet werden. Amazon EMR ermöglicht dies, indem Anwendungsmasterprozesse nur auf Core-Knoten ausgeführt werden können. Der Anwendungsmasterprozess steuert die Ausführung von Aufträgen und muss während der gesamten Laufzeit des Auftrags aktiv bleiben.

Amazon-EMR-Version 5.19.0 und höher verwendet zu diesem Zweck das integrierte YARN-Knotenbeschriftungsfeature. (Frühere Versionen verwendeten einen Code-Patch). Die Eigenschaften in den Klassifizierungen `yarn-site` und in der `capacity-scheduler`-Konfiguration sind standardmäßig so konfiguriert, dass der YARN-Kapazitätsplaner und der Fair-Scheduler die Vorteile von Knotenbezeichnungen nutzen. Amazon EMR kennzeichnet Core-Knoten automatisch mit dem `CORE`-Label und legt Eigenschaften fest, sodass Anwendungsmaster nur für Knoten mit dem CORE-Label geplant werden. Durch manuelles Ändern verwandter Eigenschaften in den Konfigurationsklassifizierungen von Yarn-Site und Kapazitätsplaner oder direkt in den zugehörigen XML-Dateien könnte diese Feature beeinträchtigt oder verändert werden.

Beginnend mit der Amazon-EMR-6.x-Release-Reihe ist das Feature YARN-Knotenbeschriftungen standardmäßig deaktiviert. Die Anwendungs-Primär-Prozesse können standardmäßig sowohl auf Core- als auch auf Aufgabenknoten ausgeführt werden. Sie können die Funktion für YARN-Knotenbeschriftungen aktivieren, indem Sie folgende Eigenschaften konfigurieren:

- `yarn.node-labels.enabled: true`
- `yarn.node-labels.am.default-node-label-expression: 'CORE'`

Informationen zu spezifischen Eigenschaften finden Sie unter Amazon-EMR-Einstellungen, die Aufgabenfehler aufgrund des Beendens von Aufgabenknoten-Spot Instances verhindern.

Amazon-EC2-Instances konfigurieren

EC2 Instances haben verschiedene Konfigurationen, die als Instance-Typen bezeichnet werden. Instance-Typen verfügen über andere CPU-, Eingabe/Ausgabe- und Speicherkapazitäten. Zusätzlich zum Instance-Typ können Sie verschiedene Kaufoptionen für Amazon-EC2-Instances auswählen. Sie können verschiedene Instance-Typen und Kaufoptionen innerhalb von einheitlichen Instance-Gruppen oder Instance-Flotten angeben. Weitere Informationen finden Sie unter Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen. Hinweise zur Auswahl von Instance-Typen und Kaufoptionen für Ihre Anwendung finden Sie unter Bewährte Methoden für die Konfiguration des Clusters.

> **Important**
>
> Wenn Sie mithilfe von einen Instance-Typ mit AWS Management Console auswählen, entspricht die Anzahl der für jeden Instance-Typ angezeigten vCPUs der Anzahl der YARN-vcores für diesen Instance-Typ, nicht der Anzahl der EC2-vCPUs für diesen Instance-Typ. Weitere Informationen zur Anzahl der vCPUs für jeden Instance-Typ finden Sie unter Amazon-EC2-Instance-Typen.

Themen

- Unterstützte Instance-Typen
- Netzwerk konfigurieren
- Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen

Unterstützte Instance-Typen

In diesem Abschnitt werden die Instance-Typen beschrieben, die Amazon EMR unterstützt, geordnet nach AWS-Region. Weitere Informationen zu Instance-Typen finden Sie unter Amazon-EC2-Instances und Amazon-Linux-AMI-Instance-Typmatrix.

Nicht alle Instance-Typen sind in allen Regionen verfügbar. Die Instance-Verfügbarkeit hängt von der Verfügbarkeit und der Nachfrage in der angegebenen Region und Availability Zone ab. Die Availability Zone einer Instance wird durch das Subnetz bestimmt, das Sie zum Starten Ihres Clusters verwenden.

Überlegungen

Berücksichtigen Sie Folgendes, wenn Sie Instance-Typen für Ihren Amazon-EMR-Cluster auswählen.

> **Important**
>
> Wenn Sie mithilfe von einen Instance-Typ mit AWS Management Console auswählen, entspricht die Anzahl der für jeden Instance-Typ angezeigten vCPUs der Anzahl der YARN-vcores für diesen Instance-Typ, nicht der Anzahl der EC2-vCPUs für diesen Instance-Typ. Weitere Informationen zur Anzahl der vCPUs für jeden Instance-Typ finden Sie unter Amazon-EC2-Instance-Typen.

- Wenn Sie einen Cluster mit einem Instance-Typ erstellen, der in der angegebenen Region und Verfügbarkeitszone nicht verfügbar ist, schlägt die Bereitstellung Ihres Clusters möglicherweise fehl oder die Bereitstellung bleibt hängen. Informationen zur Instance-Verfügbarkeit finden Sie auf der Amazon-EMR-Preisseite oder in den Unterstützte Instance-Typen von AWS-Region-Tabellen auf dieser Seite.
- Ab Amazon-EMR-Version 5.13.0 verwenden alle Instances HVM-Virtualisierung und EBS-gestützten Speicher für Stamm-Volumes. Bei der Verwendung von Amazon-EMR-Versionen vor Version 5.13.0 nutzen einige Instances der vorherigen Generation PVM-Virtualisierung. Weitere Informationen finden Sie unter Linux AMI-Virtualisierungstypen.
- Einige Instance-Typen unterstützen Enhanced Networking. Weitere Informationen finden Sie unter Enhanced Networking in Linux.
- NVIDIA- und CUDA-Treiber sind auf GPU-Instance-Typen standardmäßig installiert.

Unterstützte Instance-Typen von AWS-Region

In den folgenden Tabellen werden die von Amazon EMR unterstützten Instance-Typen beschrieben, sortiert nach AWS-Region. In den Tabellen sind auch die frühesten Amazon-EMR-Versionen der Serien 4.x, 5.x oder 6.x aufgeführt, die die einzelnen Instance-Typen unterstützen. EMR unterstützt beispielsweise m4.16xlarge-Instances in USA Ost (Nord-Virginia) in den Versionen 4.8.3 und höher, 5.2.1 und höher und 6.0.0 und höher.

USA Ost (Nord-Virginia) – us-east-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
	m7gd.xlarge	emr-5.36.1, emr-6.10.0
	m7gd.2xlarge	emr-5.36.1, emr-6.10.0
	m7gd.4xlarge	emr-5.36.1, emr-6.10.0
	m7gd.8xlarge	emr-5.36.1, emr-6.10.0
	m7gd.12xlarge	emr-5.36.1, emr-6.10.0
	m7gd.16xlarge	emr-5.36.1, emr-6.10.0
	m7i.xlarge	emr-5.36.1, emr-6.10.0
	m7i.2xlarge	emr-5.36.1, emr-6.10.0
	m7i.4xlarge	emr-5.36.1, emr-6.10.0
	m7i.8xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.2xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
	c7gd.xlarge	emr-5.36.1, emr-6.10.0
	c7gd.2xlarge	emr-5.36.1, emr-6.10.0
	c7gd.4xlarge	emr-5.36.1, emr-6.10.0
	c7gd.8xlarge	emr-5.36.1, emr-6.10.0
	c7gd.12xlarge	emr-5.36.1, emr-6.10.0
	c7gd.16xlarge	emr-5.36.1, emr-6.10.0
	c7gn.xlarge	emr-5.36.1, emr-6.10.0
	c7gn.2xlarge	emr-5.36.1, emr-6.10.0
	c7gn.4xlarge	emr-5.36.1, emr-6.10.0
	c7gn.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c7gn.12xlarge	emr-5.36.1, emr-6.10.0
	c7gn.16xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
	p5.48xlarge	emr-6.14.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6a.xlarge	emr-5.36.1, emr-6.8.0
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	r7gd.xlarge	emr-5.36.1, emr-6.10.0
	r7gd.2xlarge	emr-5.36.1, emr-6.10.0
	r7gd.4xlarge	emr-5.36.1, emr-6.10.0
	r7gd.8xlarge	emr-5.36.1, emr-6.10.0
	r7gd.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r7gd.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2gd.xlarge	emr-5.36.1, emr-6.10.0
	x2gd.2xlarge	emr-5.36.1, emr-6.10.0
	x2gd.4xlarge	emr-5.36.1, emr-6.10.0
	x2gd.8xlarge	emr-5.36.1, emr-6.10.0
	x2gd.12xlarge	emr-5.36.1, emr-6.10.0
	x2gd.16xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.12xlarge	emr-5.33.0, emr-6.3.0
	h1.2xlarge	emr-5.17.0, emr-6.0.0
	h1.4xlarge	emr-5.17.0, emr-6.0.0
	h1.8xlarge	emr-5.17.0, emr-6.0.0
	h1.16xlarge	emr-5.17.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4g.xlarge	emr-5.36.1, emr-6.10.0
	i4g.2xlarge	emr-5.36.1, emr-6.10.0
	i4g.4xlarge	emr-5.36.1, emr-6.10.0
	i4g.8xlarge	emr-5.36.1, emr-6.10.0
	i4g.16xlarge	emr-5.36.1, emr-6.10.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

USA Ost (Ohio) – us-east-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
	m7gd.xlarge	emr-5.36.1, emr-6.10.0
	m7gd.2xlarge	emr-5.36.1, emr-6.10.0
	m7gd.4xlarge	emr-5.36.1, emr-6.10.0
	m7gd.8xlarge	emr-5.36.1, emr-6.10.0
	m7gd.12xlarge	emr-5.36.1, emr-6.10.0
	m7gd.16xlarge	emr-5.36.1, emr-6.10.0
	m7i.xlarge	emr-5.36.1, emr-6.10.0
	m7i.2xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7i.4xlarge	emr-5.36.1, emr-6.10.0
	m7i.8xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.2xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.4xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
	c7gd.xlarge	emr-5.36.1, emr-6.10.0
	c7gd.2xlarge	emr-5.36.1, emr-6.10.0
	c7gd.4xlarge	emr-5.36.1, emr-6.10.0
	c7gd.8xlarge	emr-5.36.1, emr-6.10.0
	c7gd.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c7gd.16xlarge	emr-5.36.1, emr-6.10.0
	c7gn.xlarge	emr-5.36.1, emr-6.10.0
	c7gn.2xlarge	emr-5.36.1, emr-6.10.0
	c7gn.4xlarge	emr-5.36.1, emr-6.10.0
	c7gn.8xlarge	emr-5.36.1, emr-6.10.0
	c7gn.12xlarge	emr-5.36.1, emr-6.10.0
	c7gn.16xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6a.xlarge	emr-5.36.1, emr-6.8.0
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	r7gd.xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r7gd.2xlarge	emr-5.36.1, emr-6.10.0
	r7gd.4xlarge	emr-5.36.1, emr-6.10.0
	r7gd.8xlarge	emr-5.36.1, emr-6.10.0
	r7gd.12xlarge	emr-5.36.1, emr-6.10.0
	r7gd.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2gd.xlarge	emr-5.36.1, emr-6.10.0
	x2gd.2xlarge	emr-5.36.1, emr-6.10.0
	x2gd.4xlarge	emr-5.36.1, emr-6.10.0
	x2gd.8xlarge	emr-5.36.1, emr-6.10.0
	x2gd.12xlarge	emr-5.36.1, emr-6.10.0
	x2gd.16xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.6.0, emr-5.0.3, emr-6.0.0
	d2.2xlarge	emr-4.6.0, emr-5.0.3, emr-6.0.0
	d2.4xlarge	emr-4.6.0, emr-5.0.3, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d2.8xlarge	emr-4.6.0, emr-5.0.3, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	h1.2xlarge	emr-5.17.0, emr-6.0.0
	h1.4xlarge	emr-5.17.0, emr-6.0.0
	h1.8xlarge	emr-5.17.0, emr-6.0.0
	h1.16xlarge	emr-5.17.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4g.xlarge	emr-5.36.1, emr-6.10.0
	i4g.2xlarge	emr-5.36.1, emr-6.10.0
	i4g.4xlarge	emr-5.36.1, emr-6.10.0
	i4g.8xlarge	emr-5.36.1, emr-6.10.0
	i4g.16xlarge	emr-5.36.1, emr-6.10.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

USA West (Nordkalifornien) – us-west-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

USA West (Oregon) – us-west-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
	m7gd.xlarge	emr-5.36.1, emr-6.10.0
	m7gd.2xlarge	emr-5.36.1, emr-6.10.0
	m7gd.4xlarge	emr-5.36.1, emr-6.10.0
	m7gd.8xlarge	emr-5.36.1, emr-6.10.0
	m7gd.12xlarge	emr-5.36.1, emr-6.10.0
	m7gd.16xlarge	emr-5.36.1, emr-6.10.0
	m7i.xlarge	emr-5.36.1, emr-6.10.0
	m7i.2xlarge	emr-5.36.1, emr-6.10.0
	m7i.4xlarge	emr-5.36.1, emr-6.10.0
	m7i.8xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.2xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.4xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
	c7gd.xlarge	emr-5.36.1, emr-6.10.0
	c7gd.2xlarge	emr-5.36.1, emr-6.10.0
	c7gd.4xlarge	emr-5.36.1, emr-6.10.0
	c7gd.8xlarge	emr-5.36.1, emr-6.10.0
	c7gd.12xlarge	emr-5.36.1, emr-6.10.0
	c7gd.16xlarge	emr-5.36.1, emr-6.10.0
	c7gn.xlarge	emr-5.36.1, emr-6.10.0
	c7gn.2xlarge	emr-5.36.1, emr-6.10.0
	c7gn.4xlarge	emr-5.36.1, emr-6.10.0
	c7gn.8xlarge	emr-5.36.1, emr-6.10.0
	c7gn.12xlarge	emr-5.36.1, emr-6.10.0
	c7gn.16xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	p5.48xlarge	emr-6.14.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6a.xlarge	emr-5.36.1, emr-6.8.0
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	r7gd.xlarge	emr-5.36.1, emr-6.10.0
	r7gd.2xlarge	emr-5.36.1, emr-6.10.0
	r7gd.4xlarge	emr-5.36.1, emr-6.10.0
	r7gd.8xlarge	emr-5.36.1, emr-6.10.0
	r7gd.12xlarge	emr-5.36.1, emr-6.10.0
	r7gd.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2gd.xlarge	emr-5.36.1, emr-6.10.0
	x2gd.2xlarge	emr-5.36.1, emr-6.10.0
	x2gd.4xlarge	emr-5.36.1, emr-6.10.0
	x2gd.8xlarge	emr-5.36.1, emr-6.10.0
	x2gd.12xlarge	emr-5.36.1, emr-6.10.0
	x2gd.16xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d3en.12xlarge	emr-5.33.0, emr-6.3.0
	h1.2xlarge	emr-5.17.0, emr-6.0.0
	h1.4xlarge	emr-5.17.0, emr-6.0.0
	h1.8xlarge	emr-5.17.0, emr-6.0.0
	h1.16xlarge	emr-5.17.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4g.xlarge	emr-5.36.1, emr-6.10.0
	i4g.2xlarge	emr-5.36.1, emr-6.10.0
	i4g.4xlarge	emr-5.36.1, emr-6.10.0
	i4g.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4g.16xlarge	emr-5.36.1, emr-6.10.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

AWS GovCloud (USA-West) – us-gov-west-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

AWS GovCloud (USA-Ost) – us-gov-east-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.16.0, emr-6.0.0
	m5.2xlarge	emr-5.16.0, emr-6.0.0
	m5.4xlarge	emr-5.16.0, emr-6.0.0
	m5.8xlarge	emr-5.16.0, emr-6.0.0
	m5.12xlarge	emr-5.16.0, emr-6.0.0
	m5.16xlarge	emr-5.16.0, emr-6.0.0
	m5.24xlarge	emr-5.16.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.16.0, emr-6.0.0
	m5d.2xlarge	emr-5.16.0, emr-6.0.0
	m5d.4xlarge	emr-5.16.0, emr-6.0.0
	m5d.8xlarge	emr-5.16.0, emr-6.0.0
	m5d.12xlarge	emr-5.16.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.16xlarge	emr-5.16.0, emr-6.0.0
	m5d.24xlarge	emr-5.16.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.16.0, emr-6.0.0
	c5.2xlarge	emr-5.16.0, emr-6.0.0
	c5.4xlarge	emr-5.16.0, emr-6.0.0
	c5.9xlarge	emr-5.16.0, emr-6.0.0
	c5.12xlarge	emr-5.16.0, emr-6.0.0
	c5.18xlarge	emr-5.16.0, emr-6.0.0
	c5.24xlarge	emr-5.16.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.16.0, emr-6.0.0
	c5d.2xlarge	emr-5.16.0, emr-6.0.0
	c5d.4xlarge	emr-5.16.0, emr-6.0.0
	c5d.9xlarge	emr-5.16.0, emr-6.0.0
	c5d.18xlarge	emr-5.16.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.16.0, emr-6.0.0
	r5.2xlarge	emr-5.16.0, emr-6.0.0
	r5.4xlarge	emr-5.16.0, emr-6.0.0
	r5.8xlarge	emr-5.16.0, emr-6.0.0
	r5.12xlarge	emr-5.16.0, emr-6.0.0
	r5.16xlarge	emr-5.16.0, emr-6.0.0
	r5.24xlarge	emr-5.16.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.16.0, emr-6.0.0
	r5d.2xlarge	emr-5.16.0, emr-6.0.0
	r5d.4xlarge	emr-5.16.0, emr-6.0.0
	r5d.8xlarge	emr-5.16.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.12xlarge	emr-5.16.0, emr-6.0.0
	r5d.16xlarge	emr-5.16.0, emr-6.0.0
	r5d.24xlarge	emr-5.16.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.16.0, emr-6.0.0
	d2.2xlarge	emr-5.16.0, emr-6.0.0
	d2.4xlarge	emr-5.16.0, emr-6.0.0
	d2.8xlarge	emr-5.16.0, emr-6.0.0
	i3.xlarge	emr-5.16.0, emr-6.0.0
	i3.2xlarge	emr-5.16.0, emr-6.0.0
	i3.4xlarge	emr-5.16.0, emr-6.0.0
	i3.8xlarge	emr-5.16.0, emr-6.0.0
	i3.16xlarge	emr-5.16.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Afrika (Kapstadt) – af-south-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.29.0, emr-6.0.0
	m5.2xlarge	emr-5.29.0, emr-6.0.0
	m5.4xlarge	emr-5.29.0, emr-6.0.0
	m5.8xlarge	emr-5.29.0, emr-6.0.0
	m5.12xlarge	emr-5.29.0, emr-6.0.0
	m5.16xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.24xlarge	emr-5.29.0, emr-6.0.0
	m5d.xlarge	emr-5.29.0, emr-6.0.0
	m5d.2xlarge	emr-5.29.0, emr-6.0.0
	m5d.4xlarge	emr-5.29.0, emr-6.0.0
	m5d.8xlarge	emr-5.29.0, emr-6.0.0
	m5d.12xlarge	emr-5.29.0, emr-6.0.0
	m5d.16xlarge	emr-5.29.0, emr-6.0.0
	m5d.24xlarge	emr-5.29.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.29.0, emr-6.0.0
	c5.2xlarge	emr-5.29.0, emr-6.0.0
	c5.4xlarge	emr-5.29.0, emr-6.0.0
	c5.9xlarge	emr-5.29.0, emr-6.0.0
	c5.12xlarge	emr-5.29.0, emr-6.0.0
	c5.18xlarge	emr-5.29.0, emr-6.0.0
	c5.24xlarge	emr-5.29.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.29.0, emr-6.0.0
	c5d.2xlarge	emr-5.29.0, emr-6.0.0
	c5d.4xlarge	emr-5.29.0, emr-6.0.0
	c5d.9xlarge	emr-5.29.0, emr-6.0.0
	c5d.12xlarge	emr-5.29.0, emr-6.0.0
	c5d.18xlarge	emr-5.29.0, emr-6.0.0
	c5d.24xlarge	emr-5.29.0, emr-6.0.0
	c5n.xlarge	emr-5.29.0, emr-6.0.0
	c5n.2xlarge	emr-5.29.0, emr-6.0.0
	c5n.4xlarge	emr-5.29.0, emr-6.0.0
	c5n.9xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5n.18xlarge	emr-5.29.0, emr-6.0.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.29.0, emr-6.0.0
	r5.2xlarge	emr-5.29.0, emr-6.0.0
	r5.4xlarge	emr-5.29.0, emr-6.0.0
	r5.8xlarge	emr-5.29.0, emr-6.0.0
	r5.12xlarge	emr-5.29.0, emr-6.0.0
	r5.16xlarge	emr-5.29.0, emr-6.0.0
	r5.24xlarge	emr-5.29.0, emr-6.0.0
	r5d.xlarge	emr-5.29.0, emr-6.0.0
	r5d.2xlarge	emr-5.29.0, emr-6.0.0
	r5d.4xlarge	emr-5.29.0, emr-6.0.0
	r5d.8xlarge	emr-5.29.0, emr-6.0.0
	r5d.12xlarge	emr-5.29.0, emr-6.0.0
	r5d.16xlarge	emr-5.29.0, emr-6.0.0
	r5d.24xlarge	emr-5.29.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
Speicheroptimiert	d2.xlarge	emr-5.29.0, emr-6.0.0
	d2.2xlarge	emr-5.29.0, emr-6.0.0
	d2.4xlarge	emr-5.29.0, emr-6.0.0
	d2.8xlarge	emr-5.29.0, emr-6.0.0
	i3.xlarge	emr-5.29.0, emr-6.0.0
	i3.2xlarge	emr-5.29.0, emr-6.0.0
	i3.4xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.8xlarge	emr-5.29.0, emr-6.0.0
	i3.16xlarge	emr-5.29.0, emr-6.0.0
	i3en.xlarge	emr-5.29.0, emr-6.0.0
	i3en.2xlarge	emr-5.29.0, emr-6.0.0
	i3en.3xlarge	emr-5.29.0, emr-6.0.0
	i3en.6xlarge	emr-5.29.0, emr-6.0.0
	i3en.12xlarge	emr-5.29.0, emr-6.0.0
	i3en.24xlarge	emr-5.29.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Hongkong) – ap-east-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.20.0, emr-6.0.0
	m5.2xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.4xlarge	emr-5.20.0, emr-6.0.0
	m5.8xlarge	emr-5.20.0, emr-6.0.0
	m5.12xlarge	emr-5.20.0, emr-6.0.0
	m5.16xlarge	emr-5.20.0, emr-6.0.0
	m5.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.20.0, emr-6.0.0
	m5d.2xlarge	emr-5.20.0, emr-6.0.0
	m5d.4xlarge	emr-5.20.0, emr-6.0.0
	m5d.8xlarge	emr-5.20.0, emr-6.0.0
	m5d.12xlarge	emr-5.20.0, emr-6.0.0
	m5d.16xlarge	emr-5.20.0, emr-6.0.0
	m5d.24xlarge	emr-5.20.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.20.0, emr-6.0.0
	c5.2xlarge	emr-5.20.0, emr-6.0.0
	c5.4xlarge	emr-5.20.0, emr-6.0.0
	c5.9xlarge	emr-5.20.0, emr-6.0.0
	c5.12xlarge	emr-5.20.0, emr-6.0.0
	c5.18xlarge	emr-5.20.0, emr-6.0.0
	c5.24xlarge	emr-5.20.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.xlarge	emr-5.20.0, emr-6.0.0
	c5d.2xlarge	emr-5.20.0, emr-6.0.0
	c5d.4xlarge	emr-5.20.0, emr-6.0.0
	c5d.9xlarge	emr-5.20.0, emr-6.0.0
	c5d.18xlarge	emr-5.20.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.20.0, emr-6.0.0
	r5.2xlarge	emr-5.20.0, emr-6.0.0
	r5.4xlarge	emr-5.20.0, emr-6.0.0
	r5.8xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.12xlarge	emr-5.20.0, emr-6.0.0
	r5.16xlarge	emr-5.20.0, emr-6.0.0
	r5.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.20.0, emr-6.0.0
	r5d.2xlarge	emr-5.20.0, emr-6.0.0
	r5d.4xlarge	emr-5.20.0, emr-6.0.0
	r5d.8xlarge	emr-5.20.0, emr-6.0.0
	r5d.12xlarge	emr-5.20.0, emr-6.0.0
	r5d.16xlarge	emr-5.20.0, emr-6.0.0
	r5d.24xlarge	emr-5.20.0, emr-6.0.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.20.0, emr-6.0.0
	d2.2xlarge	emr-5.20.0, emr-6.0.0
	d2.4xlarge	emr-5.20.0, emr-6.0.0
	d2.8xlarge	emr-5.20.0, emr-6.0.0
	i3.xlarge	emr-5.20.0, emr-6.0.0
	i3.2xlarge	emr-5.20.0, emr-6.0.0
	i3.4xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.8xlarge	emr-5.20.0, emr-6.0.0
	i3.16xlarge	emr-5.20.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Jakarta) – ap-southeast-3

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.30.2, emr-6.0.1
	m5.2xlarge	emr-5.30.2, emr-6.0.1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.4xlarge	emr-5.30.2, emr-6.0.1
	m5.8xlarge	emr-5.30.2, emr-6.0.1
	m5.12xlarge	emr-5.30.2, emr-6.0.1
	m5.16xlarge	emr-5.30.2, emr-6.0.1
	m5.24xlarge	emr-5.30.2, emr-6.0.1
	m5a.xlarge	emr-5.30.2, emr-6.0.1
	m5a.2xlarge	emr-5.30.2, emr-6.0.1
	m5a.4xlarge	emr-5.30.2, emr-6.0.1
	m5a.8xlarge	emr-5.30.2, emr-6.0.1
	m5a.12xlarge	emr-5.30.2, emr-6.0.1
	m5a.16xlarge	emr-5.30.2, emr-6.0.1
	m5a.24xlarge	emr-5.30.2, emr-6.0.1
	m5d.xlarge	emr-5.30.2, emr-6.0.1
	m5d.2xlarge	emr-5.30.2, emr-6.0.1
	m5d.4xlarge	emr-5.30.2, emr-6.0.1
	m5d.8xlarge	emr-5.30.2, emr-6.0.1
	m5d.12xlarge	emr-5.30.2, emr-6.0.1
	m5d.16xlarge	emr-5.30.2, emr-6.0.1
	m5d.24xlarge	emr-5.30.2, emr-6.0.1
	m6g.xlarge	emr-5.30.2, emr-6.1.1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.2xlarge	emr-5.30.2, emr-6.1.1
	m6g.4xlarge	emr-5.30.2, emr-6.1.1
	m6g.8xlarge	emr-5.30.2, emr-6.1.1
	m6g.12xlarge	emr-5.30.2, emr-6.1.1
	m6g.16xlarge	emr-5.30.2, emr-6.1.1
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.30.2, emr-6.0.1
	c5.2xlarge	emr-5.30.2, emr-6.0.1
	c5.4xlarge	emr-5.30.2, emr-6.0.1
	c5.9xlarge	emr-5.30.2, emr-6.0.1
	c5.12xlarge	emr-5.30.2, emr-6.0.1
	c5.18xlarge	emr-5.30.2, emr-6.0.1
	c5.24xlarge	emr-5.30.2, emr-6.0.1
	c5d.xlarge	emr-5.30.2, emr-6.0.1
	c5d.2xlarge	emr-5.30.2, emr-6.0.1
	c5d.4xlarge	emr-5.30.2, emr-6.0.1
	c5d.9xlarge	emr-5.30.2, emr-6.0.1
	c5d.12xlarge	emr-5.30.2, emr-6.0.1
	c5d.18xlarge	emr-5.30.2, emr-6.0.1
	c5d.24xlarge	emr-5.30.2, emr-6.0.1
	c5n.xlarge	emr-5.30.2, emr-6.0.1
	c5n.2xlarge	emr-5.30.2, emr-6.0.1
	c5n.4xlarge	emr-5.30.2, emr-6.0.1
	c5n.9xlarge	emr-5.30.2, emr-6.0.1
	c5n.18xlarge	emr-5.30.2, emr-6.0.1
	c6g.xlarge	emr-5.31.1, emr-6.1.1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.2xlarge	emr-5.31.1, emr-6.1.1
	c6g.4xlarge	emr-5.31.1, emr-6.1.1
	c6g.8xlarge	emr-5.31.1, emr-6.1.1
	c6g.12xlarge	emr-5.31.1, emr-6.1.1
	c6g.16xlarge	emr-5.31.1, emr-6.1.1
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Beschleunigte Datenverarbeitung	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
RAM-optimiert	r5.xlarge	emr-5.30.2, emr-6.0.1
	r5.2xlarge	emr-5.30.2, emr-6.0.1
	r5.4xlarge	emr-5.30.2, emr-6.0.1
	r5.8xlarge	emr-5.30.2, emr-6.0.1
	r5.12xlarge	emr-5.30.2, emr-6.0.1
	r5.16xlarge	emr-5.30.2, emr-6.0.1
	r5.24xlarge	emr-5.30.2, emr-6.0.1
	r5d.xlarge	emr-5.30.2, emr-6.0.1
	r5d.2xlarge	emr-5.30.2, emr-6.0.1
	r5d.4xlarge	emr-5.30.2, emr-6.0.1
	r5d.8xlarge	emr-5.30.2, emr-6.0.1
	r5d.12xlarge	emr-5.30.2, emr-6.0.1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.30.2, emr-6.0.1
	r5d.24xlarge	emr-5.30.2, emr-6.0.1
	r6g.xlarge	emr-5.31.1, emr-6.1.1
	r6g.2xlarge	emr-5.31.1, emr-6.1.1
	r6g.4xlarge	emr-5.31.1, emr-6.1.1
	r6g.8xlarge	emr-5.31.1, emr-6.1.1
	r6g.12xlarge	emr-5.31.1, emr-6.1.1
	r6g.16xlarge	emr-5.31.1, emr-6.1.1
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.30.2, emr-6.0.1
	d2.2xlarge	emr-5.30.2, emr-6.0.1
	d2.4xlarge	emr-5.30.2, emr-6.0.1
	d2.8xlarge	emr-5.30.2, emr-6.0.1
	i3.xlarge	emr-5.30.2, emr-6.0.1
	i3.2xlarge	emr-5.30.2, emr-6.0.1
	i3.4xlarge	emr-5.30.2, emr-6.0.1
	i3.8xlarge	emr-5.30.2, emr-6.0.1
	i3.16xlarge	emr-5.30.2, emr-6.0.1
	i3en.xlarge	emr-5.30.2, emr-6.0.1
	i3en.2xlarge	emr-5.30.2, emr-6.0.1
	i3en.3xlarge	emr-5.30.2, emr-6.0.1
	i3en.6xlarge	emr-5.30.2, emr-6.0.1
	i3en.12xlarge	emr-5.30.2, emr-6.0.1
	i3en.24xlarge	emr-5.30.2, emr-6.0.1
	i4i.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Mumbai) – ap-south-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6a.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.6.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.6.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.6.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.6.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Hyderabad) – ap-south-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.36.0, emr-6.7.0
	m5.2xlarge	emr-5.36.0, emr-6.7.0
	m5.4xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.8xlarge	emr-5.36.0, emr-6.7.0
	m5.12xlarge	emr-5.36.0, emr-6.7.0
	m5.16xlarge	emr-5.36.0, emr-6.7.0
	m5.24xlarge	emr-5.36.0, emr-6.7.0
	m5d.xlarge	emr-5.36.0, emr-6.7.0
	m5d.2xlarge	emr-5.36.0, emr-6.7.0
	m5d.4xlarge	emr-5.36.0, emr-6.7.0
	m5d.8xlarge	emr-5.36.0, emr-6.7.0
	m5d.12xlarge	emr-5.36.0, emr-6.7.0
	m5d.16xlarge	emr-5.36.0, emr-6.7.0
	m5d.24xlarge	emr-5.36.0, emr-6.7.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.xlarge	emr-5.36.0, emr-6.7.0
	m6g.2xlarge	emr-5.36.0, emr-6.7.0
	m6g.4xlarge	emr-5.36.0, emr-6.7.0
	m6g.8xlarge	emr-5.36.0, emr-6.7.0
	m6g.12xlarge	emr-5.36.0, emr-6.7.0
	m6g.16xlarge	emr-5.36.0, emr-6.7.0
	m6gd.xlarge	emr-5.36.0, emr-6.7.0
	m6gd.2xlarge	emr-5.36.0, emr-6.7.0
	m6gd.4xlarge	emr-5.36.0, emr-6.7.0
	m6gd.8xlarge	emr-5.36.0, emr-6.7.0
	m6gd.12xlarge	emr-5.36.0, emr-6.7.0
	m6gd.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.xlarge	emr-5.36.0, emr-6.7.0
	m6i.2xlarge	emr-5.36.0, emr-6.7.0
	m6i.4xlarge	emr-5.36.0, emr-6.7.0
	m6i.8xlarge	emr-5.36.0, emr-6.7.0
	m6i.12xlarge	emr-5.36.0, emr-6.7.0
	m6i.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.24xlarge	emr-5.36.0, emr-6.7.0
	m6i.32xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.36.0, emr-6.7.0
	c5.2xlarge	emr-5.36.0, emr-6.7.0
	c5.4xlarge	emr-5.36.0, emr-6.7.0
	c5.9xlarge	emr-5.36.0, emr-6.7.0
	c5.12xlarge	emr-5.36.0, emr-6.7.0
	c5.18xlarge	emr-5.36.0, emr-6.7.0
	c5.24xlarge	emr-5.36.0, emr-6.7.0
	c5d.xlarge	emr-5.36.0, emr-6.7.0
	c5d.2xlarge	emr-5.36.0, emr-6.7.0
	c5d.4xlarge	emr-5.36.0, emr-6.7.0
	c5d.9xlarge	emr-5.36.0, emr-6.7.0
	c5d.12xlarge	emr-5.36.0, emr-6.7.0
	c5d.18xlarge	emr-5.36.0, emr-6.7.0
	c5d.24xlarge	emr-5.36.0, emr-6.7.0
	c6g.xlarge	emr-5.36.0, emr-6.7.0
	c6g.2xlarge	emr-5.36.0, emr-6.7.0
	c6g.4xlarge	emr-5.36.0, emr-6.7.0
	c6g.8xlarge	emr-5.36.0, emr-6.7.0
	c6g.12xlarge	emr-5.36.0, emr-6.7.0
	c6g.16xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.xlarge	emr-5.36.0, emr-6.7.0
	c6i.2xlarge	emr-5.36.0, emr-6.7.0
	c6i.4xlarge	emr-5.36.0, emr-6.7.0
	c6i.8xlarge	emr-5.36.0, emr-6.7.0
	c6i.12xlarge	emr-5.36.0, emr-6.7.0
	c6i.16xlarge	emr-5.36.0, emr-6.7.0
	c6i.24xlarge	emr-5.36.0, emr-6.7.0
	c6i.32xlarge	emr-5.36.0, emr-6.7.0
RAM-optimiert	r5.xlarge	emr-5.36.0, emr-6.7.0
	r5.2xlarge	emr-5.36.0, emr-6.7.0
	r5.4xlarge	emr-5.36.0, emr-6.7.0
	r5.8xlarge	emr-5.36.0, emr-6.7.0
	r5.12xlarge	emr-5.36.0, emr-6.7.0
	r5.16xlarge	emr-5.36.0, emr-6.7.0
	r5.24xlarge	emr-5.36.0, emr-6.7.0
	r5d.xlarge	emr-5.36.0, emr-6.7.0
	r5d.2xlarge	emr-5.36.0, emr-6.7.0
	r5d.4xlarge	emr-5.36.0, emr-6.7.0
	r5d.8xlarge	emr-5.36.0, emr-6.7.0
	r5d.12xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.36.0, emr-6.7.0
	r5d.24xlarge	emr-5.36.0, emr-6.7.0
	r6g.xlarge	emr-5.36.0, emr-6.7.0
	r6g.2xlarge	emr-5.36.0, emr-6.7.0
	r6g.4xlarge	emr-5.36.0, emr-6.7.0
	r6g.8xlarge	emr-5.36.0, emr-6.7.0
	r6g.12xlarge	emr-5.36.0, emr-6.7.0
	r6g.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.xlarge	emr-5.36.0, emr-6.7.0
	r6i.2xlarge	emr-5.36.0, emr-6.7.0
	r6i.4xlarge	emr-5.36.0, emr-6.7.0
	r6i.8xlarge	emr-5.36.0, emr-6.7.0
	r6i.12xlarge	emr-5.36.0, emr-6.7.0
	r6i.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.24xlarge	emr-5.36.0, emr-6.7.0
	r6i.32xlarge	emr-5.36.0, emr-6.7.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	i3.xlarge	emr-5.36.0, emr-6.7.0
	i3.2xlarge	emr-5.36.0, emr-6.7.0
	i3.4xlarge	emr-5.36.0, emr-6.7.0
	i3.8xlarge	emr-5.36.0, emr-6.7.0
	i3.16xlarge	emr-5.36.0, emr-6.7.0
	i3en.xlarge	emr-5.36.0, emr-6.7.0
	i3en.2xlarge	emr-5.36.0, emr-6.7.0
	i3en.3xlarge	emr-5.36.0, emr-6.7.0
	i3en.6xlarge	emr-5.36.0, emr-6.7.0
	i3en.12xlarge	emr-5.36.0, emr-6.7.0
	i3en.24xlarge	emr-5.36.0, emr-6.7.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Osaka) – ap-northeast-3

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.10.0, emr-6.0.0
	d2.2xlarge	emr-5.10.0, emr-6.0.0
	d2.4xlarge	emr-5.10.0, emr-6.0.0
	d2.8xlarge	emr-5.10.0, emr-6.0.0
	i3.xlarge	emr-5.10.0, emr-6.0.0
	i3.2xlarge	emr-5.10.0, emr-6.0.0
	i3.4xlarge	emr-5.10.0, emr-6.0.0
	i3.8xlarge	emr-5.10.0, emr-6.0.0
	i3.16xlarge	emr-5.10.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Seoul) – ap-northeast-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.1.0, emr-5.0.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d2.2xlarge	emr-4.1.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.1.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.1.0, emr-5.0.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Asien-Pazifik (Singapur) – ap-southeast-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Asien-Pazifik (Sydney) – ap-southeast-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Asien-Pazifik (Tokio) – ap-northeast-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.12xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Kanada (Zentral) – ca-central-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-4.8.2, emr-5.1.0, emr-6.0.0
	d2.2xlarge	emr-4.8.2, emr-5.1.0, emr-6.0.0
	d2.4xlarge	emr-4.8.2, emr-5.1.0, emr-6.0.0
	d2.8xlarge	emr-4.8.2, emr-5.1.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4g.xlarge	emr-5.36.1, emr-6.10.0
	i4g.2xlarge	emr-5.36.1, emr-6.10.0
	i4g.4xlarge	emr-5.36.1, emr-6.10.0
	i4g.8xlarge	emr-5.36.1, emr-6.10.0
	i4g.16xlarge	emr-5.36.1, emr-6.10.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

China (Ningxia) – cn-northwest-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.9.1, emr-5.5.3, emr-6.0.0
	d2.2xlarge	emr-4.9.1, emr-5.5.3, emr-6.0.0
	d2.4xlarge	emr-4.9.1, emr-5.5.3, emr-6.0.0
	d2.8xlarge	emr-4.9.1, emr-5.5.3, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0

China (Peking) – cn-north-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0

Europa (Frankfurt) – eu-central-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0
	m7gd.xlarge	emr-5.36.1, emr-6.10.0
	m7gd.2xlarge	emr-5.36.1, emr-6.10.0
	m7gd.4xlarge	emr-5.36.1, emr-6.10.0
	m7gd.8xlarge	emr-5.36.1, emr-6.10.0
	m7gd.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7gd.16xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
	c7gd.xlarge	emr-5.36.1, emr-6.10.0
	c7gd.2xlarge	emr-5.36.1, emr-6.10.0
	c7gd.4xlarge	emr-5.36.1, emr-6.10.0
	c7gd.8xlarge	emr-5.36.1, emr-6.10.0
	c7gd.12xlarge	emr-5.36.1, emr-6.10.0
	c7gd.16xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6a.xlarge	emr-5.36.1, emr-6.8.0
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	r7gd.xlarge	emr-5.36.1, emr-6.10.0
	r7gd.2xlarge	emr-5.36.1, emr-6.10.0
	r7gd.4xlarge	emr-5.36.1, emr-6.10.0
	r7gd.8xlarge	emr-5.36.1, emr-6.10.0
	r7gd.12xlarge	emr-5.36.1, emr-6.10.0
	r7gd.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.12xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Europa (Zürich) – eu-central-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.36.0, emr-6.7.0
	m5.2xlarge	emr-5.36.0, emr-6.7.0
	m5.4xlarge	emr-5.36.0, emr-6.7.0
	m5.8xlarge	emr-5.36.0, emr-6.7.0
	m5.12xlarge	emr-5.36.0, emr-6.7.0
	m5.16xlarge	emr-5.36.0, emr-6.7.0
	m5.24xlarge	emr-5.36.0, emr-6.7.0
	m5d.xlarge	emr-5.36.0, emr-6.7.0
	m5d.2xlarge	emr-5.36.0, emr-6.7.0
	m5d.4xlarge	emr-5.36.0, emr-6.7.0
	m5d.8xlarge	emr-5.36.0, emr-6.7.0
	m5d.12xlarge	emr-5.36.0, emr-6.7.0
	m5d.16xlarge	emr-5.36.0, emr-6.7.0
	m5d.24xlarge	emr-5.36.0, emr-6.7.0
	m6g.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.2xlarge	emr-5.36.0, emr-6.7.0
	m6g.4xlarge	emr-5.36.0, emr-6.7.0
	m6g.8xlarge	emr-5.36.0, emr-6.7.0
	m6g.12xlarge	emr-5.36.0, emr-6.7.0
	m6g.16xlarge	emr-5.36.0, emr-6.7.0
	m6gd.xlarge	emr-5.36.0, emr-6.7.0
	m6gd.2xlarge	emr-5.36.0, emr-6.7.0
	m6gd.4xlarge	emr-5.36.0, emr-6.7.0
	m6gd.8xlarge	emr-5.36.0, emr-6.7.0
	m6gd.12xlarge	emr-5.36.0, emr-6.7.0
	m6gd.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.xlarge	emr-5.36.0, emr-6.7.0
	m6i.2xlarge	emr-5.36.0, emr-6.7.0
	m6i.4xlarge	emr-5.36.0, emr-6.7.0
	m6i.8xlarge	emr-5.36.0, emr-6.7.0
	m6i.12xlarge	emr-5.36.0, emr-6.7.0
	m6i.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.24xlarge	emr-5.36.0, emr-6.7.0
	m6i.32xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.36.0, emr-6.7.0
	c5.2xlarge	emr-5.36.0, emr-6.7.0
	c5.4xlarge	emr-5.36.0, emr-6.7.0
	c5.9xlarge	emr-5.36.0, emr-6.7.0
	c5.12xlarge	emr-5.36.0, emr-6.7.0
	c5.18xlarge	emr-5.36.0, emr-6.7.0
	c5.24xlarge	emr-5.36.0, emr-6.7.0
	c5d.xlarge	emr-5.36.0, emr-6.7.0
	c5d.2xlarge	emr-5.36.0, emr-6.7.0
	c5d.4xlarge	emr-5.36.0, emr-6.7.0
	c5d.9xlarge	emr-5.36.0, emr-6.7.0
	c5d.12xlarge	emr-5.36.0, emr-6.7.0
	c5d.18xlarge	emr-5.36.0, emr-6.7.0
	c5d.24xlarge	emr-5.36.0, emr-6.7.0
	c6g.xlarge	emr-5.36.0, emr-6.7.0
	c6g.2xlarge	emr-5.36.0, emr-6.7.0
	c6g.4xlarge	emr-5.36.0, emr-6.7.0
	c6g.8xlarge	emr-5.36.0, emr-6.7.0
	c6g.12xlarge	emr-5.36.0, emr-6.7.0
	c6g.16xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
RAM-optimiert	r5.xlarge	emr-5.36.0, emr-6.7.0
	r5.2xlarge	emr-5.36.0, emr-6.7.0
	r5.4xlarge	emr-5.36.0, emr-6.7.0
	r5.8xlarge	emr-5.36.0, emr-6.7.0
	r5.12xlarge	emr-5.36.0, emr-6.7.0
	r5.16xlarge	emr-5.36.0, emr-6.7.0
	r5.24xlarge	emr-5.36.0, emr-6.7.0
	r5d.xlarge	emr-5.36.0, emr-6.7.0
	r5d.2xlarge	emr-5.36.0, emr-6.7.0
	r5d.4xlarge	emr-5.36.0, emr-6.7.0
	r5d.8xlarge	emr-5.36.0, emr-6.7.0
	r5d.12xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.36.0, emr-6.7.0
	r5d.24xlarge	emr-5.36.0, emr-6.7.0
	r6g.xlarge	emr-5.36.0, emr-6.7.0
	r6g.2xlarge	emr-5.36.0, emr-6.7.0
	r6g.4xlarge	emr-5.36.0, emr-6.7.0
	r6g.8xlarge	emr-5.36.0, emr-6.7.0
	r6g.12xlarge	emr-5.36.0, emr-6.7.0
	r6g.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.xlarge	emr-5.36.0, emr-6.7.0
	r6i.2xlarge	emr-5.36.0, emr-6.7.0
	r6i.4xlarge	emr-5.36.0, emr-6.7.0
	r6i.8xlarge	emr-5.36.0, emr-6.7.0
	r6i.12xlarge	emr-5.36.0, emr-6.7.0
	r6i.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.24xlarge	emr-5.36.0, emr-6.7.0
	r6i.32xlarge	emr-5.36.0, emr-6.7.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	i3.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.2xlarge	emr-5.36.0, emr-6.7.0
	i3.4xlarge	emr-5.36.0, emr-6.7.0
	i3.8xlarge	emr-5.36.0, emr-6.7.0
	i3.16xlarge	emr-5.36.0, emr-6.7.0
	i3en.xlarge	emr-5.36.0, emr-6.7.0
	i3en.2xlarge	emr-5.36.0, emr-6.7.0
	i3en.3xlarge	emr-5.36.0, emr-6.7.0
	i3en.6xlarge	emr-5.36.0, emr-6.7.0
	i3en.12xlarge	emr-5.36.0, emr-6.7.0
	i3en.24xlarge	emr-5.36.0, emr-6.7.0

Europa (Irland) – eu-west-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5dn.xlarge	emr-5.31.0, emr-6.1.0
	m5dn.2xlarge	emr-5.31.0, emr-6.1.0
	m5dn.4xlarge	emr-5.31.0, emr-6.1.0
	m5dn.8xlarge	emr-5.31.0, emr-6.1.0
	m5dn.12xlarge	emr-5.31.0, emr-6.1.0
	m5dn.16xlarge	emr-5.31.0, emr-6.1.0
	m5dn.24xlarge	emr-5.31.0, emr-6.1.0
	m5n.xlarge	emr-5.31.0, emr-6.1.0
	m5n.2xlarge	emr-5.31.0, emr-6.1.0
	m5n.4xlarge	emr-5.31.0, emr-6.1.0
	m5n.8xlarge	emr-5.31.0, emr-6.1.0
	m5n.12xlarge	emr-5.31.0, emr-6.1.0
	m5n.16xlarge	emr-5.31.0, emr-6.1.0
	m5n.24xlarge	emr-5.31.0, emr-6.1.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
	m6id.xlarge	emr-5.36.1, emr-6.8.0
	m6id.2xlarge	emr-5.36.1, emr-6.8.0
	m6id.4xlarge	emr-5.36.1, emr-6.8.0
	m6id.8xlarge	emr-5.36.1, emr-6.8.0
	m6id.12xlarge	emr-5.36.1, emr-6.8.0
	m6id.16xlarge	emr-5.36.1, emr-6.8.0
	m6id.24xlarge	emr-5.36.1, emr-6.8.0
	m6id.32xlarge	emr-5.36.1, emr-6.8.0
	m6idn.xlarge	emr-5.36.1, emr-6.10.0
	m6idn.2xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6idn.4xlarge	emr-5.36.1, emr-6.10.0
	m6idn.8xlarge	emr-5.36.1, emr-6.10.0
	m6idn.12xlarge	emr-5.36.1, emr-6.10.0
	m6idn.16xlarge	emr-5.36.1, emr-6.10.0
	m6idn.24xlarge	emr-5.36.1, emr-6.10.0
	m6idn.32xlarge	emr-5.36.1, emr-6.10.0
	m6in.xlarge	emr-5.36.1, emr-6.10.0
	m6in.2xlarge	emr-5.36.1, emr-6.10.0
	m6in.4xlarge	emr-5.36.1, emr-6.10.0
	m6in.8xlarge	emr-5.36.1, emr-6.10.0
	m6in.12xlarge	emr-5.36.1, emr-6.10.0
	m6in.16xlarge	emr-5.36.1, emr-6.10.0
	m6in.24xlarge	emr-5.36.1, emr-6.10.0
	m6in.32xlarge	emr-5.36.1, emr-6.10.0
	m7g.xlarge	emr-5.36.1, emr-6.10.0
	m7g.2xlarge	emr-5.36.1, emr-6.10.0
	m7g.4xlarge	emr-5.36.1, emr-6.10.0
	m7g.8xlarge	emr-5.36.1, emr-6.10.0
	m7g.12xlarge	emr-5.36.1, emr-6.10.0
	m7g.16xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m7gd.xlarge	emr-5.36.1, emr-6.10.0
	m7gd.2xlarge	emr-5.36.1, emr-6.10.0
	m7gd.4xlarge	emr-5.36.1, emr-6.10.0
	m7gd.8xlarge	emr-5.36.1, emr-6.10.0
	m7gd.12xlarge	emr-5.36.1, emr-6.10.0
	m7gd.16xlarge	emr-5.36.1, emr-6.10.0
	m7i.xlarge	emr-5.36.1, emr-6.10.0
	m7i.2xlarge	emr-5.36.1, emr-6.10.0
	m7i.4xlarge	emr-5.36.1, emr-6.10.0
	m7i.8xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.2xlarge	emr-5.36.1, emr-6.10.0
	m7i-flex.4xlarge	emr-5.36.1, emr-6.10.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6id.xlarge	emr-5.36.1, emr-6.8.0
	c6id.2xlarge	emr-5.36.1, emr-6.8.0
	c6id.4xlarge	emr-5.36.1, emr-6.8.0
	c6id.8xlarge	emr-5.36.1, emr-6.8.0
	c6id.12xlarge	emr-5.36.1, emr-6.8.0
	c6id.16xlarge	emr-5.36.1, emr-6.8.0
	c6id.24xlarge	emr-5.36.1, emr-6.8.0
	c6id.32xlarge	emr-5.36.1, emr-6.8.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
	c7g.xlarge	emr-5.36.1, emr-6.7.0
	c7g.2xlarge	emr-5.36.1, emr-6.7.0
	c7g.4xlarge	emr-5.36.1, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c7g.8xlarge	emr-5.36.1, emr-6.7.0
	c7g.12xlarge	emr-5.36.1, emr-6.7.0
	c7g.16xlarge	emr-5.36.1, emr-6.7.0
	c7gd.xlarge	emr-5.36.1, emr-6.10.0
	c7gd.2xlarge	emr-5.36.1, emr-6.10.0
	c7gd.4xlarge	emr-5.36.1, emr-6.10.0
	c7gd.8xlarge	emr-5.36.1, emr-6.10.0
	c7gd.12xlarge	emr-5.36.1, emr-6.10.0
	c7gd.16xlarge	emr-5.36.1, emr-6.10.0
	c7gn.xlarge	emr-5.36.1, emr-6.10.0
	c7gn.2xlarge	emr-5.36.1, emr-6.10.0
	c7gn.4xlarge	emr-5.36.1, emr-6.10.0
	c7gn.8xlarge	emr-5.36.1, emr-6.10.0
	c7gn.12xlarge	emr-5.36.1, emr-6.10.0
	c7gn.16xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p2.xlarge	emr-5.10.0, emr-6.0.0
	p2.8xlarge	emr-5.10.0, emr-6.0.0
	p2.16xlarge	emr-5.10.0, emr-6.0.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6a.xlarge	emr-5.36.1, emr-6.8.0
	r6a.2xlarge	emr-5.36.1, emr-6.8.0
	r6a.4xlarge	emr-5.36.1, emr-6.8.0
	r6a.8xlarge	emr-5.36.1, emr-6.8.0
	r6a.12xlarge	emr-5.36.1, emr-6.8.0
	r6a.16xlarge	emr-5.36.1, emr-6.8.0
	r6a.24xlarge	emr-5.36.1, emr-6.8.0
	r6a.32xlarge	emr-5.36.1, emr-6.8.0
	r6a.48xlarge	emr-5.36.1, emr-6.8.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	r6idn.xlarge	emr-5.36.1, emr-6.10.0
	r6idn.2xlarge	emr-5.36.1, emr-6.10.0
	r6idn.4xlarge	emr-5.36.1, emr-6.10.0
	r6idn.8xlarge	emr-5.36.1, emr-6.10.0
	r6idn.12xlarge	emr-5.36.1, emr-6.10.0
	r6idn.16xlarge	emr-5.36.1, emr-6.10.0
	r6idn.24xlarge	emr-5.36.1, emr-6.10.0
	r6idn.32xlarge	emr-5.36.1, emr-6.10.0
	r6in.xlarge	emr-5.36.1, emr-6.10.0
	r6in.2xlarge	emr-5.36.1, emr-6.10.0
	r6in.4xlarge	emr-5.36.1, emr-6.10.0
	r6in.8xlarge	emr-5.36.1, emr-6.10.0
	r6in.12xlarge	emr-5.36.1, emr-6.10.0
	r6in.16xlarge	emr-5.36.1, emr-6.10.0
	r6in.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6in.32xlarge	emr-5.36.1, emr-6.10.0
	r7g.xlarge	emr-5.36.1, emr-6.10.0
	r7g.2xlarge	emr-5.36.1, emr-6.10.0
	r7g.4xlarge	emr-5.36.1, emr-6.10.0
	r7g.8xlarge	emr-5.36.1, emr-6.10.0
	r7g.12xlarge	emr-5.36.1, emr-6.10.0
	r7g.16xlarge	emr-5.36.1, emr-6.10.0
	r7gd.xlarge	emr-5.36.1, emr-6.10.0
	r7gd.2xlarge	emr-5.36.1, emr-6.10.0
	r7gd.4xlarge	emr-5.36.1, emr-6.10.0
	r7gd.8xlarge	emr-5.36.1, emr-6.10.0
	r7gd.12xlarge	emr-5.36.1, emr-6.10.0
	r7gd.16xlarge	emr-5.36.1, emr-6.10.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2gd.xlarge	emr-5.36.1, emr-6.10.0
	x2gd.2xlarge	emr-5.36.1, emr-6.10.0
	x2gd.4xlarge	emr-5.36.1, emr-6.10.0
	x2gd.8xlarge	emr-5.36.1, emr-6.10.0
	x2gd.12xlarge	emr-5.36.1, emr-6.10.0
	x2gd.16xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.2xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.4xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d2.8xlarge	emr-4.0.0, emr-5.0.0, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.xlarge	emr-5.33.0, emr-6.3.0
	d3en.2xlarge	emr-5.33.0, emr-6.3.0
	d3en.4xlarge	emr-5.33.0, emr-6.3.0
	d3en.6xlarge	emr-5.33.0, emr-6.3.0
	d3en.8xlarge	emr-5.33.0, emr-6.3.0
	d3en.12xlarge	emr-5.33.0, emr-6.3.0
	h1.2xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	h1.4xlarge	emr-5.17.0, emr-6.0.0
	h1.8xlarge	emr-5.17.0, emr-6.0.0
	h1.16xlarge	emr-5.17.0, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4g.xlarge	emr-5.36.1, emr-6.10.0
	i4g.2xlarge	emr-5.36.1, emr-6.10.0
	i4g.4xlarge	emr-5.36.1, emr-6.10.0
	i4g.8xlarge	emr-5.36.1, emr-6.10.0
	i4g.16xlarge	emr-5.36.1, emr-6.10.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Europa (London) – eu-west-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g3.4xlarge	emr-5.18.0, emr-6.0.0
	g3.8xlarge	emr-5.18.0, emr-6.0.0
	g3.16xlarge	emr-5.18.0, emr-6.0.0
	g3s.xlarge	emr-5.19.0, emr-6.0.0
	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
	p3.2xlarge	emr-5.10.0, emr-6.0.0
	p3.8xlarge	emr-5.10.0, emr-6.0.0
	p3.16xlarge	emr-5.10.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	r6id.xlarge	emr-5.36.1, emr-6.8.0
	r6id.2xlarge	emr-5.36.1, emr-6.8.0
	r6id.4xlarge	emr-5.36.1, emr-6.8.0
	r6id.8xlarge	emr-5.36.1, emr-6.8.0
	r6id.12xlarge	emr-5.36.1, emr-6.8.0
	r6id.16xlarge	emr-5.36.1, emr-6.8.0
	r6id.24xlarge	emr-5.36.1, emr-6.8.0
	r6id.32xlarge	emr-5.36.1, emr-6.8.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
	z1d.xlarge	emr-5.17.0, emr-6.0.0
	z1d.2xlarge	emr-5.17.0, emr-6.0.0
	z1d.3xlarge	emr-5.17.0, emr-6.0.0
	z1d.6xlarge	emr-5.17.0, emr-6.0.0
	z1d.12xlarge	emr-5.17.0, emr-6.0.0
Speicheroptimiert	d2.xlarge	emr-4.8.2, emr-5.0.3, emr-6.0.0
	d2.2xlarge	emr-4.8.2, emr-5.0.3, emr-6.0.0
	d2.4xlarge	emr-4.8.2, emr-5.0.3, emr-6.0.0
	d2.8xlarge	emr-4.8.2, emr-5.0.3, emr-6.0.0
	d3.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d3.2xlarge	emr-5.33.0, emr-6.3.0
	d3.4xlarge	emr-5.33.0, emr-6.3.0
	d3.8xlarge	emr-5.33.0, emr-6.3.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Europa (Mailand) – eu-south-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.29.0, emr-6.0.0
	m5.2xlarge	emr-5.29.0, emr-6.0.0
	m5.4xlarge	emr-5.29.0, emr-6.0.0
	m5.8xlarge	emr-5.29.0, emr-6.0.0
	m5.12xlarge	emr-5.29.0, emr-6.0.0
	m5.16xlarge	emr-5.29.0, emr-6.0.0
	m5.24xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.xlarge	emr-5.29.0, emr-6.0.0
	m5a.2xlarge	emr-5.29.0, emr-6.0.0
	m5a.4xlarge	emr-5.29.0, emr-6.0.0
	m5a.8xlarge	emr-5.29.0, emr-6.0.0
	m5a.12xlarge	emr-5.29.0, emr-6.0.0
	m5a.16xlarge	emr-5.29.0, emr-6.0.0
	m5a.24xlarge	emr-5.29.0, emr-6.0.0
	m5d.xlarge	emr-5.29.0, emr-6.0.0
	m5d.2xlarge	emr-5.29.0, emr-6.0.0
	m5d.4xlarge	emr-5.29.0, emr-6.0.0
	m5d.8xlarge	emr-5.29.0, emr-6.0.0
	m5d.12xlarge	emr-5.29.0, emr-6.0.0
	m5d.16xlarge	emr-5.29.0, emr-6.0.0
	m5d.24xlarge	emr-5.29.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.29.0, emr-6.0.0
	c5.2xlarge	emr-5.29.0, emr-6.0.0
	c5.4xlarge	emr-5.29.0, emr-6.0.0
	c5.9xlarge	emr-5.29.0, emr-6.0.0
	c5.12xlarge	emr-5.29.0, emr-6.0.0
	c5.18xlarge	emr-5.29.0, emr-6.0.0
	c5.24xlarge	emr-5.29.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.29.0, emr-6.0.0
	c5d.2xlarge	emr-5.29.0, emr-6.0.0
	c5d.4xlarge	emr-5.29.0, emr-6.0.0
	c5d.9xlarge	emr-5.29.0, emr-6.0.0
	c5d.12xlarge	emr-5.29.0, emr-6.0.0
	c5d.18xlarge	emr-5.29.0, emr-6.0.0
	c5d.24xlarge	emr-5.29.0, emr-6.0.0
	c5n.xlarge	emr-5.29.0, emr-6.0.0
	c5n.2xlarge	emr-5.29.0, emr-6.0.0
	c5n.4xlarge	emr-5.29.0, emr-6.0.0
	c5n.9xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5n.18xlarge	emr-5.29.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.29.0, emr-6.0.0
	r5.2xlarge	emr-5.29.0, emr-6.0.0
	r5.4xlarge	emr-5.29.0, emr-6.0.0
	r5.8xlarge	emr-5.29.0, emr-6.0.0
	r5.12xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5.16xlarge	emr-5.29.0, emr-6.0.0
	r5.24xlarge	emr-5.29.0, emr-6.0.0
	r5a.xlarge	emr-5.29.0, emr-6.0.0
	r5a.2xlarge	emr-5.29.0, emr-6.0.0
	r5a.4xlarge	emr-5.29.0, emr-6.0.0
	r5a.8xlarge	emr-5.29.0, emr-6.0.0
	r5a.12xlarge	emr-5.29.0, emr-6.0.0
	r5a.16xlarge	emr-5.29.0, emr-6.0.0
	r5a.24xlarge	emr-5.29.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.29.0, emr-6.0.0
	r5d.2xlarge	emr-5.29.0, emr-6.0.0
	r5d.4xlarge	emr-5.29.0, emr-6.0.0
	r5d.8xlarge	emr-5.29.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.12xlarge	emr-5.29.0, emr-6.0.0
	r5d.16xlarge	emr-5.29.0, emr-6.0.0
	r5d.24xlarge	emr-5.29.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.29.0, emr-6.0.0
	d2.2xlarge	emr-5.29.0, emr-6.0.0
	d2.4xlarge	emr-5.29.0, emr-6.0.0
	d2.8xlarge	emr-5.29.0, emr-6.0.0
	i3.xlarge	emr-5.29.0, emr-6.0.0
	i3.2xlarge	emr-5.29.0, emr-6.0.0
	i3.4xlarge	emr-5.29.0, emr-6.0.0
	i3.8xlarge	emr-5.29.0, emr-6.0.0
	i3.16xlarge	emr-5.29.0, emr-6.0.0
	i3en.xlarge	emr-5.29.0, emr-6.0.0
	i3en.2xlarge	emr-5.29.0, emr-6.0.0
	i3en.3xlarge	emr-5.29.0, emr-6.0.0
	i3en.6xlarge	emr-5.29.0, emr-6.0.0
	i3en.12xlarge	emr-5.29.0, emr-6.0.0
	i3en.24xlarge	emr-5.29.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Europa (Spanien) – eu-south-2

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.36.0, emr-6.7.0
	m5.2xlarge	emr-5.36.0, emr-6.7.0
	m5.4xlarge	emr-5.36.0, emr-6.7.0
	m5.8xlarge	emr-5.36.0, emr-6.7.0
	m5.12xlarge	emr-5.36.0, emr-6.7.0
	m5.16xlarge	emr-5.36.0, emr-6.7.0
	m5.24xlarge	emr-5.36.0, emr-6.7.0
	m5d.xlarge	emr-5.36.0, emr-6.7.0
	m5d.2xlarge	emr-5.36.0, emr-6.7.0
	m5d.4xlarge	emr-5.36.0, emr-6.7.0
	m5d.8xlarge	emr-5.36.0, emr-6.7.0
	m5d.12xlarge	emr-5.36.0, emr-6.7.0
	m5d.16xlarge	emr-5.36.0, emr-6.7.0
	m5d.24xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.xlarge	emr-5.36.0, emr-6.7.0
	m6g.2xlarge	emr-5.36.0, emr-6.7.0
	m6g.4xlarge	emr-5.36.0, emr-6.7.0
	m6g.8xlarge	emr-5.36.0, emr-6.7.0
	m6g.12xlarge	emr-5.36.0, emr-6.7.0
	m6g.16xlarge	emr-5.36.0, emr-6.7.0
	m6gd.xlarge	emr-5.36.0, emr-6.7.0
	m6gd.2xlarge	emr-5.36.0, emr-6.7.0
	m6gd.4xlarge	emr-5.36.0, emr-6.7.0
	m6gd.8xlarge	emr-5.36.0, emr-6.7.0
	m6gd.12xlarge	emr-5.36.0, emr-6.7.0
	m6gd.16xlarge	emr-5.36.0, emr-6.7.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.36.0, emr-6.7.0
	c5.2xlarge	emr-5.36.0, emr-6.7.0
	c5.4xlarge	emr-5.36.0, emr-6.7.0
	c5.9xlarge	emr-5.36.0, emr-6.7.0
	c5.12xlarge	emr-5.36.0, emr-6.7.0
	c5.18xlarge	emr-5.36.0, emr-6.7.0
	c5.24xlarge	emr-5.36.0, emr-6.7.0
	c5d.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.2xlarge	emr-5.36.0, emr-6.7.0
	c5d.4xlarge	emr-5.36.0, emr-6.7.0
	c5d.9xlarge	emr-5.36.0, emr-6.7.0
	c5d.12xlarge	emr-5.36.0, emr-6.7.0
	c5d.18xlarge	emr-5.36.0, emr-6.7.0
	c5d.24xlarge	emr-5.36.0, emr-6.7.0
	c6g.xlarge	emr-5.36.0, emr-6.7.0
	c6g.2xlarge	emr-5.36.0, emr-6.7.0
	c6g.4xlarge	emr-5.36.0, emr-6.7.0
	c6g.8xlarge	emr-5.36.0, emr-6.7.0
	c6g.12xlarge	emr-5.36.0, emr-6.7.0
	c6g.16xlarge	emr-5.36.0, emr-6.7.0
RAM-optimiert	r5.xlarge	emr-5.36.0, emr-6.7.0
	r5.2xlarge	emr-5.36.0, emr-6.7.0
	r5.4xlarge	emr-5.36.0, emr-6.7.0
	r5.8xlarge	emr-5.36.0, emr-6.7.0
	r5.12xlarge	emr-5.36.0, emr-6.7.0
	r5.16xlarge	emr-5.36.0, emr-6.7.0
	r5.24xlarge	emr-5.36.0, emr-6.7.0
	r5d.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.2xlarge	emr-5.36.0, emr-6.7.0
	r5d.4xlarge	emr-5.36.0, emr-6.7.0
	r5d.8xlarge	emr-5.36.0, emr-6.7.0
	r5d.12xlarge	emr-5.36.0, emr-6.7.0
	r5d.16xlarge	emr-5.36.0, emr-6.7.0
	r5d.24xlarge	emr-5.36.0, emr-6.7.0
	r6g.xlarge	emr-5.36.0, emr-6.7.0
	r6g.2xlarge	emr-5.36.0, emr-6.7.0
	r6g.4xlarge	emr-5.36.0, emr-6.7.0
	r6g.8xlarge	emr-5.36.0, emr-6.7.0
	r6g.12xlarge	emr-5.36.0, emr-6.7.0
	r6g.16xlarge	emr-5.36.0, emr-6.7.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	i3.xlarge	emr-5.36.0, emr-6.7.0
	i3.2xlarge	emr-5.36.0, emr-6.7.0
	i3.4xlarge	emr-5.36.0, emr-6.7.0
	i3.8xlarge	emr-5.36.0, emr-6.7.0
	i3.16xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.xlarge	emr-5.36.0, emr-6.7.0
	i3en.2xlarge	emr-5.36.0, emr-6.7.0
	i3en.3xlarge	emr-5.36.0, emr-6.7.0
	i3en.6xlarge	emr-5.36.0, emr-6.7.0
	i3en.12xlarge	emr-5.36.0, emr-6.7.0
	i3en.24xlarge	emr-5.36.0, emr-6.7.0

Europa (Paris) – eu-west-3

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5.4xlarge	emr-5.13.0, emr-6.0.0
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-4.9.2, emr-5.5.3, emr-6.0.0
	d2.2xlarge	emr-4.9.2, emr-5.5.3, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	d2.4xlarge	emr-4.9.2, emr-5.5.3, emr-6.0.0
	d2.8xlarge	emr-4.9.2, emr-5.5.3, emr-6.0.0
	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	im4gn.xlarge	emr-5.35.0, emr-6.6.0
	im4gn.2xlarge	emr-5.35.0, emr-6.6.0
	im4gn.4xlarge	emr-5.35.0, emr-6.6.0
	im4gn.8xlarge	emr-5.35.0, emr-6.6.0
	im4gn.16xlarge	emr-5.35.0, emr-6.6.0
	is4gen.xlarge	emr-5.35.0, emr-6.6.0
	is4gen.2xlarge	emr-5.35.0, emr-6.6.0
	is4gen.4xlarge	emr-5.35.0, emr-6.6.0
	is4gen.8xlarge	emr-5.35.0, emr-6.6.0

Europa (Stockholm) – eu-north-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.17.0, emr-6.0.0
	m5.2xlarge	emr-5.17.0, emr-6.0.0
	m5.4xlarge	emr-5.17.0, emr-6.0.0
	m5.8xlarge	emr-5.17.0, emr-6.0.0
	m5.12xlarge	emr-5.17.0, emr-6.0.0
	m5.16xlarge	emr-5.17.0, emr-6.0.0
	m5.24xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.xlarge	emr-5.17.0, emr-6.0.0
	m5d.2xlarge	emr-5.17.0, emr-6.0.0
	m5d.4xlarge	emr-5.17.0, emr-6.0.0
	m5d.8xlarge	emr-5.17.0, emr-6.0.0
	m5d.12xlarge	emr-5.17.0, emr-6.0.0
	m5d.16xlarge	emr-5.17.0, emr-6.0.0
	m5d.24xlarge	emr-5.17.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6gd.xlarge	emr-5.33.0, emr-6.3.0
	m6gd.2xlarge	emr-5.33.0, emr-6.3.0
	m6gd.4xlarge	emr-5.33.0, emr-6.3.0
	m6gd.8xlarge	emr-5.33.0, emr-6.3.0
	m6gd.12xlarge	emr-5.33.0, emr-6.3.0
	m6gd.16xlarge	emr-5.33.0, emr-6.3.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.17.0, emr-6.0.0
	c5.2xlarge	emr-5.17.0, emr-6.0.0
	c5.4xlarge	emr-5.17.0, emr-6.0.0
	c5.9xlarge	emr-5.17.0, emr-6.0.0
	c5.12xlarge	emr-5.17.0, emr-6.0.0
	c5.18xlarge	emr-5.17.0, emr-6.0.0
	c5.24xlarge	emr-5.17.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5d.xlarge	emr-5.17.0, emr-6.0.0
	c5d.2xlarge	emr-5.17.0, emr-6.0.0
	c5d.4xlarge	emr-5.17.0, emr-6.0.0
	c5d.9xlarge	emr-5.17.0, emr-6.0.0
	c5d.12xlarge	emr-5.17.0, emr-6.0.0
	c5d.18xlarge	emr-5.17.0, emr-6.0.0
	c5d.24xlarge	emr-5.17.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.48xlarge	emr-5.36.1, emr-6.9.0
RAM-optimiert	r5.xlarge	emr-5.17.0, emr-6.0.0
	r5.2xlarge	emr-5.17.0, emr-6.0.0
	r5.4xlarge	emr-5.17.0, emr-6.0.0
	r5.8xlarge	emr-5.17.0, emr-6.0.0
	r5.12xlarge	emr-5.17.0, emr-6.0.0
	r5.16xlarge	emr-5.17.0, emr-6.0.0
	r5.24xlarge	emr-5.17.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.17.0, emr-6.0.0
	r5d.2xlarge	emr-5.17.0, emr-6.0.0
	r5d.4xlarge	emr-5.17.0, emr-6.0.0
	r5d.8xlarge	emr-5.17.0, emr-6.0.0
	r5d.12xlarge	emr-5.17.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.17.0, emr-6.0.0
	r5d.24xlarge	emr-5.17.0, emr-6.0.0
	r5dn.xlarge	emr-5.31.0, emr-6.1.0
	r5dn.2xlarge	emr-5.31.0, emr-6.1.0
	r5dn.4xlarge	emr-5.31.0, emr-6.1.0
	r5dn.8xlarge	emr-5.31.0, emr-6.1.0
	r5dn.12xlarge	emr-5.31.0, emr-6.1.0
	r5dn.16xlarge	emr-5.31.0, emr-6.1.0
	r5dn.24xlarge	emr-5.31.0, emr-6.1.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	d2.xlarge	emr-5.17.0, emr-6.0.0
	d2.2xlarge	emr-5.17.0, emr-6.0.0
	d2.4xlarge	emr-5.17.0, emr-6.0.0
	d2.8xlarge	emr-5.17.0, emr-6.0.0
	i3.xlarge	emr-5.17.0, emr-6.0.0
	i3.2xlarge	emr-5.17.0, emr-6.0.0
	i3.4xlarge	emr-5.17.0, emr-6.0.0
	i3.8xlarge	emr-5.17.0, emr-6.0.0
	i3.16xlarge	emr-5.17.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Naher Osten (Bahrain) – me-south-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.24.0, emr-6.0.0
	m5.2xlarge	emr-5.24.0, emr-6.0.0
	m5.4xlarge	emr-5.24.0, emr-6.0.0
	m5.8xlarge	emr-5.24.0, emr-6.0.0
	m5.12xlarge	emr-5.24.0, emr-6.0.0
	m5.16xlarge	emr-5.24.0, emr-6.0.0
	m5.24xlarge	emr-5.24.0, emr-6.0.0
	m5d.xlarge	emr-5.24.0, emr-6.0.0
	m5d.2xlarge	emr-5.24.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5d.4xlarge	emr-5.24.0, emr-6.0.0
	m5d.8xlarge	emr-5.24.0, emr-6.0.0
	m5d.12xlarge	emr-5.24.0, emr-6.0.0
	m5d.16xlarge	emr-5.24.0, emr-6.0.0
	m5d.24xlarge	emr-5.24.0, emr-6.0.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.24.0, emr-6.0.0
	c5.2xlarge	emr-5.24.0, emr-6.0.0
	c5.4xlarge	emr-5.24.0, emr-6.0.0
	c5.9xlarge	emr-5.24.0, emr-6.0.0
	c5.12xlarge	emr-5.24.0, emr-6.0.0
	c5.18xlarge	emr-5.24.0, emr-6.0.0
	c5.24xlarge	emr-5.24.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.24.0, emr-6.0.0
	c5d.2xlarge	emr-5.24.0, emr-6.0.0
	c5d.4xlarge	emr-5.24.0, emr-6.0.0
	c5d.9xlarge	emr-5.24.0, emr-6.0.0
	c5d.18xlarge	emr-5.24.0, emr-6.0.0
	c5n.xlarge	emr-5.24.0, emr-6.0.0
	c5n.2xlarge	emr-5.24.0, emr-6.0.0
	c5n.4xlarge	emr-5.24.0, emr-6.0.0
	c5n.9xlarge	emr-5.24.0, emr-6.0.0
	c5n.18xlarge	emr-5.24.0, emr-6.0.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
RAM-optimiert	r5.xlarge	emr-5.24.0, emr-6.0.0
	r5.2xlarge	emr-5.24.0, emr-6.0.0
	r5.4xlarge	emr-5.24.0, emr-6.0.0
	r5.8xlarge	emr-5.24.0, emr-6.0.0
	r5.12xlarge	emr-5.24.0, emr-6.0.0
	r5.16xlarge	emr-5.24.0, emr-6.0.0
	r5.24xlarge	emr-5.24.0, emr-6.0.0
	r5d.xlarge	emr-5.24.0, emr-6.0.0
	r5d.2xlarge	emr-5.24.0, emr-6.0.0
	r5d.4xlarge	emr-5.24.0, emr-6.0.0
	r5d.8xlarge	emr-5.24.0, emr-6.0.0
	r5d.12xlarge	emr-5.24.0, emr-6.0.0
	r5d.16xlarge	emr-5.24.0, emr-6.0.0
	r5d.24xlarge	emr-5.24.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
Speicheroptimiert	d2.xlarge	emr-5.24.0, emr-6.0.0
	d2.2xlarge	emr-5.24.0, emr-6.0.0
	d2.4xlarge	emr-5.24.0, emr-6.0.0
	d2.8xlarge	emr-5.24.0, emr-6.0.0
	i3.xlarge	emr-5.24.0, emr-6.0.0
	i3.2xlarge	emr-5.24.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i3.4xlarge	emr-5.24.0, emr-6.0.0
	i3.8xlarge	emr-5.24.0, emr-6.0.0
	i3.16xlarge	emr-5.24.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Naher Osten (VAE) – me-central-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5.2xlarge	emr-5.36.0, emr-6.7.0
	m5.4xlarge	emr-5.36.0, emr-6.7.0
	m5.8xlarge	emr-5.36.0, emr-6.7.0
	m5.12xlarge	emr-5.36.0, emr-6.7.0
	m5.16xlarge	emr-5.36.0, emr-6.7.0
	m5.24xlarge	emr-5.36.0, emr-6.7.0
	m5d.xlarge	emr-5.36.0, emr-6.7.0
	m5d.2xlarge	emr-5.36.0, emr-6.7.0
	m5d.4xlarge	emr-5.36.0, emr-6.7.0
	m5d.8xlarge	emr-5.36.0, emr-6.7.0
	m5d.12xlarge	emr-5.36.0, emr-6.7.0
	m5d.16xlarge	emr-5.36.0, emr-6.7.0
	m5d.24xlarge	emr-5.36.0, emr-6.7.0
	m6g.xlarge	emr-5.36.0, emr-6.7.0
	m6g.2xlarge	emr-5.36.0, emr-6.7.0
	m6g.4xlarge	emr-5.36.0, emr-6.7.0
	m6g.8xlarge	emr-5.36.0, emr-6.7.0
	m6g.12xlarge	emr-5.36.0, emr-6.7.0
	m6g.16xlarge	emr-5.36.0, emr-6.7.0
	m6gd.xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6gd.2xlarge	emr-5.36.0, emr-6.7.0
	m6gd.4xlarge	emr-5.36.0, emr-6.7.0
	m6gd.8xlarge	emr-5.36.0, emr-6.7.0
	m6gd.12xlarge	emr-5.36.0, emr-6.7.0
	m6gd.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.xlarge	emr-5.36.0, emr-6.7.0
	m6i.2xlarge	emr-5.36.0, emr-6.7.0
	m6i.4xlarge	emr-5.36.0, emr-6.7.0
	m6i.8xlarge	emr-5.36.0, emr-6.7.0
	m6i.12xlarge	emr-5.36.0, emr-6.7.0
	m6i.16xlarge	emr-5.36.0, emr-6.7.0
	m6i.24xlarge	emr-5.36.0, emr-6.7.0
	m6i.32xlarge	emr-5.36.0, emr-6.7.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.36.0, emr-6.7.0
	c5.2xlarge	emr-5.36.0, emr-6.7.0
	c5.4xlarge	emr-5.36.0, emr-6.7.0
	c5.9xlarge	emr-5.36.0, emr-6.7.0
	c5.12xlarge	emr-5.36.0, emr-6.7.0
	c5.18xlarge	emr-5.36.0, emr-6.7.0
	c5.24xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.xlarge	emr-5.36.0, emr-6.7.0
	c5d.2xlarge	emr-5.36.0, emr-6.7.0
	c5d.4xlarge	emr-5.36.0, emr-6.7.0
	c5d.9xlarge	emr-5.36.0, emr-6.7.0
	c5d.12xlarge	emr-5.36.0, emr-6.7.0
	c5d.18xlarge	emr-5.36.0, emr-6.7.0
	c5d.24xlarge	emr-5.36.0, emr-6.7.0
	c6g.xlarge	emr-5.36.0, emr-6.7.0
	c6g.2xlarge	emr-5.36.0, emr-6.7.0
	c6g.4xlarge	emr-5.36.0, emr-6.7.0
	c6g.8xlarge	emr-5.36.0, emr-6.7.0
	c6g.12xlarge	emr-5.36.0, emr-6.7.0
	c6g.16xlarge	emr-5.36.0, emr-6.7.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g5.xlarge	emr-5.36.1, emr-6.9.0
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
RAM-optimiert	r5.xlarge	emr-5.36.0, emr-6.7.0
	r5.2xlarge	emr-5.36.0, emr-6.7.0
	r5.4xlarge	emr-5.36.0, emr-6.7.0
	r5.8xlarge	emr-5.36.0, emr-6.7.0
	r5.12xlarge	emr-5.36.0, emr-6.7.0
	r5.16xlarge	emr-5.36.0, emr-6.7.0
	r5.24xlarge	emr-5.36.0, emr-6.7.0
	r5d.xlarge	emr-5.36.0, emr-6.7.0
	r5d.2xlarge	emr-5.36.0, emr-6.7.0
	r5d.4xlarge	emr-5.36.0, emr-6.7.0
	r5d.8xlarge	emr-5.36.0, emr-6.7.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.12xlarge	emr-5.36.0, emr-6.7.0
	r5d.16xlarge	emr-5.36.0, emr-6.7.0
	r5d.24xlarge	emr-5.36.0, emr-6.7.0
	r6g.xlarge	emr-5.36.0, emr-6.7.0
	r6g.2xlarge	emr-5.36.0, emr-6.7.0
	r6g.4xlarge	emr-5.36.0, emr-6.7.0
	r6g.8xlarge	emr-5.36.0, emr-6.7.0
	r6g.12xlarge	emr-5.36.0, emr-6.7.0
	r6g.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.xlarge	emr-5.36.0, emr-6.7.0
	r6i.2xlarge	emr-5.36.0, emr-6.7.0
	r6i.4xlarge	emr-5.36.0, emr-6.7.0
	r6i.8xlarge	emr-5.36.0, emr-6.7.0
	r6i.12xlarge	emr-5.36.0, emr-6.7.0
	r6i.16xlarge	emr-5.36.0, emr-6.7.0
	r6i.24xlarge	emr-5.36.0, emr-6.7.0
	r6i.32xlarge	emr-5.36.0, emr-6.7.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Speicheroptimiert	i3.xlarge	emr-5.36.0, emr-6.7.0
	i3.2xlarge	emr-5.36.0, emr-6.7.0
	i3.4xlarge	emr-5.36.0, emr-6.7.0
	i3.8xlarge	emr-5.36.0, emr-6.7.0
	i3.16xlarge	emr-5.36.0, emr-6.7.0
	i3en.xlarge	emr-5.36.0, emr-6.7.0
	i3en.2xlarge	emr-5.36.0, emr-6.7.0
	i3en.3xlarge	emr-5.36.0, emr-6.7.0
	i3en.6xlarge	emr-5.36.0, emr-6.7.0
	i3en.12xlarge	emr-5.36.0, emr-6.7.0
	i3en.24xlarge	emr-5.36.0, emr-6.7.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Südamerika (São Paulo) – sa-east-1

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
Allgemeine Zwecke	m5.xlarge	emr-5.13.0, emr-6.0.0
	m5.2xlarge	emr-5.13.0, emr-6.0.0
	m5.4xlarge	emr-5.13.0, emr-6.0.0
	m5.8xlarge	emr-5.13.0, emr-6.0.0
	m5.12xlarge	emr-5.13.0, emr-6.0.0
	m5.16xlarge	emr-5.13.0, emr-6.0.0
	m5.24xlarge	emr-5.13.0, emr-6.0.0
	m5a.xlarge	emr-5.20.0, emr-6.0.0
	m5a.2xlarge	emr-5.20.0, emr-6.0.0
	m5a.4xlarge	emr-5.20.0, emr-6.0.0
	m5a.8xlarge	emr-5.20.0, emr-6.0.0
	m5a.12xlarge	emr-5.20.0, emr-6.0.0
	m5a.16xlarge	emr-5.20.0, emr-6.0.0
	m5a.24xlarge	emr-5.20.0, emr-6.0.0
	m5ad.xlarge	emr-5.20.0, emr-6.0.0
	m5ad.2xlarge	emr-5.20.0, emr-6.0.0
	m5ad.4xlarge	emr-5.20.0, emr-6.0.0
	m5ad.8xlarge	emr-5.33.0, emr-6.3.0
	m5ad.12xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m5ad.16xlarge	emr-5.33.0, emr-6.3.0
	m5ad.24xlarge	emr-5.20.0, emr-6.0.0
	m5d.xlarge	emr-5.13.0, emr-6.0.0
	m5d.2xlarge	emr-5.13.0, emr-6.0.0
	m5d.4xlarge	emr-5.13.0, emr-6.0.0
	m5d.8xlarge	emr-5.13.0, emr-6.0.0
	m5d.12xlarge	emr-5.13.0, emr-6.0.0
	m5d.16xlarge	emr-5.13.0, emr-6.0.0
	m5d.24xlarge	emr-5.13.0, emr-6.0.0
	m5zn.xlarge	emr-5.33.0, emr-6.3.0
	m5zn.2xlarge	emr-5.33.0, emr-6.3.0
	m5zn.3xlarge	emr-5.33.0, emr-6.3.0
	m5zn.6xlarge	emr-5.33.0, emr-6.3.0
	m5zn.12xlarge	emr-5.33.0, emr-6.3.0
	m6a.xlarge	emr-5.36.1, emr-6.8.0
	m6a.2xlarge	emr-5.36.1, emr-6.8.0
	m6a.4xlarge	emr-5.36.1, emr-6.8.0
	m6a.8xlarge	emr-5.36.1, emr-6.8.0
	m6a.12xlarge	emr-5.36.1, emr-6.8.0
	m6a.16xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	m6a.24xlarge	emr-5.36.1, emr-6.8.0
	m6a.32xlarge	emr-5.36.1, emr-6.8.0
	m6a.48xlarge	emr-5.36.1, emr-6.8.0
	m6g.xlarge	emr-5.30.0, emr-6.1.0
	m6g.2xlarge	emr-5.30.0, emr-6.1.0
	m6g.4xlarge	emr-5.30.0, emr-6.1.0
	m6g.8xlarge	emr-5.30.0, emr-6.1.0
	m6g.12xlarge	emr-5.30.0, emr-6.1.0
	m6g.16xlarge	emr-5.30.0, emr-6.1.0
	m6i.xlarge	emr-5.35.0, emr-6.6.0
	m6i.2xlarge	emr-5.35.0, emr-6.6.0
	m6i.4xlarge	emr-5.35.0, emr-6.6.0
	m6i.8xlarge	emr-5.35.0, emr-6.6.0
	m6i.12xlarge	emr-5.35.0, emr-6.6.0
	m6i.16xlarge	emr-5.35.0, emr-6.6.0
	m6i.24xlarge	emr-5.35.0, emr-6.6.0
	m6i.32xlarge	emr-5.35.0, emr-6.6.0
Für Datenverarbeitung optimiert	c5.xlarge	emr-5.13.0, emr-6.0.0
	c5.2xlarge	emr-5.13.0, emr-6.0.0
	c5.4xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5.9xlarge	emr-5.13.0, emr-6.0.0
	c5.12xlarge	emr-5.13.0, emr-6.0.0
	c5.18xlarge	emr-5.13.0, emr-6.0.0
	c5.24xlarge	emr-5.13.0, emr-6.0.0
	c5a.xlarge	emr-5.31.0, emr-6.1.0
	c5a.2xlarge	emr-5.31.0, emr-6.1.0
	c5a.4xlarge	emr-5.31.0, emr-6.1.0
	c5a.8xlarge	emr-5.31.0, emr-6.1.0
	c5a.12xlarge	emr-5.31.0, emr-6.1.0
	c5a.16xlarge	emr-5.31.0, emr-6.1.0
	c5a.24xlarge	emr-5.31.0, emr-6.1.0
	c5ad.xlarge	emr-5.33.0, emr-6.3.0
	c5ad.2xlarge	emr-5.33.0, emr-6.3.0
	c5ad.4xlarge	emr-5.33.0, emr-6.3.0
	c5ad.8xlarge	emr-5.33.0, emr-6.3.0
	c5ad.12xlarge	emr-5.33.0, emr-6.3.0
	c5ad.16xlarge	emr-5.33.0, emr-6.3.0
	c5ad.24xlarge	emr-5.33.0, emr-6.3.0
	c5d.xlarge	emr-5.13.0, emr-6.0.0
	c5d.2xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c5d.4xlarge	emr-5.13.0, emr-6.0.0
	c5d.9xlarge	emr-5.13.0, emr-6.0.0
	c5d.12xlarge	emr-5.13.0, emr-6.0.0
	c5d.18xlarge	emr-5.13.0, emr-6.0.0
	c5d.24xlarge	emr-5.13.0, emr-6.0.0
	c5n.xlarge	emr-5.20.0, emr-6.0.0
	c5n.2xlarge	emr-5.20.0, emr-6.0.0
	c5n.4xlarge	emr-5.20.0, emr-6.0.0
	c5n.9xlarge	emr-5.20.0, emr-6.0.0
	c5n.18xlarge	emr-5.20.0, emr-6.0.0
	c6a.xlarge	emr-5.36.1, emr-6.8.0
	c6a.2xlarge	emr-5.36.1, emr-6.8.0
	c6a.4xlarge	emr-5.36.1, emr-6.8.0
	c6a.8xlarge	emr-5.36.1, emr-6.8.0
	c6a.12xlarge	emr-5.36.1, emr-6.8.0
	c6a.16xlarge	emr-5.36.1, emr-6.8.0
	c6a.24xlarge	emr-5.36.1, emr-6.8.0
	c6a.32xlarge	emr-5.36.1, emr-6.8.0
	c6a.48xlarge	emr-5.36.1, emr-6.8.0
	c6g.xlarge	emr-5.31.0, emr-6.1.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6g.2xlarge	emr-5.31.0, emr-6.1.0
	c6g.4xlarge	emr-5.31.0, emr-6.1.0
	c6g.8xlarge	emr-5.31.0, emr-6.1.0
	c6g.12xlarge	emr-5.31.0, emr-6.1.0
	c6g.16xlarge	emr-5.31.0, emr-6.1.0
	c6gd.xlarge	emr-5.33.0, emr-6.3.0
	c6gd.2xlarge	emr-5.33.0, emr-6.3.0
	c6gd.4xlarge	emr-5.33.0, emr-6.3.0
	c6gd.8xlarge	emr-5.33.0, emr-6.3.0
	c6gd.12xlarge	emr-5.33.0, emr-6.3.0
	c6gd.16xlarge	emr-5.33.0, emr-6.3.0
	c6gn.xlarge	emr-5.33.0, emr-6.3.0
	c6gn.2xlarge	emr-5.33.0, emr-6.3.0
	c6gn.4xlarge	emr-5.33.0, emr-6.3.0
	c6gn.8xlarge	emr-5.33.0, emr-6.3.0
	c6gn.12xlarge	emr-5.33.0, emr-6.3.0
	c6gn.16xlarge	emr-5.33.0, emr-6.3.0
	c6i.xlarge	emr-5.35.0, emr-6.6.0
	c6i.2xlarge	emr-5.35.0, emr-6.6.0
	c6i.4xlarge	emr-5.35.0, emr-6.6.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	c6i.8xlarge	emr-5.35.0, emr-6.6.0
	c6i.12xlarge	emr-5.35.0, emr-6.6.0
	c6i.16xlarge	emr-5.35.0, emr-6.6.0
	c6i.24xlarge	emr-5.35.0, emr-6.6.0
	c6i.32xlarge	emr-5.35.0, emr-6.6.0
	c6in.xlarge	emr-5.36.1, emr-6.10.0
	c6in.2xlarge	emr-5.36.1, emr-6.10.0
	c6in.4xlarge	emr-5.36.1, emr-6.10.0
	c6in.8xlarge	emr-5.36.1, emr-6.10.0
	c6in.12xlarge	emr-5.36.1, emr-6.10.0
	c6in.16xlarge	emr-5.36.1, emr-6.10.0
	c6in.24xlarge	emr-5.36.1, emr-6.10.0
	c6in.32xlarge	emr-5.36.1, emr-6.10.0
Beschleunigte Datenverarbeitung	g4dn.xlarge	emr-5.30.0, emr-6.0.0
	g4dn.2xlarge	emr-5.30.0, emr-6.0.0
	g4dn.4xlarge	emr-5.30.0, emr-6.0.0
	g4dn.8xlarge	emr-5.30.0, emr-6.0.0
	g4dn.12xlarge	emr-5.30.0, emr-6.0.0
	g4dn.16xlarge	emr-5.30.0, emr-6.0.0
	g5.xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	g5.2xlarge	emr-5.36.1, emr-6.9.0
	g5.4xlarge	emr-5.36.1, emr-6.9.0
	g5.8xlarge	emr-5.36.1, emr-6.9.0
	g5.12xlarge	emr-5.36.1, emr-6.9.0
	g5.16xlarge	emr-5.36.1, emr-6.9.0
	g5.24xlarge	emr-5.36.1, emr-6.9.0
	g5.48xlarge	emr-5.36.1, emr-6.9.0
RAM-optimiert	r5.xlarge	emr-5.13.0, emr-6.0.0
	r5.2xlarge	emr-5.13.0, emr-6.0.0
	r5.4xlarge	emr-5.13.0, emr-6.0.0
	r5.8xlarge	emr-5.13.0, emr-6.0.0
	r5.12xlarge	emr-5.13.0, emr-6.0.0
	r5.16xlarge	emr-5.13.0, emr-6.0.0
	r5.24xlarge	emr-5.13.0, emr-6.0.0
	r5a.xlarge	emr-5.20.0, emr-6.0.0
	r5a.2xlarge	emr-5.20.0, emr-6.0.0
	r5a.4xlarge	emr-5.20.0, emr-6.0.0
	r5a.8xlarge	emr-5.20.0, emr-6.0.0
	r5a.12xlarge	emr-5.20.0, emr-6.0.0
	r5a.16xlarge	emr-5.20.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5a.24xlarge	emr-5.20.0, emr-6.0.0
	r5ad.xlarge	emr-5.20.0, emr-6.0.0
	r5ad.2xlarge	emr-5.20.0, emr-6.0.0
	r5ad.4xlarge	emr-5.20.0, emr-6.0.0
	r5ad.8xlarge	emr-5.33.0, emr-6.3.0
	r5ad.12xlarge	emr-5.20.0, emr-6.0.0
	r5ad.16xlarge	emr-5.33.0, emr-6.3.0
	r5ad.24xlarge	emr-5.20.0, emr-6.0.0
	r5b.xlarge	emr-5.33.0, emr-6.3.0
	r5b.2xlarge	emr-5.33.0, emr-6.3.0
	r5b.4xlarge	emr-5.33.0, emr-6.3.0
	r5b.8xlarge	emr-5.33.0, emr-6.3.0
	r5b.12xlarge	emr-5.33.0, emr-6.3.0
	r5b.16xlarge	emr-5.33.0, emr-6.3.0
	r5b.24xlarge	emr-5.33.0, emr-6.3.0
	r5d.xlarge	emr-5.13.0, emr-6.0.0
	r5d.2xlarge	emr-5.13.0, emr-6.0.0
	r5d.4xlarge	emr-5.13.0, emr-6.0.0
	r5d.8xlarge	emr-5.13.0, emr-6.0.0
	r5d.12xlarge	emr-5.13.0, emr-6.0.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r5d.16xlarge	emr-5.13.0, emr-6.0.0
	r5d.24xlarge	emr-5.13.0, emr-6.0.0
	r5n.xlarge	emr-5.31.0, emr-6.1.0
	r5n.2xlarge	emr-5.31.0, emr-6.1.0
	r5n.4xlarge	emr-5.31.0, emr-6.1.0
	r5n.8xlarge	emr-5.31.0, emr-6.1.0
	r5n.12xlarge	emr-5.31.0, emr-6.1.0
	r5n.16xlarge	emr-5.31.0, emr-6.1.0
	r5n.24xlarge	emr-5.31.0, emr-6.1.0
	r6g.xlarge	emr-5.31.0, emr-6.1.0
	r6g.2xlarge	emr-5.31.0, emr-6.1.0
	r6g.4xlarge	emr-5.31.0, emr-6.1.0
	r6g.8xlarge	emr-5.31.0, emr-6.1.0
	r6g.12xlarge	emr-5.31.0, emr-6.1.0
	r6g.16xlarge	emr-5.31.0, emr-6.1.0
	r6gd.xlarge	emr-5.33.0, emr-6.3.0
	r6gd.2xlarge	emr-5.33.0, emr-6.3.0
	r6gd.4xlarge	emr-5.33.0, emr-6.3.0
	r6gd.8xlarge	emr-5.33.0, emr-6.3.0
	r6gd.12xlarge	emr-5.33.0, emr-6.3.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	r6gd.16xlarge	emr-5.33.0, emr-6.3.0
	r6i.xlarge	emr-5.35.0, emr-6.6.0
	r6i.2xlarge	emr-5.35.0, emr-6.6.0
	r6i.4xlarge	emr-5.35.0, emr-6.6.0
	r6i.8xlarge	emr-5.35.0, emr-6.6.0
	r6i.12xlarge	emr-5.35.0, emr-6.6.0
	r6i.16xlarge	emr-5.35.0, emr-6.6.0
	r6i.24xlarge	emr-5.35.0, emr-6.6.0
	r6i.32xlarge	emr-5.35.0, emr-6.6.0
	x1.16xlarge	emr-5.36.1, emr-6.9.0
	x1.32xlarge	emr-5.36.1, emr-6.9.0
	x1e.xlarge	emr-5.36.1, emr-6.10.0
	x1e.2xlarge	emr-5.36.1, emr-6.10.0
	x1e.4xlarge	emr-5.36.1, emr-6.10.0
	x1e.8xlarge	emr-5.36.1, emr-6.10.0
	x1e.16xlarge	emr-5.36.1, emr-6.10.0
	x1e.32xlarge	emr-5.36.1, emr-6.10.0
	x2idn.16xlarge	emr-5.36.1, emr-6.9.0
	x2idn.24xlarge	emr-5.36.1, emr-6.9.0
	x2idn.32xlarge	emr-5.36.1, emr-6.9.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	x2iedn.xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.2xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.4xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.8xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.16xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.24xlarge	emr-5.36.1, emr-6.9.0
	x2iedn.32xlarge	emr-5.36.1, emr-6.9.0
Speicheroptimiert	i3.xlarge	emr-5.9.0, emr-6.0.0
	i3.2xlarge	emr-5.9.0, emr-6.0.0
	i3.4xlarge	emr-5.9.0, emr-6.0.0
	i3.8xlarge	emr-5.9.0, emr-6.0.0
	i3.16xlarge	emr-5.9.0, emr-6.0.0
	i3en.xlarge	emr-5.25.0, emr-6.0.0
	i3en.2xlarge	emr-5.25.0, emr-6.0.0
	i3en.3xlarge	emr-5.25.0, emr-6.0.0
	i3en.6xlarge	emr-5.25.0, emr-6.0.0
	i3en.12xlarge	emr-5.25.0, emr-6.0.0
	i3en.24xlarge	emr-5.25.0, emr-6.0.0
	i4i.xlarge	emr-5.36.1, emr-6.8.0
	i4i.2xlarge	emr-5.36.1, emr-6.8.0

Instance class	Instance-Typ	Unterstützte Mindestversion von Amazon EMR
	i4i.4xlarge	emr-5.36.1, emr-6.8.0
	i4i.8xlarge	emr-5.36.1, emr-6.8.0
	i4i.16xlarge	emr-5.36.1, emr-6.8.0
	i4i.32xlarge	emr-5.36.1, emr-6.8.0

Instances der vorherigen Generation

Amazon EMR unterstützt Instances der vorherigen Generation zur Unterstützung von Anwendungen, die für diese Instances optimiert sind und noch nicht aktualisiert wurden. Weitere Informationen zu diesen Instance-Typen und Upgrade-Pfaden finden Sie unter Instances der vorherigen Generation.

Instance class	Instance-Typen
General Purpose	m1.small[1] | m1.medium[1] | m1.large[1] | m1.xlarge[1] | m3.xlarge[1] | m3.2xlarge[1] | m4.large | m4.xlarge | m4.2xlarge | m4.4xlarge | m4.10xlarge | m4.16xlarge
Compute Optimized	c1.medium[1] [2] | c1.xlarge[1] | c3.xlarge[1] | c3.2xlarge[1] | c3.4xlarge[1] | c3.8xlarge[1] | c4.large | c4.xlarge | c4.2xlarge | c4.4xlarge | c4.8xlarge
GPU Optimized	g2.2xlarge
Memory Optimized	m2.xlarge[1] | m2.2xlarge[1] | m2.4xlarge[1] | r3.xlarge | r3.2xlarge | r3.4xlarge | r3.8xlarge | r4.xlarge | r4.2xlarge | r4.4xlarge | r4.8xlarge | r4.16xlarge
Storage Optimized	i2.xlarge | i2.2xlarge | i2.4xlarge | i2.8xlarge

[1] Verwendet das PVM-Virtualisierungs-AMI mit Amazon-EMR-Versionen vor 5.13.0. Weitere Informationen finden Sie unter Linux-AMI-Virtualisierungstypen.

² Nicht unterstützt in Version 5.15.0.

Instance-Kaufoptionen

Wenn Sie einen Cluster einrichten, wählen Sie eine Kaufoption für Amazon-EC2-Instances aus. Sie können On-Demand-Instances, Spot Instances oder beides auswählen. Die Preise variieren basierend auf dem Instance-Typ und der Region. Der Amazon-EMR-Preis gilt zusätzlich zum Amazon-EC2-Preis (der Preis für die zugrunde liegenden Server) und zum Amazon-EBS-Preis (wenn Amazon-EBS-Volumes angehängt werden). Aktuelle Preisangaben finden Sie unter Amazon-EMR-Preise.

Ihre Wahl zur Verwendung von Instance-Gruppen oder Instance-Flotten in Ihrem Cluster bestimmt, wie Sie die Instance-Kaufoptionen ändern können, während der Cluster ausgeführt wird. Wenn Sie einheitliche Instance-Gruppen auswählen, können Sie die Kaufoption für eine Instance-Gruppe nur beim Erstellen angeben, und der Instance-Typ und die Kaufoption gelten für alle Amazon-EC2-Instances in jeder Instance-Gruppe. Bei der Wahl von Instance-Flotten können Sie die Kaufoptionen ändern, nachdem eine Instance-Flotte erstellt wurde. Sie können die Kaufoptionen kombinieren, um eine festgelegte Zielkapazität zu erfüllen. Weitere Informationen zu diesen Konfigurationen finden Sie unter Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen.

On-Demand Instances

Bei On-Demand-Instances zahlen Sie für die Rechenkapazität nach Sekunde. Optional können Sie für diese On-Demand-Instances Reserved Instance- oder Dedicated Instance-Kaufoptionen verwenden. Bei Reserved Instances leisten Sie eine einmalige Zahlung für eine Instance, um Kapazität zu reservieren. Dedicated Instances sind auf der Host-Hardwareebene physisch von Instances isoliert, die zu anderen AWS-Konten gehören. Weitere Informationen zu Kaufoptionen finden Sie unter Instance-Kaufoptionen im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Verwenden von Reserved Instances

Um Reserved Instances in Amazon EMR zu verwenden, kaufen Sie die Reserved Instance über Amazon EC2 und geben die Parameter für die Reservierung an, einschließlich des Umfangs der Reservierung für eine Region oder Availability Zone. Weitere Informationen finden Sie unter Amazon EC2 Reserved Instances und Kaufen von Reserved Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Nachdem Sie eine Reserved Instance gekauft haben, verwendet Amazon EMR die Reserved Instance, wenn ein Cluster startet und alle der folgenden Bedingungen erfüllt sind:

- Eine On-Demand-Instance ist in der Cluster-Konfiguration angegeben, die mit der Reserved-Instance-Spezifikation übereinstimmt.

- Der Cluster wird im Rahmen der Instance-Reservierung (Availability Zone oder Region) gestartet.
- Die Reserved Instance-Kapazität ist noch verfügbar.

Angenommen, Sie kaufen eine Reserved Instance `m5.xlarge` mit der gewünschten Instance-Reservierung für die Region USA Ost. Anschließend starten Sie einen Amazon-EMR-Cluster in USA Ost, der zwei `m5.xlarge`-Instances verwendet. Die erste Instance wird nach dem Tarif für Reserved Instances abgerechnet und die andere nach dem On-Demand-Tarif. Die Reserved Instance-Kapazität wird verwendet, bevor die On-Demand-Instances erstellt werden.

Verwenden von Dedicated Instances

Um Dedicated Instances zu verwenden, kaufen Sie Dedicated Instances über Amazon EC2 und erstellen dann eine VPC mit dem Tenancy-Attribut Dedicated. Anschließend geben Sie in Amazon EMR an, dass ein Cluster in dieser VPC gestartet werden soll. Alle On-Demand-Instances im Cluster, die der Dedicated Instance-Spezifikation entsprechen, verwenden verfügbare Dedicated Instances beim Start des Clusters.

> **Note**
>
> Amazon EMR unterstützt das `dedicated` Attribut für einzelne Instances nicht.

Spot-Instances

Spot Instances in Amazon EMR ermöglichen Ihnen den Kauf von Amazon-EC2-Instance-Kapazitäten zu einem im Vergleich zu On-Demand-Käufen niedrigeren Preis. Der Nachteil der Verwendung von Spot Instances besteht darin, dass Instances möglicherweise beendet werden, wenn die Spot-Kapazität für den von Ihnen ausgeführten Instance-Typ nicht mehr verfügbar ist. Weitere Informationen dazu, wann Sie Spot Instances für Ihre Anwendung verwenden sollten, finden Sie unter Wann sollten Sie Spot Instances verwenden?.

Wenn Amazon EC2 über ungenutzte Kapazitäten verfügt, werden EC2-Instances zu einem niedrigeren Preis angeboten, dem Spot-Preis. Dieser Preis schwankt abhängig von Verfügbarkeit und Bedarf und wird nach Region und Availability Zone festgelegt. Wenn Sie Spot-Instances auswählen, geben Sie den maximalen Spot-Preis an, den Sie bereit sind für jeden EC2 Instance-Typ zu zahlen. Wenn der Spot-Preis in der Availability Zone des Clusters unter dem für diesen Instance-Typ angegebenen maximalen Spot-Preis liegt, werden Instances gestartet. Während die Instances

ausgeführt werden, wird Ihnen der aktuelle Spot-Preis nicht Ihr maximaler Spot-Preis in Rechnung gestellt.

> **Note**
>
> Spot-Instances mit definierter Laufzeit (auch Spot-Blöcke genannt) stehen Neukunden ab dem 1. Juli 2021 nicht mehr zur Verfügung. Für Kunden, die diese Funktion bereits genutzt haben, werden wir Spot-Instances mit einer definierten Laufzeit bis zum 31. Dezember 2022 weiterhin unterstützen.

Die aktuellen Preise finden Sie im Abschnitt Preise für Spot Instances in Amazon EC2. Weitere Informationen dazu finden Sie unter Spot-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Wenn Sie einen Cluster erstellen und konfigurieren, geben Sie Netzwerkoptionen an, die letztendlich die Availability Zone bestimmen, in der Ihr Cluster gestartet wird. Weitere Informationen finden Sie unter Netzwerk konfigurieren.

> **Tip**
>
> Sie können den aktuellen Spot-Preis in der Konsole anzeigen, indem Sie mit dem Mauszeiger auf die QuickInfo für Informationen neben der Kaufoption Spot (Spot) zeigen, wenn Sie einen Cluster mittels Advanced Options (Erweiterte Optionen) erstellen. Die Preise für jede Availability Zone in der ausgewählten Region werden angezeigt. Die grünen Zeilen enthalten die niedrigsten Preise. Aufgrund der Spot-Preisschwankungen zwischen Availability Zones kann es sein, dass durch Auswählen der Availability Zone mit dem niedrigsten Anfangspreis möglicherweise nicht der niedrigste Preis für die Nutzungsdauer des Clusters erzielt wird. Um optimale Ergebnisse zu erzielen, sehen Sie sich den Availability Zone-Preisverlauf an, bevor Sie sich entscheiden. Weitere Informationen finden Sie unter Benachrichtigungen über Spot Instance-Unterbrechungen im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Die Spot-Instance-Optionen hängen davon ab, ob Sie einheitliche Instance-Gruppen oder Instance-Flotten in der Cluster-Konfiguration verwenden.

Spot-Instances in einheitlichen Instance-Gruppen

Wenn Sie Spot-Instances in einer einheitlichen Instance-Gruppe verwenden, muss es sich bei allen Instances in der Instance-Gruppe um Spot-Instances handeln. Sie geben ein einzelnes Subnetz

eine oder Availability Zone für den Cluster an. Für jede Instance-Gruppe legen Sie eine einzelne Spot Instance und einen maximalen Spot-Preis fest. Die Spot Instances des entsprechenden Typs werden gestartet, wenn der Spot-Preis in der Region und Availability Zone des Clusters unter dem maximalen Spot-Preis liegt. Instances werden beendet, wenn der Spot-Preis Ihren maximalen Spot-Preis übersteigt. Sie legen den maximalen Spot-Preis nur beim Konfigurieren einer Instance-Gruppe fest. Er kann später nicht mehr geändert werden. Weitere Informationen finden Sie unter Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen.

Spot-Instances in Instance-Flotten

Wenn Sie die Instance-Flottenkonfiguration verwenden, erhalten Sie durch zusätzliche Optionen mehr Kontrolle darüber, wie Spot-Instances gestartet und beendet werden. Grundsätzlich verwenden Instance-Flotten zum Starten von Instances eine andere Methode als einheitliche Instance-Gruppen. Hierbei legen Sie eine Zielkapazität für Spot-Instances (und On-Demand-Instances) und bis zu fünf Instance-Typen fest. Sie können auch eine gewichtete Kapazität für jeden Instance-Typ festlegen oder die vCPU (YARN vcores) des Instance-Typs als gewichtete Kapazität verwenden. Die gewichtete Kapazität wird im Rahmen der Zielkapazität berücksichtigt, wenn eine Instance dieses Typs bereitgestellt wird. Amazon EMR stellt Instances mit beiden Kaufoptionen bereit, bis die Zielkapazität für jedes Ziel erfüllt ist. Darüber hinaus können Sie eine Vielzahl von Availability Zones definieren, die Amazon EMR zum Starten von Instances zur Wahl stehen. Sie stellen außerdem zusätzliche Spot-Optionen für jede Flotte bereit, einschließlich eines Bereitstellungs-Timeouts. Weitere Informationen finden Sie unter Instance-Flotten konfigurieren.

Instance-Speicher

Der Instance-Speicher und der Amazon.EBS-Volume-Speicher werden für HDFS-Daten sowie für Puffer, Caches, Arbeitsdaten und andere temporäre Inhalte verwendet, die einige Anwendungen möglicherweise in das lokale Dateisystem „verschütten“.

Amazon EBS funktioniert in Amazon EMR anders als mit regulären Amazon-EC2-Instances. An Amazon-EMR-Cluster angefügte Amazon-EMR-Volumes sind beispielsweise flüchtig: Die Volumes werden beim Beenden des Clusters und der Instance gelöscht (z. B. beim Verkleinern von Instance-Gruppen). Daher ist es wichtig, nicht davon ausgehen, dass Daten dauerhaft gespeichert werden. Obwohl die Daten flüchtig sind, ist es möglich, dass Daten in HDFS abhängig von der Anzahl und der Spezialisierung der Knoten im Cluster repliziert werden. Wenn Sie Amazon-EBS-Speichervolumes hinzufügen, werden diese als zusätzliche Volumes bereitgestellt. Sie sind nicht Teil des Startvolumes. YARN ist so konfiguriert, dass alle zusätzlichen Volumes verwendet werden. Sie sind jedoch dafür verantwortlich, die zusätzlichen Volumes als lokalen Speicher (z. B. für lokale Protokolldateien) zuzuweisen.

Weitere Einschränkungen bei der Verwendung von Amazon EBS mit Amazon-EMR-Clustern sind:

- Sie können nicht einen Snapshot eines Amazon-EBS-Volumes erstellen und dann innerhalb von Amazon EMR wiederherstellen. Um wiederverwendbare benutzerdefinierte Konfigurationen zu erstellen, verwenden Sie ein benutzerdefiniertes AMI (verfügbar ab Version 5.7.0 von Amazon EMR). Weitere Informationen finden Sie unter Verwenden eines benutzerdefinierten AMI.
- Ein verschlüsseltes Amazon-EBS-Root-Volume wird nur unterstützt, wenn Sie ein benutzerdefiniertes AMI verwenden. Weitere Informationen finden Sie unter Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon-EBS-Root-Gerät-Datenträger.
- Wenn Sie Tags mit der Amazon-EMR-Webservice-API zuweisen, werden diese Operationen auf EBS-Volumes angewendet.
- Es gilt eine Beschränkung von 25 Volumes pro Instance.
- Die Amazon-EBS-Volumes auf den Core-Knoten dürfen nicht weniger als 5 GB groß sein.

Amazon-EBS-Standardspeicher für Instances

Amazon EMR fügt automatisch ein Amazon-EBS-Allzweck-Volume SSD (gp2) mit 10 GB als Root-Gerät für die AMIs an, um die Leistung zu steigern. Darüber hinaus weist Amazon EMR für EC2-Instances mit reinem EBS-Speicher den Instances Amazon-EBS-GP2-Speichervolumes zu. Wenn Sie einen Cluster mit der Amazon-EMR-Version 5.22.0 und höher erstellen, erhöht sich die Standardmenge des Amazon-EBS-Speichers basierend auf der Größe der Instance. Wir teilen den erhöhten Speicher auf mehrere Volumes auf, was zu einer höheren IOPS-Leistung und damit wiederum zu einer höheren Leistung für einige standardisierte Workloads führt. Wenn Sie eine andere Amazon-EBS-gp2-Instance-Speicherkonfiguration verwenden möchten, können Sie diese beim Erstellen eines Amazon-EMR-Clusters bzw. beim Hinzufügen von Knoten zu einem Cluster angeben. Derzeit können Amazon-EBS-GP3-Volumes nicht als Root-Volumes in einem Amazon-EMR-Cluster verwendet werden. Sie können Amazon-EBS-GP2-Volumes nur als Root-Volumes verwenden und GP3-Volumes als zusätzliche Volumes hinzufügen. In der folgenden Tabelle sind die Standardanzahl von Amazon-EBS-GP2-Speicher-Volumes, Größen und Gesamtgrößen pro Instance-Typ aufgeführt.

Amazon-EBS-Kosten werden anteilig nach Stunde berechnet. Dies erfolgt auf der Grundlage der monatlichen Gebühren für gp2-Volumes in der AWS-Region, in der der Cluster ausgeführt wird. Die Amazon-EBS-Kosten pro Stunde für das Root-Volume auf jeden Cluster-Knoten in einer Region, in der 0,10 USD/GB/Monat berechnet werden, belaufen sich beispielsweise auf etwa 0,00139 USD pro Stunde (0,10 USD/GB/Monat dividiert durch 30 Tage dividiert durch 24h multipliziert mit 10 GB).

Standardmäßige Amazon-EBS-GP2-Speichervolumes und -größe nach Instance-Typ für Amazon EMR 5.22.0 und höher

Instance-Größe	Anzahl der Volumes	Volume-Größe (GiB)	Gesamtgröße (GB)
*.large	1	32	32
*.xlarge	2	32	64
*.2xlarge	4	32	128
*.4xlarge	4	64	256
*.8xlarge	4	128	512
9xlarge	4	144	576
10xlarge	4	160	640
12xlarge	4	192	768
*.16xlarge	4	256	1024
18xlarge	4	288	1 152
24xlarge	4	384	1536

Angeben zusätzlicher EBS-Speicher-Volumes

Wenn Sie Instance-Typen in Amazon EMR konfigurieren, können Sie zusätzliche EBS-Volumes angeben, um Kapazität über den Instance-Speicher (falls vorhanden) und das Standard-EBS-Volume hinaus hinzuzufügen. Amazon EBS bietet die folgenden Volume-Typen: Allzweck (SSD), Bereitgestellte IOPS (SSD), durchsatzoptimiert (HDD), Cold (HDD) und Magnetfestplatte. Diese

unterscheiden sich bei den Leistungsmerkmalen und im Preis, sodass Sie Ihren Speicher den Analyse- und Business-Anforderungen Ihrer Anwendungen entsprechend anpassen können. Beispielsweise benötigen einige Anwendungen den Überlauf auf Datenträger, während andere im Speicher oder unter Verwendung Amazon S3 sicher arbeiten können.

Sie können Amazon-EBS-Volumes nur beim Cluster-Startup und beim Hinzufügen einer zusätzlichen Aufgabenknoten-Instance-Gruppe an Instances anhängen. Wenn eine Instance in einem Amazon-EMR-Cluster ausfällt, werden sowohl die Instance als auch die angeschlossenen Amazon-EBS-Volumes durch neue Volumes ersetzt. Wenn Sie ein Amazon-EBS-Volume manuell trennen, behandelt Amazon EMR dies als Fehler und ersetzt sowohl den Instance-Speicher (falls zutreffend) als auch die Volume-Speicher.

Amazon EMR erlaubt Ihnen nicht, Ihren Volumetyp für einen vorhandenen EMR-Cluster von gp2 auf gp3 zu ändern. Um gp3 für Ihre Workloads/Anwendungsfälle zu verwenden, müssen Sie einen neuen EMR-Cluster starten. Darüber hinaus empfehlen wir nicht, den Durchsatz und die IOPS auf einem Cluster zu aktualisieren, der verwendet wird oder bereitgestellt wird, da Amazon EMR den Durchsatz und die IOPS-Werte verwendet, die Sie beim Clusterstart für jede neue Instance angegeben haben, die Sie beim Cluster-Scale-up hinzugefügt haben. Siehe Vergleichen der Amazon-EBS-Volumetypen gp2 und gp3 und Auswahl von IOPS und Durchsatz bei der Migration zu gp3.

> **Important**
>
> Um ein gp3-Volume mit Ihrem EMR-Cluster zu verwenden, starten Sie einen neuen EMR-Cluster mit der API, dem SDK oder der CLI.

Vergleichen der Amazon-EBS-Volumetypen gp2 und gp3

Hier finden Sie einen Vergleich der Kosten zwischen den GP2- und GP3-Volumen in der Region us-east-1 (Nord-Virginia)

Volume-Typ	gp3	gp2
Volume-Größe	1 GiB–16 TiB	1 GiB–16 TiB
Standard-/Baseline-IOPS	3000	3 IOPS/GiB (mindestens 100 IOPS) bis maximal 16 000 IOPS. Volumes, die kleiner als 1 TiB sind, können

Volume-Typ	gp3	gp2
		auch bis zu 3 000 IOPS erreichen.
Max. IOPS pro Volume	16,000	16,000
Standard-/Baseline-Durchsatz	125 MiB/s	Die Durchsatzgrenze liegt zwischen 128 MiB/s und 250 MiB/s, abhängig von der Volume-Größe.
Max. Durchsatz pro Volume	1 000 MiB/s	250 MiB/s
Preis	0,08 USD/GiB-Monat 3 000 IOPS kostenlos und 0,005 USD/bereitgestellt es IOPS-Monat über 3 000; 125 MiB/s kostenlos und 0,04 USD/bereitgestellte MiB/ s-Monat über 125 MiB/s	0,10 USD/GiB-Monat

Auswahl von IOPS und Durchsatz bei der Migration zu gp3

Bei der Bereitstellung eines GP2-Volumes müssen Sie die Größe des Volumes ermitteln, um das Verhältnis zwischen IOPS und Durchsatz zu ermitteln. Mit gp3 müssen Sie kein größeres Volume bereitstellen, um eine höhere Leistung zu erzielen. Sie können die gewünschte Größe und Leistung je nach Anwendungsanforderungen wählen. Durch die Auswahl der richtigen Größe und der richtigen Leistungsparameter (IOPS, Durchsatz) können Sie maximale Kostensenkungen erzielen, ohne die Leistung zu beeinträchtigen.

Die folgende Tabelle hilft Ihnen bei der Auswahl der gp3-Konfigurationsoptionen:

Volume-Größe	IOPS	Durchsatz
1–170 GiB	3000	125 MiB/s
170–334 GiB	3000	125 MiB/s, wenn der gewählte EC2-Instance-Typ 125 MiB/

Volume-Größe	IOPS	Durchsatz
		s oder weniger unterstützt, verwenden Sie je nach Nutzung mehr, maximal 250 MiB/s*.
334–1 000 GiB	3000	125 MiB/s, wenn der gewählte EC2-Instance-Typ 125 MiB/s oder weniger unterstützt, je nach Nutzung höher verwenden, max. 250 MiB/s*.
Über 1 000 GiB	Passen Sie gp2-IOPS (Größe in GiB x 3) oder maximale IOPS an, abhängig vom aktuellen gp2-Volume	125 MiB/s, wenn der gewählte EC2-Instance-Typ 125 MiB/s oder weniger unterstützt, je nach Nutzung höher verwenden, max. 250 MiB/s*.

*Gp3 kann einen Durchsatz von bis zu 1 000 MiB/s bieten. Da gp2 einen maximalen Durchsatz von 250 MiB/s bietet, müssen Sie diese Grenze möglicherweise nicht überschreiten, wenn Sie gp3 verwenden.

Netzwerk konfigurieren

Die meisten Cluster werden mithilfe von Amazon Virtual Private Cloud (Amazon VPC) in einem virtuellen Netzwerk gestartet. Eine VPC ist ein isoliertes virtuelles Netzwerk in AWS, das innerhalb Ihres AWS-Kontos logisch isoliert ist. Sie können Aspekte wie private IP-Adressbereiche, Subnetze, Routing-Tabellen und Netzwerk-Gateways konfigurieren. Weitere Informationen finden Sie im Amazon VPC-Benutzerhandbuch.

VPC bietet folgende Funktionen:

- Verarbeitung sensibler Daten

  Einen Cluster in einer VPC zu starten ist ähnlich wie in einem privaten Netzwerk mit zusätzlichen Funktionen wie Routing-Tabellen und Netzwerk-ACLs, um zu definieren, welche Benutzer Zugriff auf das Netzwerk haben. Wenn Sie sensible Daten in Ihrem Cluster verarbeiten, ist die zusätzliche Zugriffskontrolle, die das Starten von Ihrem Cluster in einer VPC bietet, nützlich. Außerdem können

Sie Ihre Ressourcen in einem privaten Subnetz starten, in dem keine dieser Ressourcen über eine direkte Internetverbindung verfügt.

- Zugreifen auf Ressourcen in einem internen Netzwerk

  Wenn sich Ihre Datenquelle in einem privaten Netzwerk befindet, kann es entweder aufgrund der Datenmenge oder der Vertraulichkeitsstufe der Daten unpraktisch oder unerwünscht sein, die Daten zum Importieren in Amazon EMR in AWS hochzuladen. Stattdessen können Sie den Cluster in einer VPC starten und Ihr Rechenzentrum über eine VPN-Verbindung mit Ihrer VPC zu verbinden, damit der Cluster Zugriff auf Ressourcen im internen Netzwerk erhält. Wenn sich beispielsweise eine Oracle-Datenbank in Ihrem Rechenzentrum befindet, kann der Cluster auf diese Datenbank zugreifen, wenn Sie ihn in einer VPC starten, die mit dem entsprechenden Netzwerk über VPN verbunden ist.

Öffentliche und private Subnetze

Sie können Amazon-EMR-Cluster sowohl in öffentlichen als auch privaten VPC-Subnetzen starten. Das bedeutet, dass Sie keine Internet-Konnektivität benötigen, um einen Amazon-EMR-Cluster auszuführen. Sie müssen die Netzwerkadressenübersetzung (Network Address Translation, NAT) und VPN-Gateways allerdings für den Zugriff auf Services und Ressourcen außerhalb von VPC konfigurieren, z. B. in einem Intranet oder öffentlichen AWS-Service-Endpunkten wie AWS Key Management Service.

> **Important**
>
> Amazon EMR unterstützt nur das Starten von Clustern in privaten Subnetzen in den Versionen 4.2 oder höher.

Weitere Informationen zur Amazon VPC-Sicherheit finden Sie unter Sicherheit im Amazon VPC-Benutzerhandbuch.

Themen

- Optionen für Amazon-VPC
- Einen VPC zum Hosten von Clustern einrichten
- Cluster in einer VPC starten
- Amazon-S3-Mindestrichtlinie für private Subnetze

- Weitere Ressourcen für Informationen über VPCs

Optionen für Amazon-VPC

Wenn Sie ein Amazon-EMR-Cluster in einer VPC starten, können Sie diesen Vorgang in einem öffentlichen, privaten oder gemeinsamen Subnetz ausführen. Es gibt geringe, aber erwähnenswerte Unterschiede in Bezug auf die Konfiguration, je nachdem, welchen Subnetztyp Sie für ein Cluster auswählen.

Öffentliche Subnetze

EMR-Cluster in einem öffentlichen Subnetz erfordern ein verbundenes Internet-Gateway. Der Grund hierfür ist, dass Amazon-EMR-Cluster auf AWS-Services und Amazon EMR zugreifen müssen. Wenn ein Service, wie Amazon S3 die Möglichkeit zum Erstellen eines VPC-Endpunkts bietet, können Sie auf diese Services über den Endpunkt statt über einen öffentlichen Endpunkt und ein Internet-Gateway zugreifen. Darüber hinaus kann Amazon EMR nicht über ein NAT-Gerät (Network Address Translation) mit Clustern in öffentlichen Subnetzen kommunizieren. Zu diesem Zweck ist ein Internet-Gateway erforderlich. Sie können dennoch eine NAT-Instance oder ein Gateway für anderen Datenverkehr in komplexeren Szenarien verwenden.

Alle Instances in einem Cluster stellen entweder über einen VPC-Endpunkt oder ein Internet-Gateway einen Verbindung mit Amazon S3 her. Andere AWS-Services, die derzeit keine VPC-Endpunkte unterstützen, verwenden nur ein Internet-Gateway.

Wenn Sie über zusätzliche AWS-Ressourcen verfügen, die nicht mit dem Internet-Gateway verbunden werden sollen, können Sie diese Komponenten in einem privaten Subnetz starten, das Sie in Ihrer VPC erstellen.

Cluster in einem öffentlichen Subnetz verwenden zwei Sicherheitsgruppen: eine für den Primärknoten und eine für Core- und Aufgabenknoten. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Das folgende Diagramm zeigt, wie ein Amazon-EMR-Cluster in einer VPC mit einem öffentlichen Subnetz ausgeführt wird. Der Cluster kann eine Verbindung mit anderen AWS-Ressourcen wie Amazon-S3-Buckets über das Internet-Gateway herstellen.

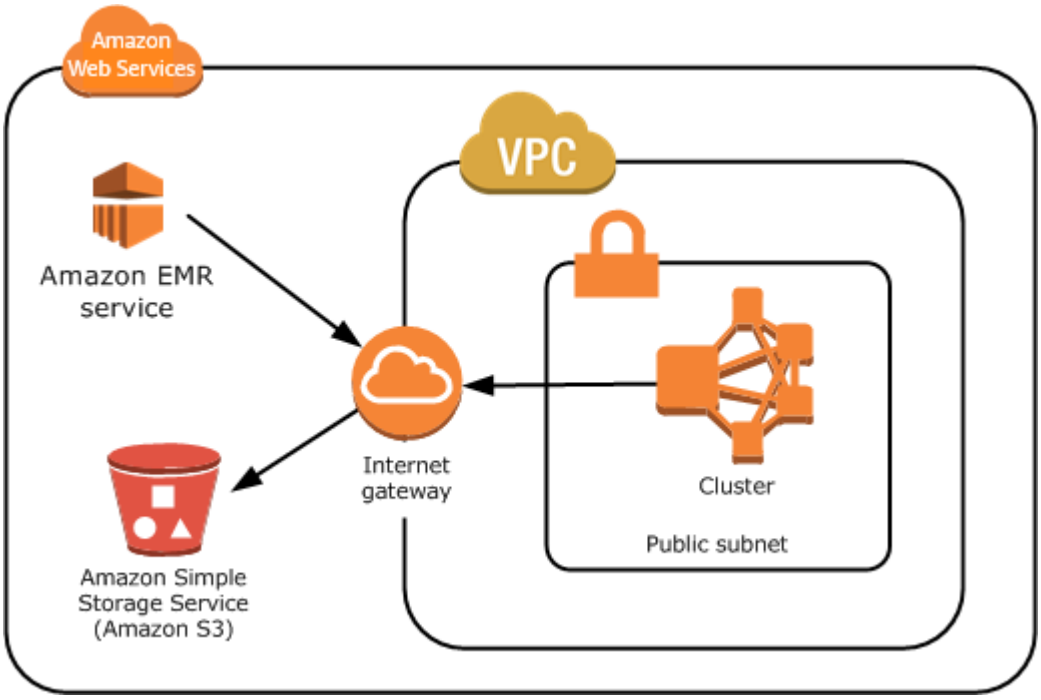

Das folgende Diagramm zeigt, wie Sie eine VPC so einrichten, dass ein Cluster in der VPC Zugriff auf Ressourcen in Ihrem eigenen Netzwerk, wie z. B. eine Oracle-Datenbank, hat.

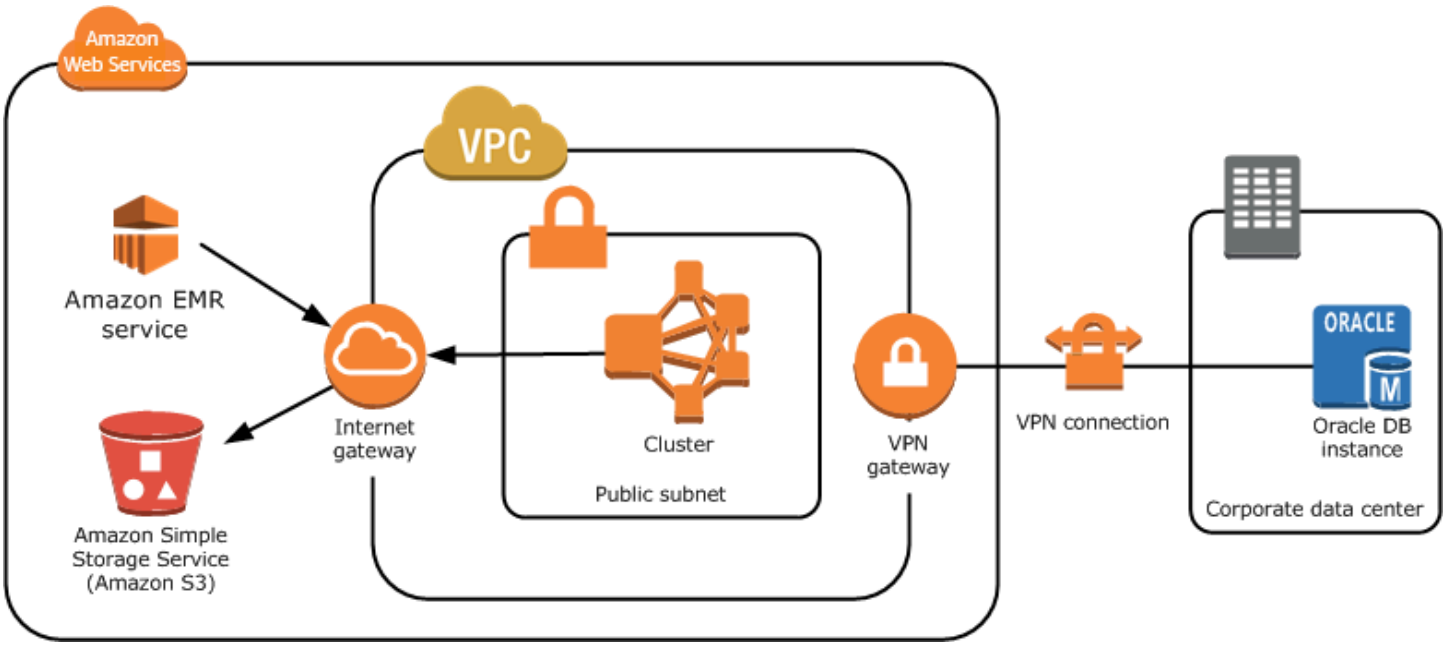

Private Subnetze

Mit einem privaten Subnetz können Sie AWS Ressourcen starten, ohne dass das Subnetz über ein angeschlossenes Internet-Gateway verfügen muss. Amazon EMR unterstützt nur das Starten von Clustern in privaten Subnetzen in den Versionen 4.2.0 oder höher.

> **Note**
>
> Wenn Sie einen Amazon EMR-Cluster in einem privaten Subnetz einrichten, empfehlen wir, dass Sie auch VPC-Endpunkte für Amazon S3 einrichten. Wenn sich Ihr EMR-Cluster in einem privaten Subnetz ohne VPC-Endpunkte für Amazon S3 befindet, fallen zusätzliche NAT-Gateway-Gebühren an, die mit S3-Verkehr verbunden sind, da der Verkehr zwischen Ihrem EMR-Cluster und S3 nicht innerhalb Ihrer VPC verbleibt.

Private Subnetze unterscheiden sich von öffentlichen Subnetzen in folgenden Punkten:

- Für den Zugriff auf AWS-Services, die keinen VPC-Endpunkt zur Verfügung stellen, müssen Sie eine NAT-Instance oder ein Internet-Gateway verwenden.
- Sie müssen mindestens eine Route zum Amazon-EMR-Bucket für Serviceprotokolle und Amazon-Linux-Repository in Amazon S3 zur Verfügung stellen. Weitere Informationen finden Sie unter Amazon-S3-Mindestrichtlinie für private Subnetze.
- Wenn Sie EMRFS-Features verwenden, benötigen Sie einen Amazon-S3-VPC-Endpunkt und eine Route von Ihrem privaten Subnetz zu DynamoDB.
- Debugging funktioniert nur, wenn Sie eine Route von Ihrem privaten Subnetz zu einem öffentlichen Amazon-SQS-Endpunkt bereitstellen.
- Das Erstellen eines privaten Subnetzes mit einer NAT-Instance oder einem Gateway in einem öffentlichen Subnetz wird nur mithilfe der AWS Management Console unterstützt. Der einfachste Weg, NAT-Instances und Amazon-S3-VPC-Endpunkte für Amazon-EMR-Cluster hinzuzufügen und zu konfigurieren, ist die Verwendung der Seite VPC-Subnetzliste in der Amazon-EMR-Konsole. Informationen zum Konfigurieren von NAT-Gateways finden Sie unter NAT-Gateways im Amazon-VPC-Benutzerhandbuch.
- Sie können ein Subnetz mit einem vorhandenen Amazon-EMR-Cluster nicht von öffentlich in privat oder umgekehrt ändern. Um ein Amazon-EMR-Cluster in einem privaten Subnetz zu finden, muss der Cluster in diesem privaten Subnetz gestartet werden.

Amazon EMR erstellt und verwendet verschiedene Standardsicherheitsgruppen für die Cluster in einem privaten Subnetz: ElasticMapReduce-Master-Private, ElasticMapReduce-Slave-Private und ElasticMapReduce-ServiceAccess. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Um eine vollständige Liste der NACLs Ihres Clusters zu erhalten, wählen Sie Sicherheitsgruppen für Primär- und Sicherheitsgruppen für Core und Aufgaben auf der Seite Cluster-Details der Amazon-EMR-Konsole.

Die folgende Abbildung zeigt, wie ein Amazon-EMR-Cluster in einem privaten Subnetz konfiguriert wird. Die einzige Kommunikation außerhalb des Subnetzes erfolgt mit Amazon EMR.

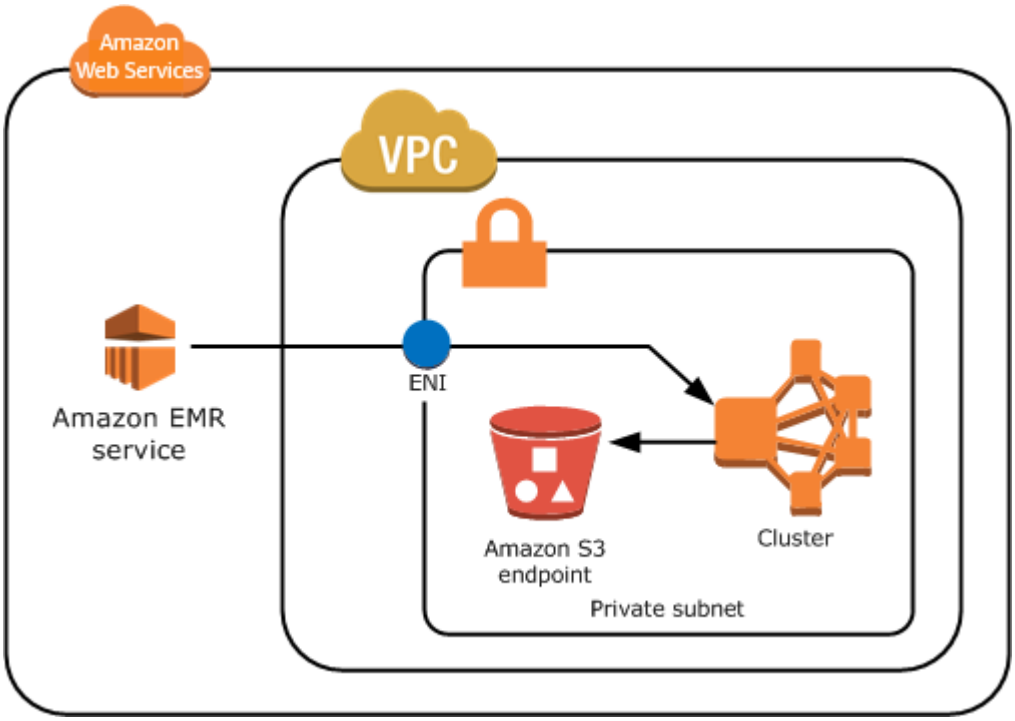

In der folgenden Abbildung ist eine Beispielkonfiguration für einen Amazon-EMR-Cluster in einem privaten Subnetz dargestellt, das mit einer NAT-Instance in einem öffentlichen Subnetz verbunden ist.

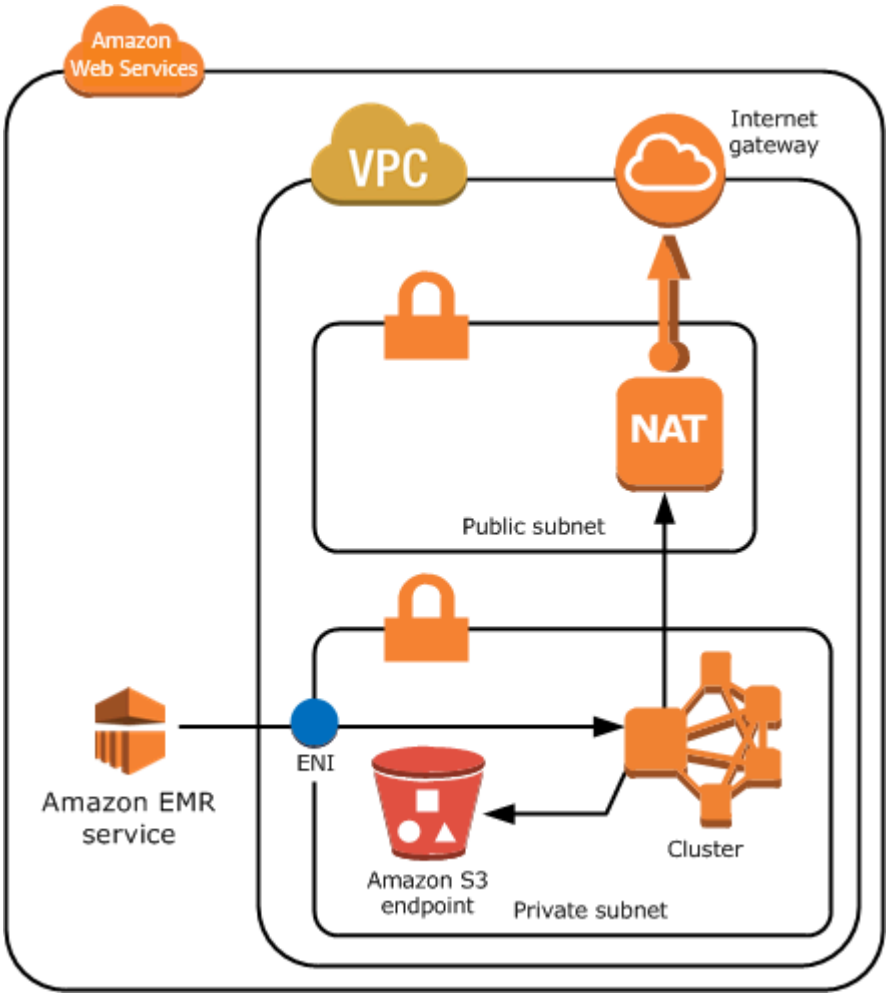

Gemeinsame Subnetze

Mit VPC können Kunden Subnetze mit anderen AWS-Konten innerhalb derselben AWS-Organisation gemeinsam nutzen. Sie können Amazon-EMR-Cluster sowohl in öffentlichen als auch privaten gemeinsamen Subnetzen starten, wobei folgende Einschränkungen gelten.

Der Subnetzbesitzer muss ein Subnetz für Sie freigeben, bevor Sie ein Amazon-EMR-Cluster darin starten können. Die Freigabe für gemeinsame Subnetze kann jedoch zu einem späteren Zeitpunkt wieder aufgehoben werden. Weitere Informationen finden Sie unter Arbeiten mit freigegebenen VPCs. Wenn ein Cluster in einem gemeinsamen Subnetz gestartet wird und die Freigabe für dieses gemeinsame Subnetz dann aufgehoben wird, lassen sich bei Aufhebung der Freigabe des Subnetzes je nach Status des Amazon-EMR-Clusters bestimmte Verhaltensweisen beobachten.

- Die Freigabe des Subnetzes wird vor dem erfolgreichen Start des Clusters aufgehoben – Wenn der Besitzer die Freigabe der Amazon VPC oder des Subnetzes aufhebt, während der Teilnehmer ein

Cluster startet, kann das Cluster nicht gestartet werden oder wird nur teilweise initialisiert, ohne alle angeforderten Instances bereitzustellen.

- Die Freigabe des Subnetzes wird nach dem erfolgreichen Start des Clusters aufgehoben – Wenn der Besitzer die Freigabe einer Amazon VPC oder eines Subnetzes für den Teilnehmer aufhebt, sind die Cluster des Teilnehmers nicht in der Lage, ihre Größe anzupassen, um neue Instances hinzuzufügen oder fehlerhafte Instances zu ersetzen.

Wenn Sie ein Amazon-EMR-Cluster starten, werden mehrere Sicherheitsgruppen erstellt. In einem gemeinsamen Subnetz steuert der Subnetzteilnehmer diese Sicherheitsgruppen. Der Subnetzbesitzer kann diese Sicherheitsgruppen zwar anzeigen, jedoch keine Aktionen bei diesen durchführen. Wenn der Subnetzbesitzer die Sicherheitsgruppe entfernen oder ändern möchte, muss der Teilnehmer, der die Sicherheitsgruppe erstellt hat, die Aktion durchführen.

VPC-Berechtigungen mit IAM steuern

Standardmäßig können alle Benutzer sämtliche Subnetze für das Konto sehen einen Cluster in einem Subnetz starten.

Wenn Sie einen Cluster in einer VPC starten, können Sie mit AWS Identity and Access Management (IAM) den Zugriff auf Cluster kontrollieren und Aktionen mithilfe von Richtlinien einschränken, genau wie bei Clustern, die in Amazon-EC2-Classic gestartet werden. Weitere Informationen zu IAM finden Sie im IAM-Benutzerhandbuch.

Sie können auch IAM verwenden, um zu kontrollieren, wer Subnetze erstellen und verwalten kann. Sie können beispielsweise ein Konto für die Verwaltung von Subnetzen und ein zweites Konto erstellen, das Cluster starten, aber die Amazon-VPC-Einstellungen nicht ändern kann. Weitere Informationen über die Verwaltung von Richtlinien und Aktionen in Amazon EC2 und Amazon VPC finden Sie unter IAM-Richtlinien für Amazon EC2 im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Einen VPC zum Hosten von Clustern einrichten

Bevor Sie Cluster in einer VPC starten können, müssen Sie eine VPC und ein Subnetz erstellen. Für öffentliche Subnetze müssen Sie ein Internet-Gateway erstellen und es dem Subnetz hinzufügen. Die folgenden Anweisungen beschreiben, wie Sie eine VPC erstellen, die Amazon-EMR-Cluster hosten können.

So erstellen Sie eine VPC mit Subnetzen für einen Amazon-EMR-Cluster

1. Öffnen Sie die Amazon-VPC-Konsole unter https://console.aws.amazon.com/vpc/.
2. Wählen Sie oben rechts auf der Seite AWS-Region für Ihre VPC aus.
3. Wählen Sie Create VPC aus.
4. Wählen Sie auf der Seite VPC-Einstellungen die Option VPC und mehr aus.
5. Aktivieren Sie unter Automatische Generierung von Namenstags die Option Automatisch generieren und geben Sie einen Namen für Ihre VPC ein. So können Sie die VPC und das Subnetz nach dem Erstellen in der Amazon VPC-Konsole identifizieren.
6. Geben Sie im Feld IPv4-CIDR-Block einen privaten IP-Adressraum für Ihre VPC ein, um eine ordnungsgemäße Auflösung des DNS-Hostnamens sicherzustellen. Andernfalls kann es zu Ausfällen des Amazon-EMR-Clusters kommen. Dieser Raum umfasst die folgenden IP-Adressbereiche:
   - 10.0.0.0 – 10.255.255.255
   - 172.16.0.0 – 172.31.255.255
   - 192.168.0.0 – 192.168.255.255
7. Wählen Sie unter Number of Availability Zones (AZs) (Anzahl der Availability Zones (AZs)) die Anzahl der Availability Zones aus, in denen Sie Ihre Subnetze starten möchten.
8. Wählen Sie unter Anzahl der öffentlichen Subnetze ein einzelnes öffentliches Subnetz aus, das Sie Ihrer VPC hinzufügen möchten. Wenn die vom Cluster verwendeten Daten im Internet verfügbar sind (z. B. in Amazon S3 oder Amazon RDS), müssen Sie nur ein öffentliches Subnetz verwenden und müssen kein privates Subnetz hinzufügen.
9. Wählen Sie unter Number of private subnets (Anzahl der privaten Subnetze) die Anzahl der privaten Subnetze aus, die Sie zu Ihrer VPC hinzufügen möchten. Wählen Sie eine oder mehrere aus, wenn die Daten für Ihre Anwendung in Ihrem eigenen Netzwerk gespeichert sind (z. B. in einer Oracle-Datenbank). Für eine VPC in einem privaten Subnetz müssen alle Amazon-EC2-Instances mindestens über eine Route zu Amazon EMR über die Elastic-Network-Schnittstelle verfügen. In der Konsole wird diese automatisch konfiguriert.
10. Wählen Sie unter NAT-Gateways optional, ob Sie NAT-Gateways hinzufügen möchten. Sie sind nur erforderlich, wenn Sie über private Subnetze verfügen, die mit dem Internet kommunizieren müssen.
11. Wählen Sie unter VPC-Endpunkte optional aus, Endpunkte für Amazon S3 zu Ihren Subnetzen hinzuzufügen.

12. Stellen Sie sicher, dass DNS-Hostnamen aktivieren und DNS-Auflösung aktivieren geprüft sind. Weitere Informationen finden Sie unter Verwenden von DNS in Ihrer VPC.
13. Wählen Sie Create VPC aus.
14. Ein Statusfenster zeigt den Fortschritt an. Wenn die Arbeit abgeschlossen ist, wählen Sie VPC anzeigen aus, um zu der Seite Ihre VPCs zu navigieren, auf der Ihre Standard-VPC und die zuvor erstellte VPC angezeigt werden. Die zuvor erstellte VPC ist eine nicht standardmäßige VPC, daher wird in der Spalte Default VPC No angezeigt.
15. Wenn Sie Ihre VPC einem DNS-Eintrag zuordnen möchten, der keinen Domainnamen enthält, navigieren Sie zu DHCP-Optionssätzen, wählen Sie DHCP-Optionssatz erstellen aus und lassen Sie einen Domainnamen weg. Nachdem Sie Ihren Optionssatz erstellt haben, navigieren Sie zu Ihrer neuen VPC, wählen Sie im Menü Aktionen die Option DHCP-Optionssatz bearbeiten und wählen Sie den neuen Optionssatz aus. Sie können den Domainnamen nicht mit der Konsole bearbeiten, nachdem die DNS-Optionsliste festgelegt wurde.

    Es ist eine bewährte Methode mit Hadoop und verwandten Anwendungen, um die Auflösung des Fully Qualified Domain Name (FQDN, vollständig qualifizierter Domainname) für Knoten sicherzustellen. Um die ordnungsgemäße DNS-Auflösung sicherzustellen, müssen Sie eine VPC konfigurieren, die eine DHCP-Optionsliste enthält, deren Parameter auf die folgenden Werte festgelegt sind:

    - domain-name = **`ec2.internal`**

      Verwenden Sie **`ec2.internal`**, wenn Ihre Region USA Ost (Nord-Virginia) ist. Für andere Regionen verwenden Sie *`region-name`***`.compute.internal`**. Beispiele für `us-west-2` finden Sie in **`us-west-2.compute.internal`**. Verwenden Sie für die Region AWS GovCloud (USA-West) **`us-gov-west-1.compute.internal`**.
    - domain-name-servers = **`AmazonProvidedDNS`**

    Weitere Informationen finden Sie unter DHCP-Optionssätze im Amazon-VPC-Benutzerhandbuch.
16. Nachdem die VPC erstellt wurde, gehen Sie zur Seite Subnetze und notieren Sie die Subnetz-ID eines der Subnetze Ihrer neuen VPC. Diese Information benötigen Sie, wenn Sie den Amazon-EMR-Cluster in der VPC starten.

Cluster in einer VPC starten

Nachdem Sie ein Subnetz zum Hosten von Amazon-EMR-Clustern konfiguriert haben, starten Sie den Cluster in diesem Subnetz, indem Sie die zugewiesene Subnetz-ID beim Erstellen des Clusters angeben.

> **Note**
>
> Amazon EMR unterstützt private Subnetze in Version 4.2 und höher.

Wenn der Cluster gestartet wird, fügt Amazon EMR Sicherheitsgruppen hinzu, je nachdem, ob der Cluster in privaten oder öffentlichen Subnetzen der VPC gestartet wird. Alle Sicherheitsgruppen ermöglichen einen Zugang über Port 8443 für die Kommunikation mit dem Amazon-EMR-Service. Die IP-Adressbereiche sind jedoch für öffentliche und private Subnetze unterschiedlich. Amazon EMR verwaltet alle Sicherheitsgruppen und muss dem AWS-Adressbereich im Laufe der Zeit möglicherweise zusätzliche IP-Adressen hinzufügen. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Zum Verwalten des Cluster in einer VPC fügt Amazon EMR dem Primärknoten ein Netzwerkgerät an und verwaltet ihn über dieses Gerät. Sie können dieses Gerät mit der Amazon-EC2-API-Aktion `DescribeInstances` ansehen. Wenn Sie dieses Gerät ändern, fällt der Cluster möglicherweise aus.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So starten Sie einen Cluster in einer VPC mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.

3. Gehen Sie unter Networking zum Feld Virtual Private Cloud (VPC). Geben Sie den Namen Ihrer VPC ein oder wählen Sie Durchsuchen, um Ihre VPC auszuwählen. Wählen Sie alternativ VPC erstellen, um eine VPC zu erstellen, die Sie für Ihren Cluster verwenden können.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So starten Sie einen Cluster in einer VPC mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Wählen Sie im Abschnitt Hardware Configuration (Hardwarekonfiguration) für Network (Netzwerk)die ID eines zuvor von Ihnen erstellen VPC-Netzwerks aus.
5. Wählen Sie in EC2 Subnet (EC2-Subnetz) die ID eines zuvor von Ihnen erstellten Subnetzes aus.

    a. Wenn das private Subnetz ordnungsgemäß NAT-Instance- und S3-Endpunkt-Optionen konfiguriert wurde, wird oberhalb der Subnetznamen und -IDs (EMR Ready) (EMR-kompatibel) angezeigt.

    b. Wenn Ihr privates Subnetz nicht über eine NAT-Instance und/oder einen S3-Endpunkt verfügt, können Sie diese konfigurieren, indem Sie Add S3 endpoint and NAT instance (S3-Endpunkt und NAT-Instance hinzufügen), Add S3 endpoint (S3-Endpunkt hinzufügen) oder Add NAT instance (NAT-Instanz hinzufügen) auswählen. Wählen Sie die gewünschten Optionen für NAT-Instance und S3-Endpunkt aus und klicken Sie auf Configure (Konfigurieren).

    > **Important**
    >
    > Um eine NAT-Instance in Amazon EMR zu erstellen, benötigen Sie die Berechtigungen ec2:CreateRoute, `ec2:RevokeSecurityGroupEgress`, `ec2:AuthorizeSecurityGroupEgress`,

`cloudformation:DescribeStackEvents` und `cloudformation:CreateStack`.

> **Note**
>
> Es fallen für das Starten einer Amazon-EC2-Instance für Ihr NAT-Gerät zusätzliche Kosten an.

6. Fahren Sie mit der Erstellung des Clusters fort.

AWS CLI

So starten Sie einen Cluster in einer VPC mit der AWS CLI

> **Note**
>
> Mit der AWS CLI können Sie eine NAT-Instance nicht automatisch erstellen und mit Ihrem privaten Subnetz verbinden. Um jedoch einen S3-Endpunkt in Ihrem Subnetz zu erstellen, können Sie die Amazon-VPC-CLI-Befehle nutzen. Verwenden Sie die Konsole zum Erstellen von NAT-Instances und Starten von Clustern in einem privaten Subnetz.

Nachdem Sie Ihre VPC konfiguriert haben, können Sie darin vorhandene Amazon-EMR-Cluster mithilfe des Unterbefehls `create-cluster` mit dem Parameter `--ec2-attributes` starten. Verwenden Sie den Parameter `--ec2-attributes`, um das VPC-Subnetz für den Cluster anzugeben.

- Um einen Cluster in einem bestimmten Subnetz zu erstellen, geben Sie den folgenden Befehl. Ersetzen Sie *myKey* durch den Namen Ihres Amazon-EC2-Schlüsselpaars und *77XXXX03* durch Ihre Subnetz-ID.

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.2.0 --
applications Name=Hadoop Name=Hive Name=Pig --use-default-roles --ec2-attributes
 KeyName=myKey,SubnetId=subnet-77XXXX03 --instance-type m5.xlarge --instance-
count 3
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige Amazon-EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie `aws emr create-default-roles` ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

Amazon-S3-Mindestrichtlinie für private Subnetze

Für private Subnetze müssen Sie Amazon EMR mindestens die Möglichkeit geben, auf Amazon-Linux-Repositorys zuzugreifen. Diese private Subnetzrichtlinie ist Teil der VPC-Endpunktrichtlinien für den Zugriff auf Amazon S3. Mit Amazon EMR 5.25.0 oder höher müssen Sie Amazon EMR den Zugriff auf den System-Bucket ermöglichen, in dem die Spark-Ereignisprotokolle erfasst werden, um den Zugriff auf den persistenten Spark-History-Server mit nur einem Klick zu aktivieren. Wenn Sie die Protokollierung aktivieren, geben Sie PUT-Berechtigungen für einen `aws157-logs-*`-Bucket ein. Weitere Informationen finden Sie unter Zugriff auf den persistenten Spark History Server mit nur einem Klick.

Es ist dem Benutzer überlassen, den Businessanforderungen entsprechende Richtlinieneinschränkungen festzulegen. Sie können beispielsweise die Region `packages.us-east-1.amazonaws.com` angeben, um einen mehrdeutigen Amazon-S3-Bucket-Namen zu vermeiden. Die folgende Beispielrichtlinie bietet Berechtigungen für den Zugriff auf Amazon-Linux-Repositorys und den Amazon-EMR-System-Bucket zum Sammeln von Spark-Ereignisprotokollen. Ersetzen Sie *`MyRegion`* durch die Region, in der sich Ihre Protokoll-Buckets befinden, zum Beispiel `us-east-1`.

Weitere Informationen zur Verwendung von IAM-Richtlinien mit Amazon-VPC-Endpunkten finden Sie unter Endpunktrichtlinien für Amazon S3.

```
{
   "Version": "2008-10-17",
   "Statement": [
       {
           "Sid": "AmazonLinuxAMIRepositoryAccess",
           "Effect": "Allow",
```

```
            "Principal": "*",
            "Action": "s3:GetObject",
            "Resource": [
             "arn:aws:s3:::packages.MyRegion.amazonaws.com/*",
             "arn:aws:s3:::repo.MyRegion.amazonaws.com/*",
             "arn:aws:s3:::repo.MyRegion.emr.amazonaws.com/*"
            ]
        },
        {
            "Sid": "EnableApplicationHistory",
            "Effect": "Allow",
            "Principal": "*",
            "Action": [
                "s3:Put*",
                "s3:Get*",
                "s3:Create*",
                "s3:Abort*",
                "s3:List*"
            ],
            "Resource": [
             "arn:aws:s3:::prod.MyRegion.appinfo.src/*"
            ]
        }
    ]
}
```

Die folgende Beispielrichtlinie stellt die Berechtigungen bereit, die für den Zugriff auf Amazon-Linux-2-Repositorys erforderlich sind. Amazon-Linux-2-AMI ist die Standardeinstellung.

```
{
    "Statement": [
        {
            "Sid": "AmazonLinux2AMIRepositoryAccess",
            "Effect": "Allow",
            "Principal": "*",
            "Action": "s3:GetObject",
            "Resource": [
             "arn:aws:s3:::amazonlinux.MyRegion.amazonaws.com/*",
             "arn:aws:s3:::amazonlinux-2-repos-MyRegion/*"
            ]
        }
    ]
}
```

Weitere Ressourcen für Informationen über VPCs

Die folgenden Themen enthalten weitere Informationen über VPCs und Subnetze.

- Private Subnetze in einer VPC
  - Szenario 2: VPC mit öffentlichen und privaten Subnetzen (NAT)
  - NAT-Instances
  - Hohe Verfügbarkeit für Amazon VPC NAT-Instances: Beispiel
- Öffentliche Subnetze in einer VPC
  - Szenario 1: VPC mit einem einzelnen öffentlichen Subnetz
- Allgemeine VPC-Informationen
  - Amazon VPC User Guide
  - VPC Peering
  - Verwenden von Elastic Network-Schnittstellen mit Ihrer VPC
  - Sichere Verbindung mit Linux-Instances, die in einer privaten VPC ausgeführt werden

Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen

Wenn Sie einen Cluster erstellen und die Konfiguration der Primär-, Core- und Aufgabenknoten angeben, stehen Ihnen zwei Konfigurationsoptionen zur Verfügung. Sie können Instance-Flotten oder einheitliche Instance-Gruppen verwenden. Die Konfigurationsoption, die Sie auswählen, gilt für alle Knoten und für die gesamte Nutzungsdauer des Clusters. Instance-Flotten und Instance-Gruppen können nicht gleichzeitig in einem Cluster vorhanden sein. Die Instance-Flottenkonfiguration ist in Amazon-EMR-Versionen 4.8.0 und höher verfügbar, nicht in 5.0.x-Versionen.

Sie können die Amazon-EMR-Konsole, die AWS CLI oder die Amazon-EMR-API verwenden, um Cluster mit einer der Konfigurationen zu erstellen. Wenn Sie den Befehl `create-cluster` in der AWS CLI verwenden, erstellen Sie den Cluster mit den `--instance-fleets`-Parametern, um den Cluster mittels Instance-Flotten zu erstellen, oder mit den `--instance-groups`-Parametern, um den Cluster mittels einheitlicher Instance-Gruppen zu erstellen.

Dasselbe gilt auch, wenn Sie die Amazon-EMR-API verwenden. Sie geben mit der Konfiguration `InstanceGroups` eine Reihe von `InstanceGroupConfig`-Objekten oder mit der Konfiguration `InstanceFleets` eine Reihe von `InstanceFleetConfig`-Objekten an.

In der neuen Amazon-EMR-Konsole können Sie wählen, ob Sie bei der Erstellung eines Clusters entweder Instance-Gruppen oder Instance-Flotten verwenden möchten, und Sie haben die

Möglichkeit, Spot Instances mit jeder zu verwenden. Wenn Sie mit der alten Amazon-EMR-Konsole beim Erstellen Ihres Clusters die Standardeinstellungen für Schnelloptionen verwenden, wendet Amazon EMR die einheitliche Instance-Gruppenkonfiguration auf den Cluster an und verwendet On-Demand-Instances. Um Spot-Instances mit einheitlichen Instance-Gruppen zu verwenden oder Instance-Flotten und anderen Anpassungen zu konfigurieren, wählen Sie Advanced Options (Erweiterte Optionen) aus.

Instance-Flotten

Die Instance-Flottenkonfiguration bietet eine Vielzahl von Bereitstellungsoptionen für Amazon-EC2-Instances. Jeder Knotentyp verfügt über eine einzelne Instance-Flotte und die Aufgaben-Instance-Flotte ist optional. Sie können bis zu fünf EC2-Instance-Typen pro Flotte oder 30 EC2-Instance-Typen pro Flotte angeben, wenn Sie einen Cluster mithilfe der AWS CLI oder Amazon-EMR-API und einer Zuweisungsstrategie für On-Demand- und Spot Instances erstellen. Für die Core- und Aufgaben-Instance-Flotten weisen Sie eine Zielkapazität für On-Demand-Instances und eine zweite für Spot Instances zu. Amazon EMR wählt eine Kombination aus fünf Instance-Typen aus, um die Zielkapazitäten zu erfüllen und stellt On-Demand- als auch Spot Instances bereit.

Für den Primärknoten-Typ wählt Amazon EMR einen einzelnen Instance-Typ aus Ihrer Liste von bis zu fünf Typen aus und Sie geben an, ob diese als On-Demand- oder Spot Instance bereitgestellt werden sollen. Instance-Flotten bieten auch zusätzliche Optionen für Spot Instance- und On-Demand-Käufe. Zu den Spot-Instance-Optionen gehören ein Timeout, das festlegt, welche Maßnahme ergriffen werden soll, wenn Spot-Kapazität nicht bereitgestellt werden kann, und eine bevorzugte Zuweisungsstrategie (kapazitätsoptimiert) für den Start von Spot Instance-Flotten. On-Demand-Instance-Flotten können auch mit der Option der Zuweisungsstrategie (niedrigster Preis) gestartet werden. Wenn Sie eine Servicerolle verwenden, die nicht die EMR-Standardservicerolle ist, oder eine von EMR verwaltete Richtlinie in Ihrer Servicerolle verwenden, müssen Sie der benutzerdefinierten Clusterservicerolle zusätzliche Berechtigungen hinzufügen, um die Option für die Zuweisungsstrategie zu aktivieren. Weitere Informationen finden Sie unter Servicerolle für Amazon EMR (EMR-Rolle).

Weitere Information zum Konfigurieren von Instance-Flotten finden Sie unter Instance-Flotten konfigurieren.

Einheitliche Instance-Gruppen

Einheitliche Instance-Gruppen bieten eine einfachere Einrichtung als Instance-Flotten. Jeder Amazon-EMR-Cluster kann bis zu 50 Instance-Gruppen umfassen: eine Primär-Instance-Gruppe mit einer Amazon-EC2-Instance, eine Core-Instance-Gruppe mit einer oder mehreren EC2-Instances und

bis zu 48 optionale Aufgaben-Instance-Gruppen. Jede Core- und Aufgaben-Instance-Gruppe kann eine beliebige Anzahl von Amazon-EC2-Instances enthalten. Sie können jede Instance-Gruppe durch Hinzufügen und Entfernen von Amazon-EC2-Instances manuell oder mit Auto Scaling automatisch skalieren. Weitere Informationen über das Hinzufügen und Entfernen von Instances finden Sie unter Clusterskalierung verwenden.

Weitere Informationen zum Konfigurieren von einheitlichen Instance-Gruppen finden Sie unter Einheitliche Instance-Gruppen konfigurieren.

Arbeiten mit Instance-Flotten und Instance-Gruppen

Themen

- Instance-Flotten konfigurieren
- Kapazitätsreservierungen mit Instance-Flotten verwenden
- Einheitliche Instance-Gruppen konfigurieren
- Bewährte Methoden für Instance- und Availability Zone-Flexibilität
- Bewährte Methoden für die Konfiguration des Clusters

Instance-Flotten konfigurieren

> **Note**
>
> Die Konfiguration der Instance-Flotten ist nur in den Amazon-EMR-Versionen 4.8.0 und höher verfügbar, mit Ausnahme von 5.0.0 und 5.0.3.

Mit der Instance-Flottenkonfiguration für Amazon-EMR-Cluster können Sie eine Vielzahl von Bereitstellungsoptionen für Amazon-EC2-Instances auswählen und eine flexible und elastische Ressourcenstrategie für jeden Knotentyp in Ihrem Cluster entwickeln.

In einer Instance-Flottenkonfiguration geben Sie eine Zielkapazität für On-Demand-Instances und Spot Instances innerhalb jeder Flotte an. Wenn der Cluster gestartet wird, stellt Amazon EMR Instances bereit, bis die Ziele erfüllt sind. Wenn Amazon EC2 eine Spot Instance in einem laufenden Cluster aufgrund einer Preiserhöhung oder eines Instance-Ausfalls zurückfordert, versucht Amazon EMR, die Instance durch einen der von Ihnen angegebenen Instance-Typen zu ersetzen. Dies erleichtert die Wiedererlangung der Kapazität während eines Anstiegs der Spot-Preise.

Sie können maximal fünf Amazon-EC2-Instance-Typen pro Flotte angeben, die Amazon EMR bei der Erfüllung der Ziele verwendet, oder maximal 30 Amazon-EC2-Instance-Typen pro Flotte, wenn Sie einen Cluster mithilfe der AWS CLI oder Amazon-EMR-API und einer Zuweisungsstrategie für On-Demand- und Spot Instances erstellen.

Sie können auch mehrere Subnetze für verschiedene Availability Zones auswählen. Wenn Amazon EMR den Cluster startet, sieht er auf diese Subnetze, um die Instances und Kaufoptionen zu finden, die Sie angeben. Wenn Amazon EMR ein AWS-großes Ereignis in einer oder mehreren Availability Zones erkennt, versucht Amazon EMR automatisch, den Verkehr von den betroffenen Availability Zones wegzuleiten und neue Cluster zu starten, die Sie entsprechend Ihrer Auswahl in alternativen Availability Zones erstellen. Beachten Sie, dass die Auswahl der Cluster-Availability-Zone nur bei der Cluster-Erstellung erfolgt. Bestehende Clusterknoten werden bei einem Ausfall der Availability Zone nicht automatisch in einer neuen Availability Zone neu gestartet.

Überlegungen

Berücksichtigen Sie Folgendes, wenn Sie Instance-Flotten mit Amazon EMR verwenden.

- Sie können eine Instance-Flotte haben, und zwar nur eine pro Knotentyp (Primär, Core, Aufgabe). Sie können bis zu fünf Amazon-EC2-Instance-Typen für jede Flotte auf der angeben AWS Management Console (oder maximal 30 Typen pro Instance-Flotte, wenn Sie einen Cluster mit AWS CLI oder Amazon-EMR-API und einem Zuweisungsstrategie für Flotten erstellen).
- Amazon EMR wählt einen oder alle der fünf EC2 Instance-Typen für die Bereitstellung sowohl mit Spot- als auch On-Demand-Kaufoptionen aus.
- Legen Sie Zielkapazitäten für Spot- und On-Demand-Instances für die Core- und Aufgaben-Flotte fest. Verwenden Sie vCPU oder eine generische Einheit, die jeder Amazon-EC2-Instance zugeordnet ist, die bei den Zielen mit eingerechnet wird. Amazon EMR stellt Instances bereit, bis die jeweilige Zielkapazität völlig erfüllt ist. Für die Primär-Flotte ist das Ziel immer auf 1 gesetzt.
- Sie können ein Subnetz (Availability Zone) oder einen Bereich auswählen. Amazon EMR stellt Kapazität in der Availability Zone bereit, die am besten passt.
- Hinweise zum Angeben der Zielkapazität für Spot-Instances:
  - Bestimmen Sie für jeden Instance-Typ einen maximalen Spot-Preis. Amazon EMR stellt Spot Instances bereit, wenn der Spot-Preis unter dem maximalen Spot-Preis liegt. Sie zahlen den Spot-Preis, nicht unbedingt den maximalen Spot-Preis.
  - Für jede Flotte definieren Sie einen Timeout-Zeitraum für die Bereitstellung von Spot-Instances. Wenn Amazon EMR keine Spot-Kapazität bereitstellen kann, können Sie den Cluster beenden oder stattdessen zur Bereitstellung von On-Demand-Kapazität wechseln. Dies gilt nur für die

Bereitstellung von Clustern, nicht für deren Größenänderung. Wenn der Timeout-Zeitraum während der Größenänderung des Clusters endet, werden Spot-Anfragen, die nicht bereitgestellt wurden, für ungültig erklärt, ohne dass sie auf On-Demand-Kapazität übertragen werden.

- Für jede Flotte können Sie eine der folgenden Zuweisungsstrategien für Ihre Spot Instances angeben: preiskapazitätsoptimiert, kapazitätsoptimiert, niedrigster Preis oder diversifiziert über alle Pools hinweg.
- Für jede Flotte können Sie eine Zuweisungsstrategie mit dem niedrigsten Preis für Ihre On-Demand-Instances anwenden. Sie können die Zuweisungsstrategie für On-Demand-Instances nicht anpassen.
- Für jede Flotte mit On-Demand-`allocation strategy - lowest-price`, können Sie wählen, ob Sie Optionen zur Kapazitätsreservierung anwenden möchten.
- Überprüfen Sie die Größe Ihres Subnetzes, bevor Sie Ihren Cluster starten. Wenn Sie einen Cluster mit einer Task-Flotte bereitstellen und im entsprechenden Subnetz nicht genügend IP-Adressen verfügbar sind, wechselt die Flotte in den Status Suspended, anstatt den Cluster mit einem Fehler zu beenden. Um dieses Problem zu vermeiden, empfehlen wir, die Anzahl der IP-Adressen in Ihren Subnetzen zu erhöhen.

Instance-Flotten-Optionen

Verwenden Sie die folgenden Richtlinien, um Instance-Flotten-Optionen zu verstehen.

Themen

- Festlegen von Zielkapazitäten
- Start-Optionen
- Optionen für mehrere Subnetze (Availability Zones)
- Hauptknoten-Konfiguration

Festlegen von Zielkapazitäten

Geben Sie die Zielkapazitäten für die Core- und Aufgaben-Flotte an. Wenn Sie dies tun, wird die Anzahl der On-Demand-Instances und Spot Instances festgelegt, die Amazon EMR bereitstellt. Wenn Sie eine Instance angeben, können Sie entscheiden, wie viel jede Instance beim Ziel mit eingerechnet wird. Wenn eine On-Demand-Instance bereitgestellt wird, wird sie beim On-Demand-Ziel mit eingerechnet. Dies gilt auch für Spot-Instances. Im Gegensatz zu Core- und Aufgaben-Flotten

besteht die Primär-Flotte immer aus einer Instance. Daher ist die Zielkapazität für diese Flotte immer auf 1 gesetzt.

Wenn Sie die Konsole verwenden, werden die vCPUs des Amazon-EC2-Instance-Typs standardmäßig als Anzahl für Zielkapazitäten verwendet. Sie können dies in Generic units (Generische Einheiten) ändern und anschließend die Anzahl für die einzelnen EC2-Instance-Typen angeben. Wenn Sie die AWS CLI verwenden, weisen Sie generische Einheiten für jeden Instance-Typ manuell zu.

> **Important**
>
> Wenn Sie mithilfe von einen Instance-Typ mit AWS Management Console auswählen, entspricht die Anzahl der für jeden Instance-Typ angezeigten vCPUs der Anzahl der YARN-vcores für diesen Instance-Typ, nicht der Anzahl der EC2-vCPUs für diesen Instance-Typ. Weitere Informationen zur Anzahl der vCPUs für jeden Instance-Typ finden Sie unter Amazon-EC2-Instance-Typen.

Für jede Flotte geben Sie bis zu fünf Amazon-EC2-Instance-Typen an. Wenn Sie einen Zuweisungsstrategie für Flotten verwenden und mithilfe der AWS CLI oder der Amazon-EMR-API einen Cluster erstellen, können Sie bis zu 30 EC2-Instance-Typen pro Instance-Flotte angeben. Amazon EMR wählt eine beliebige Kombination der folgenden EC2-Instance-Typen aus, um Ihre Zielkapazitäten zu erfüllen. Da Amazon EMR die Zielkapazität vollständig ausfüllen möchte, könnte es zu einer Übermenge kommen. Beispiel: Wenn zwei unerfüllte Einheiten vorhanden sind und Amazon EMR nur eine Instance mit einer Anzahl von fünf Einheiten bereitstellen kann, wird die Instance dennoch bereitgestellt. Dies bedeutet, dass die Zielkapazität im drei Einheiten überschritten wird.

Wenn Sie die Zielkapazität verringern, um die Größe eines laufenden Clusters zu ändern, versucht Amazon EMR, Anwendungsaufgaben abzuschließen und beendet Instances, um dem neuen Ziel zu entsprechen. Weitere Informationen finden Sie unter Beendigung bei Aufgaben-Abschluss.

Start-Optionen

Für Spot Instances können Sie einen maximalen Spot-Preis für jeden Instance-Typ in einer Flotte angeben. Sie können den Preis entweder als Prozentsatz des On-Demand-Preises oder als einen bestimmten Betrag in US-Dollar festlegen. Amazon EMR stellt Spot Instances bereit, wenn der aktuelle Spot-Preis in einer Availability Zone unter Ihrem maximalen Spot-Preis liegt. Sie zahlen den Spot-Preis, nicht unbedingt den maximalen Spot-Preis.

> **Note**
>
> Spot-Instances mit definierter Laufzeit (auch Spot-Blöcke genannt) stehen Neukunden ab dem 1. Juli 2021 nicht mehr zur Verfügung. Für Kunden, die diese Funktion bereits genutzt haben, werden wir Spot-Instances mit einer definierten Laufzeit bis zum 31. Dezember 2022 weiterhin unterstützen.

In Amazon EMR 5.12.1 und höher verfügbar, haben Sie die Möglichkeit, Spot- und On-Demand-Instance-Flotten mit optimierter Kapazitätszuweisung zu starten. Diese Option für die Zuweisungsstrategie kann in der alten Version AWS Management Console oder mithilfe der API `RunJobFlow` festgelegt werden. Beachten Sie, dass Sie die Zuweisungsstrategie in der neuen-Konsole nicht anpassen können. Für die Verwendung der Option „Zuweisungsstrategie“ sind zusätzliche Berechtigungen für Servicerollen erforderlich. Wenn Sie die standardmäßige Amazon-EMR-Servicerolle und die verwaltete Richtlinie (`EMR_DefaultRole` und `AmazonEMRServicePolicy_v2`) für den Cluster verwenden, sind die Berechtigungen für die Option Zuweisungsstrategie bereits enthalten. Wenn Sie nicht die standardmäßige Amazon-EMR-Servicerolle und die verwaltete Richtlinie verwenden, müssen Sie sie hinzufügen, um diese Option verwenden zu können. Siehe Servicerolle für Amazon EMR (EMR-Rolle).

Weitere Informationen über Spot Instances finden Sie unter Spot Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Weitere Informationen zu On-Demand-Instances finden Sie unter On-Demand-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Wenn Sie On-Demand-Instance-Flotten mit der Zuweisungsstrategie zum niedrigsten Preis starten möchten, haben Sie die Möglichkeit, Kapazitätsreservierungen zu verwenden. Optionen zur Kapazitätsreservierung können mithilfe der Amazon EMR API `RunJobFlow` festgelegt werden. Für Kapazitätsreservierungen sind zusätzliche Berechtigungen für Servicerollen erforderlich, die Sie hinzufügen müssen, um diese Optionen nutzen zu können. Siehe Zuweisungsstrategie-Berechtigungen. Beachten Sie, dass Sie Kapazitätsreservierungen in der neuen Konsole nicht anpassen können.

Optionen für mehrere Subnetze (Availability Zones)

Wenn Sie Instance-Flotten verwenden, können Sie mehrere Amazon-EC2-Subnetze innerhalb einer VPC angeben, die jeweils einer anderen Availability Zone entsprechen. Wenn Sie EC2-Classic verwenden, geben Sie Availability Zones explizit an. Amazon EMR identifiziert die beste Availability Zone zum Starten von Instances entsprechend den Spezifikationen Ihrer Flotte. Instances werden

immer nur in einer Availability Zone bereitgestellt. Sie können private Subnetze oder öffentliche Subnetze auswählen, aber nicht beides zusammen. Die Subnetze, die Sie angeben, müssen sich in derselben VPC befinden.

Hauptknoten-Konfiguration

Da die Primär-Instance-Flotte ist nur eine einzelne Instance ist, unterscheidet sich ihre Konfiguration etwas von Core- und Task-Instance-Flotten. Wählen Sie entweder On-Demand oder Spot für die Primär-Instance-Flotte aus, da sie nur aus einer Instance besteht. Wenn Sie die Konsole verwenden, um die Instance-Flotte zu erstellen, wird die Zielkapazität für die Kaufoption, die Sie auswählen, auf "1" festgelegt. Wenn Sie die AWS CLI verwenden, müssen Sie stets `TargetSpotCapacity` oder `TargetOnDemandCapacity` auf 1 festlegen, je nachdem. Sie können weiterhin bis zu fünf Instance-Typen für die primäre Instance-Flotte wählen (oder maximal 30, wenn Sie die Zuweisungsstrategie-Option für On-Demand- oder Spot Instances verwenden). Im Gegensatz zu Core- und Aufgaben-Instance-Flotten, für die Amazon EMR mehrere Instances mit verschiedenen Typen bereitstellen kann, wählt Amazon EMR einen einzelnen Instance-Typ zur Bereitstellung für die Primär-Instance-Flotte aus.

Zuweisungsstrategie für Flotten

Mit Amazon-EMR-Versionen 5.12.1 und höher können Sie die Option für die Zuweisungsstrategie mit On-Demand-Instances und Spot Instances für jeden Clusterknoten verwenden. Wenn Sie einen Cluster mithilfe der AWS CLI Amazon-EMR-API oder der Amazon-EMR-Konsole mit einer Zuweisungsstrategie erstellen, können Sie bis zu 30 Amazon-EC2-Instance-Typen pro Flotte angeben. Mit der standardmäßigen Amazon-EMR-Cluster-Instance-Flottenkonfiguration können Sie bis zu 5 Instance-Typen pro Flotte verwenden. Wir empfehlen Ihnen, die Option für die Zuweisungsstrategie zu verwenden, um eine schnellere Cluster-Bereitstellung, eine genauere Spot-Instance-Zuweisung und weniger Spot Instance-Unterbrechungen zu erzielen.

Themen

- Zuweisungsstrategie mit On-Demand-Instances
- Zuweisungsstrategie mit Spot Instances
- Zuweisungsstrategie-Berechtigungen
- Erforderliche IAM-Berechtigungen für eine Zuweisungsstrategie

Zuweisungsstrategie mit On-Demand-Instances

Wenn Sie die Zuweisungsstrategie verwenden, verwenden Ihre On-Demand-Instances die Strategie mit dem niedrigsten Preis. Dadurch werden zuerst die Instances mit dem niedrigsten Preis gestartet. Wenn Sie On-Demand-Instances starten, können Sie offene oder gezielte Kapazitätsreservierungen in Ihren Konten verwenden. Sie können offene Kapazitätsreservierungen für Primär-, Kern- und Aufgabenknoten verwenden. Bei On-Demand-Instances mit einer Zuweisungsstrategie für Instance-Flotten kann es zu einer unzureichenden Kapazität kommen. Wir empfehlen, dass Sie eine größere Anzahl von Instance-Typen angeben, um das Angebot zu diversifizieren und das Risiko einer unzureichenden Kapazität zu verringern. Weitere Informationen finden Sie unter Kapazitätsreservierungen mit Instance-Flotten verwenden.

Zuweisungsstrategie mit Spot Instances

Für Spot Instances können Sie aus einer der folgenden Zuweisungsstrategien wählen:

`price-capacity-optimized` (empfohlen)

Bei der preis-kapazitätsoptimierten Zuweisungsstrategie werden Spot Instances aus den Spot Instance-Pools gestartet, die über die höchste verfügbare Kapazität und den niedrigsten Preis für die Anzahl der zu startenden Instances verfügen. Aus diesem Grund bietet die Strategie mit optimierter Preis- und Kapazitätsoptimierung in der Regel eine höhere Wahrscheinlichkeit, Spot-Kapazität zu erhalten, und führt zu niedrigeren Unterbrechungsraten.

`capacity-optimized`

Die kapazitätsoptimierte Zuweisungsstrategie startet Spot Instances in den am meisten verfügbaren Pools mit der geringsten Wahrscheinlichkeit einer kurzfristigen Unterbrechung. Dies ist eine gute Option für Workloads, bei denen Unterbrechungen aufgrund von Neustarts von Aufgaben höhere Kosten verursachen. Dies ist die Standardstrategie für Amazon-EMR-Versionen 6.9.0 und niedriger.

`diversified`

Mit der diversifizierten Zuweisungsstrategie verteilt Amazon EC2 Spot Instances auf alle Spot-Kapazitätspools.

`lowest-price`

Bei der preisgünstigsten Zuweisungsstrategie werden Spot Instances aus dem preisgünstigsten Pool mit verfügbarer Kapazität gestartet. Wenn der günstigste Pool keine verfügbare Kapazität

aufweist, kommen die Spot Instances aus dem nächstgünstigsten Pool mit verfügbarer Kapazität. Wenn die Kapazität eines Pools erschöpft ist, bevor er Ihre angeforderte Kapazität erfüllt, greift die Amazon-EC2-Flotte auf den Pool mit dem nächstniedrigeren Preis zurück, um Ihre Anfrage weiterhin zu erfüllen. Damit die gewünschte Kapazität auf jeden Fall erreicht wird, erhalten Sie möglicherweise Spot-Instances aus mehreren Pools. Da diese Strategie nur den Instance-Preis und nicht die Kapazitätsverfügbarkeit berücksichtigt, kann es zu hohen Unterbrechungsraten kommen.

Zuweisungsstrategie-Berechtigungen

Die Option für die Zuweisungsstrategie erfordert mehrere IAM-Berechtigungen, die automatisch in der standardmäßigen Amazon-EMR-Servicerolle und der von Amazon EMR verwalteten Richtlinie (`EMR_DefaultRole` und `AmazonEMRServicePolicy_v2`) enthalten sind. Wenn Sie eine benutzerdefinierte Servicerolle oder eine verwaltete Richtlinie für Ihren Cluster verwenden, müssen Sie diese Berechtigungen hinzufügen, bevor Sie den Cluster erstellen. Weitere Informationen finden Sie unter Zuweisungsstrategie-Berechtigungen.

Optionale On-Demand-Kapazitätsreservierungen (ODCRs) sind verfügbar, wenn Sie die Option On-Demand-Zuweisungsstrategie verwenden. Mit den Optionen zur Kapazitätsreservierung können Sie angeben, ob reservierte Kapazität zuerst für Amazon-EMR-Cluster verwendet werden soll. Auf diese Weise können Sie sicherstellen, dass Ihre kritischen Workloads die Kapazität nutzen, die Sie bereits über offene oder gezielte ODCRs reserviert haben. Bei unkritischen Workloads können Sie in den Einstellungen für die Kapazitätsreservierung angeben, ob reservierte Kapazität verbraucht werden soll.

Kapazitätsreservierungen können nur von Instances verwendet werden, die ihren Attributen (Instance-Typ, Plattform und Availability Zone) entsprechen. Standardmäßig werden offene Kapazitätsreservierungen automatisch von Amazon EMR verwendet, wenn On-Demand-Instances bereitgestellt werden, die den Instance-Attributen entsprechen. Wenn Sie keine laufenden Instances haben, die den Attributen der Kapazitätsreservierungen entsprechen, bleiben diese ungenutzt, bis Sie eine Instance starten, die ihren Attributen entspricht. Wenn Sie beim Starten Ihres Clusters keine Kapazitätsreservierungen verwenden möchten, müssen Sie in den Startoptionen die Einstellung „Kapazitätsreservierung“ auf Keine setzen.

Sie können jedoch auch eine Kapazitätsreservierung für bestimmte Workloads festlegen. Auf diese Weise können Sie explizit steuern, welche Instances in der reservierten Kapazität ausgeführt werden dürfen. Weitere Informationen über On-Demand-Kapazitätsreservierungen finden Sie unter Kapazitätsreservierungen mit Instance-Flotten verwenden.

Erforderliche IAM-Berechtigungen für eine Zuweisungsstrategie

Ihre Servicerolle für Amazon EMR (EMR-Rolle) benötigen zusätzliche Berechtigungen, um einen Cluster zu erstellen, der die Zuweisungsstrategieoption für On-Demand-Instance-Flotten oder Spot-Instance-Flotten verwendet.

Wir nehmen diese Berechtigungen automatisch in die standardmäßige Amazon-EMR-Servicerolle `EMR_DefaultRole` und die von Amazon EMR verwaltete Richtlinie `AmazonEMRServicePolicy_v2` auf.

Wenn Sie eine benutzerdefinierte Servicerolle oder eine verwaltete Richtlinie für Ihren Cluster verwenden, müssen Sie die folgenden Berechtigungen hinzufügen:

```
{
 "Version": "2012-10-17",
 "Statement": [
  {
   "Effect": "Allow",
   "Action": [
    "ec2:DeleteLaunchTemplate",
    "ec2:CreateLaunchTemplate",
    "ec2:DescribeLaunchTemplates",
    "ec2:CreateLaunchTemplateVersion",
    "ec2:CreateFleet"
   ],
   "Resource": "*"
  }
}
```

Die folgenden Berechtigungen für Servicerollen sind erforderlich, um einen Cluster zu erstellen, der offene oder gezielte Kapazitätsreservierungen verwendet. Sie müssen diese Berechtigungen zusätzlich zu den Berechtigungen angeben, die für die Verwendung der Zuweisungsstrategie-Option erforderlich sind.

Example Richtliniendokument für Kapazitätsreservierungen für Servicerollen

Um offene Kapazitätsreservierungen verwenden zu können, müssen Sie die folgenden zusätzlichen Berechtigungen angeben.

```
{
    "Version": "2012-10-17",
```

```
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "ec2:DescribeCapacityReservations",
                "ec2:DescribeLaunchTemplateVersions",
                "ec2:DeleteLaunchTemplateVersions"
            ],
            "Resource": "*"
        }
    ]
}
```

Example

Um gezielte Kapazitätsreservierungen verwenden zu können, müssen Sie die folgenden zusätzlichen Berechtigungen angeben.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "ec2:DescribeCapacityReservations",
                "ec2:DescribeLaunchTemplateVersions",
                "ec2:DeleteLaunchTemplateVersions",
                "resource-groups:ListGroupResources"
            ],
            "Resource": "*"
        }
    ]
}
```

Instance-Flotten für Ihren Cluster konfigurieren

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So erstellen Sie einen Cluster mit Instance-Flotten mithilfe der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Clusterkonfiguration die Option Instance-Flotten aus.
4. Wählen Sie für jede Knotengruppe die Option Instance-Typ hinzufügen und wählen Sie bis zu 5 Instance-Typen für Primär- und Core-Instance-Flotten und bis zu fünfzehn Instance-Typen für Aufgaben-Instance-Flotten aus. Amazon EMR kann jede beliebige Kombination dieser Instance-Typen beim Starten des Clusters bereitstellen.
5. Wählen Sie unter jedem Knotengruppentyp das Drop-Down-Menü Aktionen neben jeder Instance aus, um diese Einstellungen zu ändern:

   EBS-Volumes hinzufügen

   Geben Sie EBS-Volumes an, die an den Instance-Typ angefügt werden sollen, nachdem Amazon EMR ihn bereitgestellt hat.

   Gewichtete Kapazität bearbeiten

   Ändern Sie diesen Wert für die Core-Knotengruppe auf eine beliebige Anzahl von Einheiten, die Ihren Anwendungen entspricht. Die Anzahl der virtuellen YARN-Kerne für jeden Flotten-Instance-Typ wird als standardmäßige gewichtete Kapazitätseinheiten verwendet. Sie können die gewichtete Kapazität für den Primärknoten nicht bearbeiten.

   Den maximalen Spot-Preis bearbeiten

   Geben Sie für jeden Instance-Typ in einer Flotte einen maximalen Spot-Preis an. Sie können den Preis entweder als Prozentsatz des On-Demand-Preises oder als einen bestimmten Betrag in US-Dollar festlegen. Amazon EMR stellt Spot Instances bereit, wenn der aktuelle Spot-Preis in einer Availability Zone unter Ihrem maximalen Spot-Preis liegt. Sie zahlen den Spot-Preis, nicht unbedingt den maximalen Spot-Preis.
6. Um optional Sicherheitsgruppen für Ihre Knoten hinzuzufügen, erweitern Sie EC2-Sicherheitsgruppen (Firewall) im Bereich Netzwerk und wählen Sie Ihre Sicherheitsgruppe für jeden Knotentyp aus.

7. Aktivieren Sie optional das Kontrollkästchen neben Zuweisungsstrategie anwenden, wenn Sie die Option Zuweisungsstrategie verwenden möchten, und wählen Sie die Zuweisungsstrategie aus, die Sie für die Spot Instances angeben möchten. Sie sollten diese Option nicht auswählen, wenn Ihre Amazon-EMR-Servicerolle nicht über die erforderlichen Berechtigungen verfügt. Weitere Informationen finden Sie unter Zuweisungsstrategie für Flotten.
8. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
9. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So erstellen Sie einen Cluster mit Instance-Flotten mithilfe der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Klicken Sie oben im Konsolenfenster auf Zu erweiterten Optionen gehen, geben Sie Softwarekonfigurationsoptionen ein und klicken Sie dann auf Weiter.
4. Wählen Sie unter Cluster-Zusammensetzung die Option Instance-Fotten aus. Wenn Sie die Option Instance-Flotten auswählen, sollten in der Tabelle Cluster-Knoten und Instances Optionen zur Angabe der Zielkapazität von On-Demand- und Spot Instances angezeigt werden.
5. Geben Sie einen Wert in Network (Netzwerk) ein. Wenn Sie in Netzwerk VPC auswählen, wählen Sie ein einzelnes EC2-Subnetz aus oder drücken STRG und klicken, um mehrere Amazon-EC2-Subnetze auszuwählen. Die ausgewählten Subnetze müssen denselben Typ haben (öffentlich oder privat). Wenn Sie nur ein Subnetz auswählen, wird Ihr Cluster in diesem Subnetz gestartet. Wenn Sie eine Gruppe auswählen, wird das am besten passende Subnetz aus der Gruppe ausgewählt, wenn der Cluster startet.

> **Note**
>
> Je nach Konto und Region können Sie in Netzwerk die Option In EC2-Classic startenauswählen. Wenn Sie diese Option auswählen, geben Sie eine oder mehrere EC2 Availability Zones (EC2 Availability Zones) anstelle von EC2 Subnets (EC2-

Subnetzen) an. Weitere Informationen zu IAM-Rollen finden Sie unter IAM-Rollen für Amazon EC2 im Amazon-EC2-Leitfaden für Linux-Instances.

6. Aktivieren Sie unter Zuweisungsstrategie das Kontrollkästchen, um Zuweisungsstrategien anzuwenden, wenn Sie die Option Zuweisungsstrategie verwenden möchten. Weitere Informationen finden Sie unter Zuweisungsstrategie für Flotten.
7. Wenn Sie für jeden Knotentyp den Standardnamen einer Instance-Flotte ändern möchten, wählen Sie das Stiftsymbol aus und geben Sie dann einen benutzerfreundlichen Namen ein. Wenn Sie die Aufgaben-Instance-Flotte entfernen möchten, wählen Sie das X-Symbol auf der rechten Seite der Aufgaben-Zeile.
8. Wählen Sie Instance-Typen zur Flotte hinzufügen/entfernen und wählen Sie bis zu fünf Instance-Typen aus der Liste für Primär- und Core-Instance-Flotten aus. Fügen Sie bis zu fünfzehn Instance-Typen für Aufgaben-Instance-Flotten hinzu. Amazon EMR kann jede beliebige Kombination dieser Instance-Typen beim Starten des Clusters bereitstellen.
9. Wählen Sie für jeden Core- und Aufgaben-Instance-Typ aus, wie Sie die gewichtete Kapazität (jede Instance zählt als X Einheiten) für diese Instance definieren möchten. Die Anzahl der YARN-vCores für jeden Flotten-Instance-Typ wird als standardmäßige gewichtete Kapazitätseinheiten verwendet. Sie können den Wert jedoch auf alle Einheiten ändern, die für Ihre Anwendungen sinnvoll sind.
10. Definieren Sie unter Zielkapazität die Gesamtzahl der On-Demand- und Spot Instances, die Sie pro Flotte benötigen. EMR stellt sicher, dass die Instances in der Flotte die angeforderten Einheiten für On-Demand- und Spot-Zielkapazitäten erfüllen. Wenn für eine Flotte keine On-Demand- oder Spot-Einheiten angegeben sind, wird für diese Flotte keine Kapazität bereitgestellt.
11. Wenn eine Flotte mit einer Zielkapazität für Spot konfiguriert ist, können Sie Ihren maximalen Spot-Preis als Prozentsatz des On-Demand-Preises oder einen Betrag in Dollar ($) in USD eingeben.
12. Um dem Instance-Typ bei der Bereitstellung EBS-Volumes anzufügen, klicken Sie auf das Stiftsymbol neben EBS Storage (EBS-Speicher) und geben dann die EBS-Konfigurationsoptionen ein.
13. Wenn Sie eine sofortige Zählung für Spot-Einheiten eingerichtet haben, legen Sie die erweiterten Spot-Optionen gemäß den folgenden Richtlinien fest:

    - Bereitstellungs-Timeout – Mit diesen Einstellungen können Sie die Aktionen steuern, die Amazon EMR ausführt, wenn keine Spot Instances aus den von Ihnen angegebenen

Flotten-Instance-Typen bereitgestellt werden können. Geben Sie einen Timeout-Zeitraum in Minuten ein und wählen Sie dann die Aktion Terminate the cluster (Den Cluster beenden) oder Switch to provisioning On-Demand-Instances (Zur Bereitstellung von On-Demand-Instances wechseln) aus. Wenn Sie zu On-Demand-Instances wechseln möchten, fließt die gewichtete Kapazität von On-Demand-Instances in die Berechnung der Zielkapazität für Spot Instances ein und Amazon EMR stellt On-Demand-Instances bereit, bis die Zielkapazität für Spot Instances erfüllt ist.

14. Wählen Sie Weiter aus, ändern Sie andere Clustereinstellungen und wählen Sie dann Weiter aus.
15. Wenn Sie sich dafür entschieden haben, die neue Option für die Zuweisungsstrategie anzuwenden, wählen Sie in den Einstellungen für die Sicherheitsoptionen eine EMR-Rolle und ein EC2-Instance-Profil aus, die die für die Option Zuweisungsstrategie erforderlichen Berechtigungen enthalten. Andernfalls schlägt die Cluster-Erstellung fehl.
16. Wählen Sie Create Cluster aus.

AWS CLI

Folgen Sie diesen Richtlinien, um einen Cluster mit Instance-Flotten mit AWS CLI zu erstellen und zu starten:

- Zum Erstellen und Starten eines Clusters mit Instance-Flotten verwenden Sie den Befehl `create-cluster` zusammen mit `--instance-fleet`-Parametern.
- Um mehr Konfigurationsdetails der Instance-Flotten in einem Cluster zu erhalten, verwenden Sie den Befehl `list-instance-fleets`.
- Um einem Cluster, den Sie gerade erstellen, mehrere benutzerdefinierte Amazon-Linux-AMIs hinzuzufügen, verwenden Sie die `CustomAmiId`-Option für jede `InstanceType`-Spezifikation. Sie können Instance-Flottenknoten mit mehreren Instance-Typen und mehreren benutzerdefinierten AMIs entsprechend Ihren Anforderungen konfigurieren. Siehe Beispiele: Erstellen eines Clusters mit der Instance-Flotten-Konfiguration.
- Wenn Sie die Zielkapazität für eine Instance-Flotte ändern möchten, verwenden Sie den Befehl `modify-instance-fleet`.
- Zum Hinzufügen einer Aufgaben-Instance-Flotte zu einem Cluster, dem noch keine Flotte zugewiesen wurde, verwenden Sie den Befehl `add-instance-fleet`.

- Mehrere benutzerdefinierte AMIs können der Aufgaben-Instance-Flotte hinzugefügt werden, indem das Argument CustomAmiId mit dem Befehl add-instance-fleet verwendet wird. Siehe Beispiele: Erstellen eines Clusters mit der Instance-Flotten-Konfiguration.
- Um die Option für die Zuweisungsstrategie bei der Erstellung einer Instance-Flotte zu verwenden, aktualisieren Sie die Servicerolle so, dass sie das Beispielrichtliniendokument im folgenden Abschnitt enthält.
- Um die Optionen für Kapazitätsreservierungen bei der Erstellung einer Instance-Flotte mit On-Demand-Zuweisungsstrategie zu verwenden, aktualisieren Sie die Servicerolle so, dass sie das Beispielrichtliniendokument im folgenden Abschnitt enthält.
- Die Instance-Flotten sind automatisch in der standardmäßigen EMR-Servicerolle und der von Amazon EMR verwalteten Richtlinie (`EMR_DefaultRole` und `AmazonEMRServicePolicy_v2`) enthalten. Wenn Sie eine benutzerdefinierte Servicerolle oder eine vom Kunden verwaltete Richtlinie für Ihren Cluster verwenden, müssen Sie die neuen Berechtigungen für die Zuweisungsstrategie im folgenden Abschnitt hinzufügen.

Beispiele: Erstellen eines Clusters mit der Instance-Flotten-Konfiguration

Die folgenden Beispiele zeigen `create-cluster`-Befehle mit einer Vielzahl von Optionen, die Sie kombinieren können.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige Amazon-EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, verwenden Sie `aws emr create-default-roles`, um sie zu erstellen, bevor Sie den Befehl `create-cluster` eingeben.

Example Beispiel: On-Demand-Primär, On-Demand-Core mit einzelnem Instance-Typ, Standard-VPC

```
aws emr create-cluster --release-label emr-5.3.1 --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \

 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarg
 \

 InstanceFleetType=CORE,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarge}
```

Example Beispiel: Spot-Primär, Spot-Core mit einzelnem Instance-Typ, Standard-VPC

```
aws emr create-cluster --release-label emr-5.3.1 --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \
    InstanceFleetType=MASTER,TargetSpotCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5}'] \
    InstanceFleetType=CORE,TargetSpotCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5}']
```

Example Beispiel: On-Demand-Primär, kombinierter Core mit einzelnem Instance-Typ, einzelnes EC2-Subnetz

```
aws emr create-cluster --release-label emr-5.3.1 --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,SubnetIds=['subnet-ab12345c'] \
  --instance-fleets \
    InstanceFleetType=MASTER,TargetOnDemandCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge}'] \
    InstanceFleetType=CORE,TargetOnDemandCapacity=2,TargetSpotCapacity=6,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5,WeightedCapacity=2}']
```

Example Beispiel: On-Demand-Primär, Spot-Core mit mehreren gewichteten Instance-Typen, Timeout für Spot, Bereich von EC2-Subnetzen

```
aws emr create-cluster --release-label emr-5.3.1 --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,SubnetIds=['subnet-
ab12345c','subnet-de67890f'] \
  --instance-fleets \
    InstanceFleetType=MASTER,TargetOnDemandCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge}'] \
    InstanceFleetType=CORE,TargetSpotCapacity=11,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5,WeightedCapacity=3}',\
'{InstanceType=m4.2xlarge,BidPrice=0.9,WeightedCapacity=5}'],\
LaunchSpecifications={SpotSpecification='{TimeoutDurationMinutes=120,TimeoutAction=SWITCH_TO_ON
```

Example Beispiel: On-Demand-Primär-, gemischter Core und Aufgabe mit mehreren gewichteten Instance-Typen, Timeout für Core-Spot Instances, Bereich von EC2-Subnetzen

```
aws emr create-cluster --release-label emr-5.3.1 --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,SubnetIds=['subnet-
ab12345c','subnet-de67890f'] \
```

```
  --instance-fleets \

 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=m5.xlarg
 \
    InstanceFleetType=CORE,TargetOnDemandCapacity=8,TargetSpotCapacity=6,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5,WeightedCapacity=3}',\
'{InstanceType=m4.2xlarge,BidPrice=0.9,WeightedCapacity=5}'],\
LaunchSpecifications={SpotSpecification='{TimeoutDurationMinutes=120,TimeoutAction=SWITCH_TO_ON
 \
    InstanceFleetType=TASK,TargetOnDemandCapacity=3,TargetSpotCapacity=3,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5,WeightedCapacity=3}']
```

Example Beispiel: Spot-Primär, kein Core oder Aufgabe, Amazon-EBS-Konfiguration, Standard-VPC

```
aws emr create-cluster --release-label Amazon EMR 5.3.1 --service-role EMR_DefaultRole
 \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \
    InstanceFleetType=MASTER,TargetSpotCapacity=1,\
LaunchSpecifications={SpotSpecification='{TimeoutDurationMinutes=60,TimeoutAction=TERMINATE_CLU
\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5,\
EbsConfiguration={EbsOptimized=true,EbsBlockDeviceConfigs=[{VolumeSpecification={VolumeType=gp2
\
SizeIn GB=100}},{VolumeSpecification={VolumeType=io1,SizeInGB=100,Iop
 s=100},VolumesPerInstance=4}]}}']
```

Example Beispiel: Mehrere benutzerdefinierte AMIs, mehrere Instance-Typen, On-Demand-Primär-Instance, On-Demand-Core

```
aws emr create-cluster --release-label Amazon EMR 5.3.1 --service-role EMR_DefaultRole
 \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \
    InstanceFleetType=MASTER,TargetOnDemandCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,CustomAmiId=ami-123456},
{InstanceType=m6g.xlarge, CustomAmiId=ami-234567}'] \
    InstanceFleetType=CORE,TargetOnDemandCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,CustomAmiId=ami-123456},
{InstanceType=m6g.xlarge, CustomAmiId=ami-234567}']
```

Example Beispiel: Einem laufenden Cluster mit mehreren Instance-Typen und mehreren benutzerdefinierten AMIs einen Aufgabenknoten hinzufügen

```
aws emr add-instance-fleet --cluster-id j-123456 --release-label Amazon EMR 5.3.1 \
  --service-role EMR_DefaultRole \
  --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleet \
    InstanceFleetType=Task,TargetSpotCapacity=1,\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,CustomAmiId=ami-123456}',\
'{InstanceType=m6g.xlarge,CustomAmiId=ami-234567}']
```

Example Beispiel: Eine JSON-Konfigurationsdatei verwenden

Sie können Instance-Flotten-Parameter in einer JSON-Datei konfigurieren und dann auf die JSON-Datei als einzigen Parameter für Instance-Flotten verweisen. Mit dem folgenden Befehl wird z. B. auf die JSON-Konfigurationsdatei *my-fleet-config.json* verwiesen:

```
aws emr create-cluster --release-label emr-5.30.0 --service-role EMR_DefaultRole \
--ec2-attributes InstanceProfile=EMR_EC2_DefaultRole \
--instance-fleets file://my-fleet-config.json
```

Die *my-fleet-config.json*-Datei gibt die Primär-, Core- und Aufgaben-Instance-Flotten an, wie im folgenden Beispiel dargestellt. Die Core-Instance-Flotte verwendet einen maximalen Spot-Preis (`BidPrice`) als Prozentsatz des On-Demand-Preises, während die Aufgaben- und Primär-Instance-Flotten einen maximalen Spot-Preis (BidPriceAsPercentageofOnDemandPrice) als Zeichenfolge in USD verwenden.

```
[
    {
        "Name": "Masterfleet",
        "InstanceFleetType": "MASTER",
        "TargetSpotCapacity": 1,
        "LaunchSpecifications": {
            "SpotSpecification": {
                "TimeoutDurationMinutes": 120,
                "TimeoutAction": "SWITCH_TO_ON_DEMAND"
            }
        },
        "InstanceTypeConfigs": [
            {
                "InstanceType": "m5.xlarge",
```

```
                "BidPrice": "0.89"
            }
        ]
    },
    {
        "Name": "Corefleet",
        "InstanceFleetType": "CORE",
        "TargetSpotCapacity": 1,
        "TargetOnDemandCapacity": 1,
        "LaunchSpecifications": {
          "OnDemandSpecification": {
            "AllocationStrategy": "lowest-price",
            "CapacityReservationOptions":
            {
                "UsageStrategy": "use-capacity-reservations-first",
                "CapacityReservationResourceGroupArn": "String"
            }
        },
            "SpotSpecification": {
                "AllocationStrategy": "capacity-optimized",
                "TimeoutDurationMinutes": 120,
                "TimeoutAction": "TERMINATE_CLUSTER"
            }
        },
        "InstanceTypeConfigs": [
            {
                "InstanceType": "m5.xlarge",
                "BidPriceAsPercentageOfOnDemandPrice": 100
            }
        ]
    },
    {
        "Name": "Taskfleet",
        "InstanceFleetType": "TASK",
        "TargetSpotCapacity": 1,
        "LaunchSpecifications": {
          "OnDemandSpecification": {
            "AllocationStrategy": "lowest-price",
            "CapacityReservationOptions":
            {
                "CapacityReservationPreference": "none"
            }
        },
            "SpotSpecification": {
```

```
                "TimeoutDurationMinutes": 120,
                "TimeoutAction": "TERMINATE_CLUSTER"
            }
        },
        "InstanceTypeConfigs": [
            {
                "InstanceType": "m5.xlarge",
                "BidPrice": "0.89"
            }
        ]
    }
]
```

Zielkapazitäten für eine Instance-Flotte ändern

Verwenden Sie den Befehl `modify-instance-fleet`, um neue Zielkapazitäten für eine Instance-Flotte anzugeben. Sie müssen die Cluster-ID und die Instance-Flotten-ID angeben. Verwenden Sie den Befehl `list-instance-fleets` zum Abrufen der Instance-Flotten-IDs.

```
aws emr modify-instance-fleet --cluster-id <cluster-id> \
  --instance-fleet \
    InstanceFleetId='<instance-fleet-id>',TargetOnDemandCapacity=1,TargetSpotCapacity=1
```

Eine Aufgaben-Instance-Flotte zu einem Cluster hinzufügen

Wenn ein Cluster nur über Primär- und Core-Instance-Flotten verfügt, können Sie den Befehl `add-instance-fleet` verwenden, um eine Aufgaben-Instance-Flotte hinzuzufügen. Sie können nur diesen Befehl verwenden, um Aufgaben-Instance-Flotten hinzuzufügen.

```
aws emr add-instance-fleet --cluster-id <cluster-id>
  --instance-fleet \
    InstanceFleetType=TASK,TargetSpotCapacity=1,\
LaunchSpecifications={SpotSpecification='{TimeoutDurationMinutes=20,TimeoutAction=TERMINATE_CLU
\
InstanceTypeConfigs=['{InstanceType=m5.xlarge,BidPrice=0.5}']
```

Konfigurationsdetails der Instance-Flotten in einem Cluster abrufen

Verwenden Sie den Befehl `list-instance-fleets`, um Konfigurationsdetails der Instance-Flotten in einem Cluster abzurufen. Der Befehl erfordert die Eingabe einer Cluster-ID. Das folgende

Beispiel zeigt den Befehl und die Ausgabe für einen Cluster mit einer Primär-Aufgaben-Instance-Gruppe und einer Core-Aufgaben-Instance-Gruppe. Die vollständige Antwortsyntax finden Sie unter ListInstanceFleets in der Amazon-EMR-API-Referenz.

```
list-instance-fleets --cluster-id <cluster-id>
```

```
{
    "InstanceFleets": [
        {
            "Status": {
                "Timeline": {
                    "ReadyDateTime": 1488759094.637,
                    "CreationDateTime": 1488758719.817
                },
                "State": "RUNNING",
                "StateChangeReason": {
                    "Message": ""
                }
            },
            "ProvisionedSpotCapacity": 6,
            "Name": "CORE",
            "InstanceFleetType": "CORE",
            "LaunchSpecifications": {
                "SpotSpecification": {
                    "TimeoutDurationMinutes": 60,
                    "TimeoutAction": "TERMINATE_CLUSTER"
                }
            },
            "ProvisionedOnDemandCapacity": 2,
            "InstanceTypeSpecifications": [
                {
                    "BidPrice": "0.5",
                    "InstanceType": "m5.xlarge",
                    "WeightedCapacity": 2
                }
            ],
            "Id": "if-1ABC2DEFGHIJ3"
        },
        {
            "Status": {
                "Timeline": {
                    "ReadyDateTime": 1488759058.598,
                    "CreationDateTime": 1488758719.811
```

```
                },
                "State": "RUNNING",
                "StateChangeReason": {
                    "Message": ""
                }
            },
            "ProvisionedSpotCapacity": 0,
            "Name": "MASTER",
            "InstanceFleetType": "MASTER",
            "ProvisionedOnDemandCapacity": 1,
            "InstanceTypeSpecifications": [
                {
                    "BidPriceAsPercentageOfOnDemandPrice": 100.0,
                    "InstanceType": "m5.xlarge",
                    "WeightedCapacity": 1
                }
            ],
           "Id": "if-2ABC4DEFGHIJ4"
        }
    ]
}
```

Kapazitätsreservierungen mit Instance-Flotten verwenden

Um On-Demand-Instance-Flotten mit Optionen für Kapazitätsreservierungen zu starten, fügen Sie zusätzliche Servicerollenberechtigungen hinzu, die für die Nutzung von Kapazitätsreservierungsoptionen erforderlich sind. Da Optionen zur Kapazitätsreservierung zusammen mit der On-Demand-Zuweisungsstrategie verwendet werden müssen, müssen Sie auch die für die Zuweisungsstrategie erforderlichen Berechtigungen in Ihre Servicerolle und verwaltete Richtlinie aufnehmen. Weitere Informationen finden Sie unter Zuweisungsstrategie-Berechtigungen.

Amazon EMR unterstützt sowohl offene als auch gezielte Kapazitätsreservierungen. Die folgenden Themen zeigen Konfigurationen von Instance-Flotten, die Sie zusammen mit der `RunJobFlow`-Aktion oder dem `create-cluster`-Befehl verwenden können, um Instance-Flotten mithilfe von On-Demand-Kapazitätsreservierungen zu starten.

Offene Kapazitätsreservierungen nach bestmöglichem Bemühen verwenden

Wenn die On-Demand-Instances des Clusters den in Ihrem Konto verfügbaren Attributen der offenen Kapazitätsreservierungen (Instance-Typ, Plattform, Tenancy und Availability Zone) entsprechen,

werden die Kapazitätsreservierungen automatisch angewendet. Es kann jedoch nicht garantiert werden, dass Ihre Kapazitätsreservierungen genutzt werden. Für die Bereitstellung des Clusters bewertet Amazon EMR alle in der Startanforderung angegebenen Instance-Pools und verwendet den Pool mit dem niedrigsten Preis, der über ausreichend Kapazität verfügt, um alle angeforderten Core-Knoten zu starten. Verfügbare offene Kapazitätsreservierungen, die dem Instance-Pool entsprechen, werden automatisch angewendet. Wenn verfügbare offene Kapazitätsreservierungen nicht mit dem Instance-Pool übereinstimmen, bleiben sie ungenutzt.

Sobald die Core-Knoten bereitgestellt sind, wird die Availability Zone ausgewählt und repariert. Amazon EMR stellt Aufgabenknoten in Instance-Pools bereit, beginnend mit den günstigsten zuerst, in der ausgewählten Availability Zone, bis alle Aufgabenknoten bereitgestellt sind. Verfügbare offene Kapazitätsreservierungen, die den Instance-Pools entsprechen, werden automatisch angewendet.

Im Folgenden finden Sie Anwendungsfälle der Amazon-EMR-Kapazitätszuweisungslogik für die Nutzung offener Kapazitätsreservierungen nach bestem Wissen.

Beispiel 1: Der Instance-Pool mit dem niedrigsten Preis in der Startanfrage verfügt über verfügbare offene Kapazitätsreservierungen

In diesem Fall führt Amazon EMR Kapazität im Instance-Pool mit On-Demand-Instances mit dem niedrigsten Preis ein. Ihre verfügbaren offenen Kapazitätsreservierungen in diesem Instance-Pool werden automatisch verwendet.

On-Demand Strategy	lowest-price		
Requested Capacity	100		
Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Available Open capacity reservations	150	100	100
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	100	-	-
Offene Kapazität sreservierung verwendet	100	-	-

Verfügbare offene Kapazitätsreservierung	50	100	100

Nachdem die Instance-Flotte gestartet wurde, können Sie `describe-capacity-reservations` ausführen, um zu sehen, wie viele ungenutzte Kapazitätsreservierungen verbleiben.

Beispiel 2: Für den Instance-Pool mit dem niedrigsten Preis in der Startanfrage sind keine offenen Kapazitätsreservierungen verfügbar

In diesem Fall führt Amazon EMR Kapazität im Instance-Pool mit On-Demand-Instances mit dem niedrigsten Preis ein. Ihre offenen Kapazitätsreservierungen bleiben jedoch ungenutzt.

On-Demand Strategy	lowest-price		
Requested Capacity	100		
Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Verfügbare offene Kapazitätsreservierung	-	-	100
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	100	-	-
Offene Kapazitätsreservierung verwendet	-	-	-
Verfügbare offene Kapazitätsreservierung	-	-	100

Konfigurieren Sie Instance-Flotten so, dass offene Kapazitätsreservierungen nach bestem Wissen und Gewissen verwendet werden

Wenn Sie die `RunJobFlow`-Aktion verwenden, um einen auf Instance-Flotten basierenden Cluster zu erstellen, legen Sie für die On-Demand-Zuweisungsstrategie die Optionen `lowest-price` und `CapacityReservationPreference` für Kapazitätsreservierungen auf `open` fest. Wenn Sie dieses Feld leer lassen, setzt Amazon EMR alternativ die Kapazitätsreservierungspräferenz der On-Demand-Instance standardmäßig auf `open`.

```
"LaunchSpecifications":
    {"OnDemandSpecification": {
        "AllocationStrategy": "lowest-price",
        "CapacityReservationOptions":
         {
            "CapacityReservationPreference": "open"
         }
        }
    }
```

Sie können auch die Amazon-EMR-CLI verwenden, um mithilfe von offenen Kapazitätsreservierungen einen auf Instance-Flotten basierenden Cluster zu erstellen.

```
aws emr create-cluster \
 --name 'open-ODCR-cluster' \
 --release-label emr-5.30.0 \
 --service-role EMR_DefaultRole \
 --ec2-attributes SubnetId=subnet-22XXXX01,InstanceProfile=EMR_EC2_DefaultRole \
 --instance-fleets
 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=c4.xlarg
 \

 InstanceFleetType=CORE,TargetOnDemandCapacity=100,InstanceTypeConfigs=['{InstanceType=c5.xlarg
{InstanceType=m5.xlarge},{InstanceType=r5.xlarge}'],\
   LaunchSpecifications={OnDemandSpecification='{AllocationStrategy=lowest-
price,CapacityReservationOptions={CapacityReservationPreference=open}}'}
```

Wobei gilt,

- `open-ODCR-cluster` wird durch den Namen des Clusters ersetzt, der offenen Kapazitätsreservierungen verwendet.
- `subnet-22XXXX01` wird durch die Subnetz-ID ersetzt.

Zuerst offene Kapazitätsreservierungen verwenden

Sie können sich dafür entscheiden, bei der Bereitstellung eines Amazon-EMR-Clusters die Zuweisungsstrategie mit dem niedrigsten Preis außer Kraft zu setzen und zuerst verfügbare offene Kapazitätsreservierungen zu verwenden. In diesem Fall bewertet Amazon EMR alle Instance-Pools mit Kapazitätsreservierungen, die in der Startanfrage angegeben wurden, und verwendet den Pool mit dem niedrigsten Preis, der über ausreichend Kapazität verfügt, um alle angeforderten Core-Knoten zu starten. Wenn keiner der Instance-Pools mit Kapazitätsreservierungen über ausreichend Kapazität für die angeforderten Core-Knoten verfügt, greift Amazon EMR auf den im vorherigen Thema beschriebenen bestmöglichen Fall zurück. Das heißt, Amazon EMR bewertet alle in der Startanfrage angegebenen Instance-Pools neu und verwendet den Pool mit dem niedrigsten Preis, der über ausreichende Kapazität verfügt, um alle angeforderten Core-Knoten zu starten. Verfügbare offene Kapazitätsreservierungen, die dem Instance-Pool entsprechen, werden automatisch angewendet. Wenn verfügbare offene Kapazitätsreservierungen nicht mit dem Instance-Pool übereinstimmen, bleiben sie ungenutzt.

Sobald die Core-Knoten bereitgestellt sind, wird die Availability Zone ausgewählt und repariert. Amazon EMR stellt Aufgabenknoten in der ausgewählten Availability Zone in Instance-Pools mit Kapazitätsreservierungen bereit, beginnend mit den günstigsten zuerst, bis alle Aufgabenknoten bereitgestellt sind. Amazon EMR verwendet zuerst die verfügbaren offenen Kapazitätsreservierungen, die für jeden Instance-Pool in der ausgewählten Availability Zone verfügbar sind, und verwendet nur bei Bedarf die niedrigste Preisstrategie, um alle verbleibenden Aufgabenknoten bereitzustellen.

Im Folgenden finden Sie Anwendungsfälle der Amazon-EMR-Kapazitätszuweisungslogik, bei der zuerst offene Kapazitätsreservierungen verwendet werden.

Beispiel 1: Der Instance-Pool mit verfügbaren offenen Kapazitätsreservierungen in der Startanfrage verfügt über ausreichend Kapazität für Core-Knoten

In diesem Fall startet Amazon EMR Kapazität im Instance-Pool mit verfügbaren offenen Kapazitätsreservierungen, unabhängig vom Preis des Instance-Pools. Daher werden Ihre offenen Kapazitätsreservierungen wann immer möglich genutzt, bis alle Core-Knoten bereitgestellt sind.

On-Demand Strategy	lowest-price
Requested Capacity	100
Usage Strategy	use-capacity-reservations-first

Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Available Open capacity reservations	-	-	150
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	-	-	100
Offene Kapazität sreservierung verwendet	-	-	100
Verfügbare offene Kapazitätsreservierung	-	-	50

Beispiel 2: Der Instance-Pool mit verfügbaren Reservierungen für offene Kapazitäten in der Startanfrage verfügt nicht über genügend Kapazität für Core-Knoten

In diesem Fall greift Amazon EMR auf die Einführung von Core-Knoten zurück und verwendet dabei die niedrigste Preisstrategie, wobei Kapazitätsreservierungen bestmöglich genutzt werden.

On-Demand Strategy	lowest-price		
Requested Capacity	100		
Usage Strategy	use-capacity-reservations-first		
Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Available Open capacity reservations	10	50	50
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	100	-	-

Offene Kapazitätsreservierung verwendet	10	-	-
Verfügbare Reservierungen für offene Kapazitäten	-	50	50

Nachdem die Instance-Flotte gestartet wurde, können Sie `describe-capacity-reservations` ausführen, um zu sehen, wie viele ungenutzte Kapazitätsreservierungen verbleiben.

Konfigurieren Sie Instance-Flotten so, dass sie zuerst offene Kapazitätsreservierungen verwenden

Wenn Sie die `RunJobFlow`-Aktion verwenden, um einen auf Instance-Flotten basierenden Cluster zu erstellen, legen Sie für die On-Demand-Zuweisungsstrategie die Optionen `lowest-price` und `UsageStrategy` für `CapacityReservationOptions` auf `use-capacity-reservations-first` fest.

```
"LaunchSpecifications":
    {"OnDemandSpecification": {
        "AllocationStrategy": "lowest-price",
        "CapacityReservationOptions":
         {
            "UsageStrategy": "use-capacity-reservations-first"
         }
       }
    }
```

Sie können auch die Amazon-EMR-CLI verwenden, um einen auf Instance-Flotten basierenden Cluster zu erstellen, indem Sie zunächst Kapazitätsreservierungen verwenden.

```
aws emr create-cluster \
  --name 'use-CR-first-cluster' \
  --release-label emr-5.30.0 \
  --service-role EMR_DefaultRole \
  --ec2-attributes SubnetId=subnet-22XXXX01,InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \

 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=c4.xlarg
 \
```

```
 InstanceFleetType=CORE,TargetOnDemandCapacity=100,InstanceTypeConfigs=['{InstanceType=c5.xlarg
{InstanceType=m5.xlarge},{InstanceType=r5.xlarge}'],\
LaunchSpecifications={OnDemandSpecification='{AllocationStrategy=lowest-
price,CapacityReservationOptions={UsageStrategy=use-capacity-reservations-first}}'}
```

Wobei gilt,

- `use-CR-first-cluster` wird durch den Namen des Clusters ersetzt, der offenen Kapazitätsreservierungen verwendet.
- `subnet-22XXXX01` wird durch die Subnetz-ID ersetzt.

Zuerst gezielte Kapazitätsreservierungen verwenden

Wenn Sie einen Amazon-EMR-Cluster bereitstellen, können Sie sich dafür entscheiden, die Zuweisungsstrategie mit dem niedrigsten Preis außer Kraft zu setzen und zuerst die verfügbaren gezielten Kapazitätsreservierungen zu verwenden. In diesem Fall bewertet Amazon EMR alle Instance-Pools mit gezielten Kapazitätsreservierungen, die in der Startanfrage angegeben wurden, und wählt den Pool mit dem niedrigsten Preis aus, der über ausreichend Kapazität verfügt, um alle angeforderten Core-Knoten zu starten. Wenn keiner der Instance-Pools mit gezielten Kapazitätsreservierungen über ausreichende Kapazitäten für Core-Knoten verfügt, fällt Amazon EMR auf den zuvor beschriebenen Fall der besten Bemühung zurück. Das heißt, Amazon EMR bewertet alle in der Startanforderung angegebenen Instance-Pools neu und wählt den Pool mit dem niedrigsten Preis aus, der über ausreichende Kapazität verfügt, um alle angeforderten Core-Knoten zu starten. Verfügbare offene Kapazitätsreservierungen, die dem Instance-Pool entsprechen, werden automatisch übernommen. Gezielte Kapazitätsreservierungen bleiben jedoch ungenutzt.

Sobald die Core-Knoten bereitgestellt sind, wird die Availability Zone ausgewählt und repariert. Amazon EMR stellt Aufgabenknoten in Instance-Pools mit gezielten Kapazitätsreservierungen bereit, beginnend mit den günstigsten zuerst, in der ausgewählten Availability Zone, bis alle Aufgabenknoten bereitgestellt sind. Amazon EMR versucht zunächst, die verfügbaren gezielten Kapazitätsreservierungen zu verwenden, die für jeden Instance-Pool in der ausgewählten Availability Zone verfügbar sind. Nur bei Bedarf verwendet Amazon EMR dann die Strategie mit dem niedrigsten Preis, um alle verbleibenden Aufgabenknoten bereitzustellen.

Im Folgenden finden Sie Anwendungsfälle der Amazon-EMR-Kapazitätszuweisungslogik, bei der zunächst gezielte Kapazitätsreservierungen verwendet werden.

Beispiel 1: Der Instance-Pool mit verfügbaren gezielten Kapazitätsreservierungen in der Startanfrage verfügt über ausreichend Kapazität für Core-Knoten

In diesem Fall startet Amazon EMR Kapazität im Instance-Pool mit verfügbaren gezielten Kapazitätsreservierungen, unabhängig vom Preis des Instance-Pools. Daher werden Ihre gezielten Kapazitätsreservierungen wann immer möglich genutzt, bis alle Core-Knoten bereitgestellt sind.

On-Demand Strategy	lowest-price		
Usage Strategy	use-capacity-reservations-first		
Requested Capacity	100		
Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Available targeted capacity reservations	-	-	150
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	-	-	100
Gezielte Kapazität sreservierung genutzt	-	-	100
Verfügbare gezielte Kapazitätsreservie rungen	-	-	50

Example Beispiel 2: Der Instance-Pool mit verfügbaren gezielten Kapazitätsreservierungen in der Startanfrage verfügt nicht über ausreichende Kapazität für Core-Knoten

On-Demand Strategy	lowest-price
Requested Capacity	100
Usage Strategy	use-capacity-reservations-first

Instance Type	c5.xlarge	m5.xlarge	r5.xlarge
Available targeted capacity reservations	10	50	50
On-Demand Price	$	$$	$$$
Bereitgestellte Instances	100	-	-
Gezielte Kapazität sreservierungen verwendet	-	-	-
Verfügbare gezielte Kapazitätsreservierungen	10	50	50

Nachdem die Instance-Flotte gestartet wurde, können Sie `describe-capacity-reservations` ausführen, um zu sehen, wie viele ungenutzte Kapazitätsreservierungen verbleiben.

Instance-Flotten so konfigurieren, dass sie zuerst gezielte Kapazitätsreservierungen verwenden

Wenn Sie die `RunJobFlow`-Aktion verwenden, um einen auf Instance-Flotten basierenden Cluster zu erstellen, legen Sie für die On-Demand-Zuweisungsstrategie die Optionen `lowest-price` und `UsageStrategy` für `CapacityReservationOptions` auf `use-capacity-reservations-first` und `CapacityReservationResourceGroupArn` für `CapacityReservationOptions` auf `<your resource group ARN>` fest. Weitere Informationen finden Sie unter Mit On-Demand-Kapazitätsreservierungen arbeiten im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

```
"LaunchSpecifications":
    {"OnDemandSpecification": {
        "AllocationStrategy": "lowest-price",
        "CapacityReservationOptions":
         {
            "UsageStrategy": "use-capacity-reservations-first",
            "CapacityReservationResourceGroupArn": "arn:aws:resource-groups:sa-
east-1:123456789012:group/MyCRGroup"
         }
       }
```

```
    }
```

Wobei `arn:aws:resource-groups:sa-east-1:123456789012:group/MyCRGroup` durch Ihren Ressourcengruppen-ARN ersetzt wird.

Sie können auch die Amazon-EMR-CLI verwenden, um mithilfe gezielter Kapazitätsreservierungen einen auf Instance-Flotten basierenden Cluster zu erstellen.

```
aws emr create-cluster \
  --name 'targeted-CR-cluster' \
  --release-label emr-5.30.0 \
  --service-role EMR_DefaultRole \
  --ec2-attributes SubnetId=subnet-22XXXX01,InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets
 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=c4.xlarg
 \
    InstanceFleetType=CORE,TargetOnDemandCapacity=100,\
InstanceTypeConfigs=['{InstanceType=c5.xlarge},{InstanceType=m5.xlarge},
{InstanceType=r5.xlarge}'],\
LaunchSpecifications={OnDemandSpecification='{AllocationStrategy=lowest-
price,CapacityReservationOptions={UsageStrategy=use-capacity-reservations-
first,CapacityReservationResourceGroupArn=arn:aws:resource-groups:sa-
east-1:123456789012:group/MyCRGroup}}'}
```

Wobei gilt,

- `targeted-CR-cluster` wird mithilfe von gezielten Kapazitätsreservierungen durch den Namen Ihres Clusters ersetzt.
- `subnet-22XXXX01` wird durch die Subnetz-ID ersetzt.
- `arn:aws:resource-groups:sa-east-1:123456789012:group/MyCRGroup` wird durch Ihren Ressourcengruppe-ARN ersetzt.

Vermeiden Sie es, verfügbare offene Kapazitätsreservierungen zu verwenden

Example

Wenn Sie vermeiden möchten, dass Ihre offenen Kapazitätsreservierungen beim Start eines Amazon-EMR-Clusters unerwartet in Anspruch genommen werden, legen Sie die On-Demand-Zuweisungsstrategie auf `lowest-price` und `CapacityReservationPreference` für `CapacityReservationOptions`auf none. Andernfalls setzt Amazon EMR die

Kapazitätsreservierungspräferenz der On-Demand-Instance standardmäßig auf open und versucht, verfügbare offene Kapazitätsreservierungen nach bestem Wissen zu verwenden.

```
"LaunchSpecifications":
    {"OnDemandSpecification": {
        "AllocationStrategy": "lowest-price",
        "CapacityReservationOptions":
         {
            "CapacityReservationPreference": "none"
         }
       }
    }
```

Sie können auch die Amazon-EMR-CLI verwenden, um einen auf einer Instance-Flotte basierenden Cluster zu erstellen, ohne offene Kapazitätsreservierungen zu verwenden.

```
aws emr create-cluster \
  --name 'none-CR-cluster' \
  --release-label emr-5.30.0 \
  --service-role EMR_DefaultRole \
  --ec2-attributes SubnetId=subnet-22XXXX01,InstanceProfile=EMR_EC2_DefaultRole \
  --instance-fleets \

 InstanceFleetType=MASTER,TargetOnDemandCapacity=1,InstanceTypeConfigs=['{InstanceType=c4.xlarg
 \

 InstanceFleetType=CORE,TargetOnDemandCapacity=100,InstanceTypeConfigs=['{InstanceType=c5.xlarg
{InstanceType=m5.xlarge},{InstanceType=r5.xlarge}'],\
LaunchSpecifications={OnDemandSpecification='{AllocationStrategy=lowest-
price,CapacityReservationOptions={CapacityReservationPreference=none}}'}
```

Wobei gilt,

- `none-CR-cluster` wird durch den Namen Ihres Clusters ersetzt, der keine offenen Kapazitätsreservierungen verwendet.
- `subnet-22XXXX01` wird durch die Subnetz-ID ersetzt.

Szenarien für die Verwendung von Kapazitätsreservierungen

In den folgenden Szenarien können Sie von der Verwendung von Kapazitätsreservierungen profitieren.

Szenario 1: Rotation eines Clusters mit langer Laufzeit mithilfe von Kapazitätsreservierungen

Wenn Sie einen Cluster mit langer Laufzeit rotieren, stellen Sie möglicherweise strenge Anforderungen an die Instance-Typen und Availability Zones für die neuen Instances, die Sie bereitstellen. Mit Kapazitätsreservierungen können Sie die Kapazitätssicherung verwenden, um die Cluster-Rotation ohne Unterbrechungen abzuschließen.

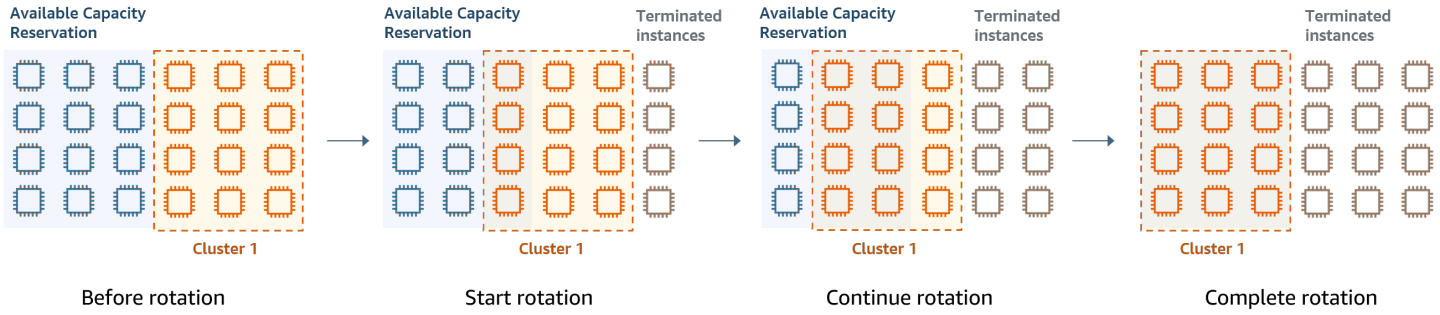

Szenario 2: Bereitstellung aufeinanderfolgender kurzlebiger Cluster mithilfe von Kapazitätsreservierungen

Sie können Kapazitätsreservierungen auch verwenden, um eine Gruppe aufeinanderfolgender, kurzlebiger Cluster für einzelne Workloads bereitzustellen, sodass, wenn Sie einen Cluster beenden, der nächste Cluster die Kapazitätsreservierungen nutzen kann. Sie können gezielte Kapazitätsreservierungen verwenden, um sicherzustellen, dass nur die vorgesehenen Cluster die Kapazitätsreservierungen nutzen.

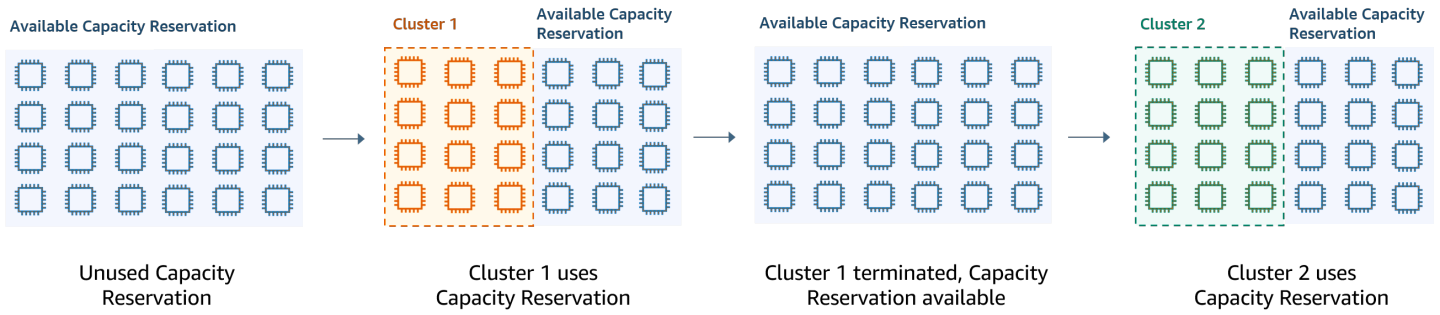

Einheitliche Instance-Gruppen konfigurieren

Mit der Instance-Gruppenkonfiguration besteht jeder Knotentyp (Master-, Core- oder Aufgabenknoten) aus demselben Instance-Typ und derselben Kaufoption für Instances: On-Demand oder Spot. Sie geben diese Einstellungen beim Erstellen einer Instance-Gruppe an. Sie können später nicht mehr geändert werden. Sie können Core- und Aufgaben-Instance-Gruppen jedoch Instances desselben Typs und derselben Kaufoption hinzufügen. Außerdem können Sie Instances entfernen.

Wenn die On-Demand-Instances des Clusters den in Ihrem Konto verfügbaren Attributen der offenen Kapazitätsreservierungen (Instance-Typ, Plattform, Tenancy und Availability Zone) entsprechen, werden die Kapazitätsreservierungen automatisch angewendet. Sie können offene Kapazitätsreservierungen für Primär-, Kern- und Aufgabenknoten verwenden. Sie können jedoch keine gezielten Kapazitätsreservierungen verwenden oder verhindern, dass Instances offene Kapazitätsreservierungen mit übereinstimmenden Attributen starten, wenn Sie Cluster mithilfe von Instancegruppen bereitstellen. Wenn Sie gezielte Kapazitätsreservierungen verwenden oder verhindern möchten, dass Instances aufgrund offener Kapazitätsreservierungen starten, verwenden Sie stattdessen Instance-Flotten. Weitere Informationen finden Sie unter Kapazitätsreservierungen mit Instance-Flotten verwenden.

Zum Hinzufügen verschiedener Instance-Typen nach dem Erstellen eines Clusters können Sie zusätzliche Aufgaben-Instance-Gruppen hinzufügen. Sie können verschiedene Instance-Typen und Kaufoptionen für jede Instance-Gruppe auswählen. Weitere Informationen finden Sie unter Clusterskalierung verwenden.

Beim Starten von Instances ist die Kapazitätsreservierungspräferenz der On-Demand-Instance standardmäßig auf open gesetzt, wodurch sie in jeder offenen Kapazitätsreservierung ausgeführt werden kann, die über passende Attribute (Instance-Typ, Plattform, Verfügbarkeitszone) verfügt. Weitere Informationen über On-Demand-Kapazitätsreservierungen finden Sie unter Kapazitätsreservierungen mit Instance-Flotten verwenden.

In diesem Abschnitt wird das Erstellen eines Clusters mit einheitlichen Instance-Gruppen beschrieben. Weitere Informationen zum Ändern einer vorhandenen Instance-Gruppe durch Hinzufügen oder Entfernen von Instances manuell oder automatisch mit Auto Scaling finden Sie unter Verwalten von Clustern.

Die Konsole zum Konfigurieren einheitlicher Instance-Gruppen verwenden

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So erstellen Sie einen Cluster mit Instance-Gruppen mithilfe der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Clusterkonfiguration die Option Instance-Gruppen aus.
4. Unter Knotengruppen gibt es einen Abschnitt für jeden Knotengruppentyp. Aktivieren Sie für die Primärknotengruppe das Kontrollkästchen Mehrere Primärknoten verwenden, wenn Sie drei Primärknoten haben möchten. Aktivieren Sie das Kontrollkästchen Spot-Kaufoption verwenden, wenn Sie Spot-Kauf verwenden möchten.
5. Wählen Sie für die Primär- und Core-Knotengruppen die Option Instance-Typ hinzufügen und wählen Sie bis zu 5 Instance-Typen aus. Wählen Sie für die Aufgabengruppe Instance-Typ hinzufügen und wählen Sie bis zu fünfzehn Instance-Typen aus. Amazon EMR kann jede beliebige Kombination dieser Instance-Typen beim Starten des Clusters bereitstellen.
6. Wählen Sie unter jedem Knotengruppentyp das Drop-Down-Menü Aktionen neben jeder Instance aus, um diese Einstellungen zu ändern:

   EBS-Volumes hinzufügen

   Geben Sie EBS-Volumes an, die an den Instance-Typ angefügt werden sollen, nachdem Amazon EMR ihn bereitgestellt hat.

   Den maximalen Spot-Preis bearbeiten

   Geben Sie für jeden Instance-Typ in einer Flotte einen maximalen Spot-Preis an. Sie können den Preis entweder als Prozentsatz des On-Demand-Preises oder als einen bestimmten Betrag in US-Dollar festlegen. Amazon EMR stellt Spot Instances bereit, wenn der aktuelle Spot-Preis in einer Availability Zone unter Ihrem maximalen Spot-Preis liegt. Sie zahlen den Spot-Preis, nicht unbedingt den maximalen Spot-Preis.
7. Erweitern Sie optional die Knotenkonfiguration, um eine JSON-Konfiguration einzugeben oder JSON aus Amazon S3 zu laden.
8. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
9. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Das folgende Verfahren beschreibt die Einstellungen in Advanced options (Erweiterte Optionen), die beim Erstellen eines Clusters zur Verfügung stehen. Mit Quick options (Schnelloptionen) können Sie ebenfalls eien Cluster mit Instance-Gruppen-Konfiguration erstellen.

So erstellen Sie einen Cluster mit einheitlichen Instance-Gruppen mithilfe der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus. Wählen Sie in Software Configuration (Softwarekonfiguration) Optionen und dann Next (Weiter) aus.
4. Lassen Sie im Bildschirm Hardware Configuration (Hardwarekonfiguration) die Option Uniform instance groups (Einheitliche Instance-Gruppen) ausgewählt.
5. Wählen Sie in Network (Netzwerk) eine Option und dann das EC2 Subnet (EC2-Subnetz) für Ihren Cluster aus. Das von Ihnen ausgewählte Subnetz ist einer Verfügbarkeitsgruppe zugeordnet, die unter jedem Subnetz aufgeführt wird. Weitere Informationen finden Sie unter Netzwerk konfigurieren.

   > **Note**
   >
   > Je nach Konto und Region können Sie in Netzwerk die Option In EC2-Classic startenauswählen. Wenn Sie diese Option auswählen, geben Sie eine EC2 Availability Zone (EC2 Availability Zone) anstelle eines Werts für EC2 Subnet (EC2-Subnetz) an. Weitere Informationen zu IAM-Rollen finden Sie unter IAM-Rollen für Amazon EC2 im Amazon-EC2-Leitfaden für Linux-Instances.

6. Führen Sie in jeder Zeile für den Node type (Knotentyp) Folgendes aus:

   - Wenn Sie den Standardnamen der Instance-Gruppe ändern möchten, klicken Sie in Knotentyp auf das Bleistiftsymbol und geben einen Anzeigenamen ein. Wenn Sie die Instance-Gruppe Aufgabe entfernen möchten, klicken Sie auf das X-Symbol. Wählen Sie Add task instance group (Aufgaben-Instance-Gruppe hinzufügen) aus, um zusätzliche Instance-Gruppen des Typs Task (Aufgabe) hinzuzufügen.

- Klicken Sie unter Instance-Typ auf das Bleistiftsymbol. Wählen Sie anschließend den Instance-Typ für den jeweiligen Knotentyp aus.

  > **Important**
  >
  > Wenn Sie mithilfe von einen Instance-Typ mit AWS Management Console auswählen, entspricht die Anzahl der für jeden Instance-Typ angezeigten vCPUs der Anzahl der YARN-vcores für diesen Instance-Typ, nicht der Anzahl der EC2-vCPUs für diesen Instance-Typ. Weitere Informationen zur Anzahl der vCPUs für jeden Instance-Typ finden Sie unter Amazon-EC2-Instance-Typen.

- Klicken Sie unter Instance-Typ auf das Bleistiftsymbol für Konfigurationenund bearbeiten Sie dann die Konfigurationen für Anwendungen für die einzelnen Instance-Gruppen.
- Geben Sie in Instance count (Instance-Zahl) die Anzahl der Instances ein, die für die einzelnen Knotentypen jeweils verwendet werden sollen.
- Wählen Sie in Kaufoption die Option On-Demand oder Spot aus. Wenn Sie Spot (Spot) auswählen, wählen Sie eine Option für den Höchstpreis für Spot-Instances aus. Standardmäßig ist die Option On-Demand-Preis als Höchstpreis verwenden ausgewählt. Sie können Set max $/hr (Max. USD/Std. festlegen) und dann Ihren Höchstpreis eingeben. Die Availability Zone für das von Ihnen ausgewählte EC2 Subnet (EC2-Subnetz) liegt unter dem Maximum Spot price (Spot-Höchstpreis).

  > **Tip**
  >
  > Pausieren Sie die QuickInfo für Spot, um den aktuellen Spot-Preis für Availability Zones in der aktuellen Region anzuzeigen. Der niedrigste Spot-Preis ist grün unterlegt. Möglicherweise sollten Sie auf der Basis dieser Informationen Ihre Auswahl in EC2 Subnet (EC2-Subnetz) ändern.

- Klicken Sie in Auto Scaling for Core and Task node types (Auto Scaling für Core- und Aufgabenknotentypen) auf das Bleistiftsymbol und wählen Sie dann die Optionen für Auto Scaling aus. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .

7. Wählen Sie Add task instance group (Aufgaben-Instance-Gruppe hinzufügen) wie gewünscht aus und konfigurieren Sie die Einstellungen wie im vorherigen Schritt beschrieben.

8. Wählen Sie Next (Weiter) aus, ändern Sie weitere Cluster-Einstellungen und starten Sie den Cluster.

Verwenden der AWS CLI zum Erstellen eines Clusters mit einheitlichen Instance-Gruppen

Um die Instance-Gruppenkonfiguration für einen Cluster mithilfe der AWS CLI anzugeben, verwenden Sie den Befehl `create-cluster` zusammen mit dem Parameter `--instance-groups`. Amazon EMR geht von der On-Demand-Instance-Option aus, es sei denn, Sie legen das Argument `BidPrice` für eine Instance-Gruppe fest. Beispiele der Befehle `create-cluster`, mit denen einheitliche Instance-Gruppen mit On-Demand-Instances gestartet werden, und eine Vielzahl von Cluster-Optionen sehen Sie, wenn Sie `aws emr create-cluster help` in der Befehlszeile eingeben oder den Abschnitt create-cluster in der AWS CLI-Befehlsreferenz lesen.

Sie können die AWS CLI zum Erstellen einheitlicher Instance-Gruppen in einem Cluster verwenden, der Spot-Instances nutzt. Der angebotene Spot-Preis hängt der von Availability Zone ab. Wenn Sie die CLI oder API verwenden, können Sie die Availability Zone entweder mit dem Argument `AvailabilityZone` (wenn Sie ein EC2-Classic-Netzwerk verwenden) oder mit dem Argument `SubnetID` des Parameters `--ec2-attributes` angeben. Die ausgewählte Availability Zone oder das Subnetz gilt für den Cluster und wird daher für alle Instance-Gruppen verwendet. Wenn Sie keine Availability Zone oder kein Subnetz explizit angeben, wählt Amazon EMR beim Starten des Clusters die Availability Zone mit dem niedrigsten Spot-Preis aus.

Das folgende Beispiel zeigt einen Befehl `create-cluster`, mit dem Primär-, Core- und zwei Aufgaben-Instance-Gruppen erstellt werden, die alle Spot Instances verwenden. Ersetzen Sie *myKey* durch den Namen Ihres Amazon-EC2-Schlüsselpaars.

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "MySpotCluster" \
  --release-label emr-5.36.1 \
  --use-default-roles \
  --ec2-attributes KeyName=myKey \
  --instance-groups \
```

```
    InstanceGroupType=MASTER,InstanceType=m5.xlarge,InstanceCount=1,BidPrice=0.25 \
    InstanceGroupType=CORE,InstanceType=m5.xlarge,InstanceCount=2,BidPrice=0.03 \
    InstanceGroupType=TASK,InstanceType=m5.xlarge,InstanceCount=4,BidPrice=0.03 \
    InstanceGroupType=TASK,InstanceType=m5.xlarge,InstanceCount=2,BidPrice=0.04
```

Mithilfe der CLI können Sie einheitliche Instance-Gruppen-Cluster erstellen, die für jeden Instance-Typ in der Instance-Gruppe ein eindeutiges benutzerdefiniertes AMI angeben. Auf diese Weise können Sie verschiedene Instance-Architekturen in derselben Instance-Gruppe verwenden. Jeder Instance-Typ muss ein benutzerdefiniertes AMI mit einer passenden Architektur verwenden. Sie würden beispielsweise einen m5.xlarge-Instance-Typ mit einem benutzerdefinierten X86_64-Architektur-AMI und einen m6g.xlarge-Instance-Typ mit einem entsprechenden benutzerdefinierten `AWS AARCH64` (ARM)-Architektur-AMI konfigurieren.

Das folgende Beispiel zeigt einen einheitlichen Instance-Gruppen-Cluster, der mit zwei Instance-Typen erstellt wurde, von denen jeder sein eigenes benutzerdefiniertes AMI hat. Beachten Sie, dass die benutzerdefinierten AMIs nur auf Instance-Typ-Ebene und nicht auf Clusterebene angegeben werden. Dadurch sollen Konflikte zwischen den AMIs des Instance-Typs und einem AMI auf Cluster-Ebene vermieden werden, die dazu führen würden, dass der Clusterstart fehlschlägt.

```
aws emr create-cluster
  --release-label emr-5.30.0 \
  --service-role EMR_DefaultRole \
  --ec2-attributes SubnetId=subnet-22XXXX01,InstanceProfile=EMR_EC2_DefaultRole \
  --instance-groups \

 InstanceGroupType=MASTER,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-123456
 \

 InstanceGroupType=CORE,InstanceType=m6g.xlarge,InstanceCount=1,CustomAmiId=ami-234567
```

Sie können einer Instance-Guppe, die Sie einem laufenden Cluster hinzufügen, mehrere benutzerdefinierte AMIs hinzufügen. Das `CustomAmiId`-Argument kann zusammen mit dem `add-instance-groups`-Befehl verwendet werden, wie im folgenden Beispiel gezeigt.

```
aws emr add-instance-groups --cluster-id j-123456 \
  --instance-groups \

 InstanceGroupType=Task,InstanceType=m5.xlarge,InstanceCount=1,CustomAmiId=ami-123456
```

Verwenden des Java-SDKs zum Erstellen einer Instance-Gruppe

Instanziieren Sie ein Objekt `InstanceGroupConfig`, das die Konfiguration einer Instance-Gruppe für einen Cluster angibt. Um Spot-Instances zu verwenden, legen Sie die Eigenschaften `withBidPrice` und `withMarket` für das Objekt `InstanceGroupConfig` fest. Der folgende Code zeigt, wie Primär-, Core- und Aufgaben-Instance-Gruppen definiert werden, die Spot Instances ausführen.

```
InstanceGroupConfig instanceGroupConfigMaster = new InstanceGroupConfig()
 .withInstanceCount(1)
 .withInstanceRole("MASTER")
 .withInstanceType("m4.large")
 .withMarket("SPOT")
 .withBidPrice("0.25");

InstanceGroupConfig instanceGroupConfigCore = new InstanceGroupConfig()
 .withInstanceCount(4)
 .withInstanceRole("CORE")
 .withInstanceType("m4.large")
 .withMarket("SPOT")
 .withBidPrice("0.03");

InstanceGroupConfig instanceGroupConfigTask = new InstanceGroupConfig()
 .withInstanceCount(2)
 .withInstanceRole("TASK")
 .withInstanceType("m4.large")
 .withMarket("SPOT")
 .withBidPrice("0.10");
```

Bewährte Methoden für Instance- und Availability Zone-Flexibilität

Jede AWS-Region verfügt über mehrere isolierte Standorte, die als Availability Zones bezeichnet werden. Beim Starten einer Instance können Sie optional eine Availability Zone (AZ) oder AWS-Region in der Region angeben, die Sie verwenden. Bei der Flexibilität der Availability Zone handelt es sich um die Verteilung von Instances auf mehrere AZs. Wenn eine Instance ausfällt, können Sie Ihre Anwendung so gestalten, dass eine Instance in einer anderen AZ Anfragen verarbeiten kann. Weitere Informationen zu Availability Zones finden Sie in der Dokumentation zu Regionen und Zonen im Amazon-EC2-Benutzerhandbuch.

Instance-Fexibilität ist die Verwendung mehrerer Instance-Typen zur Erfüllung der Kapazitätsanforderungen. Wenn Sie Flexibilität bei Instances zum Ausdruck bringen, können Sie

die Gesamtkapazität für alle Instance-Größen, Familien und Generationen nutzen. Im Vergleich zu einem Cluster, der einen einzigen Instance-Typ verwendet, verbessert sich die Wahrscheinlichkeit, die erforderliche Menge an Rechenkapazität zu finden und zuzuweisen.

Durch die Flexibilität von Instances und Availability Zones werden Fehler bei unzureichender Kapazität (ICE) und Spot-Unterbrechungen im Vergleich zu einem Cluster mit einem einzigen Instance-Typ oder AZ reduziert. Verwenden Sie die hier beschriebenen bewährten Methoden, um zu bestimmen, welche Instances Sie diversifizieren sollten, nachdem Sie die ursprüngliche Instance-Familie und Größe kennen. Dieser Ansatz maximiert die Verfügbarkeit von Amazon-EC2-Kapazitätspools bei minimaler Leistung und Kostenabweichung.

Flexibilität in Bezug auf Availability Zones

Wir empfehlen, dass Sie alle Availability Zones für die Verwendung in Ihrer Virtual Private Cloud (VPC) konfigurieren und sie für Ihren EMR-Cluster auswählen. Cluster dürfen nur in einer Availability Zone existieren, aber mit Amazon-EMR-Instance-Flotten können Sie mehrere Subnetze für verschiedene Availability Zones auswählen. Wenn Amazon EMR den Cluster startet, sieht er auf diese Subnetze, um die Instances und Kaufoptionen zu finden, die Sie angeben. Wenn Sie einen EMR-Cluster für mehrere Subnetze bereitstellen, kann Ihr Cluster im Vergleich zu Clustern in einem einzelnen Subnetz auf einen größeren Amazon-EC2-Kapazitätspool zugreifen.

Wenn Sie eine bestimmte Anzahl von Availability Zones für die Verwendung in Ihrer Virtual Private Cloud (VPC) für Ihren EMR-Cluster priorisieren müssen, können Sie die Spot-Platzierungsbewertungs-Funktion mit Amazon EC2 nutzen. Mit der Spot-Platzierung geben Sie die Rechenanforderungen für Ihre Spot Instances an. Anschließend gibt EC2 die zehn besten AWS-Regionen oder Availability Zones zurück, die auf einer Skala von 1 bis 10 bewertet wurden. Eine Punktzahl von 10 zeigt an, dass Ihre Spot-Anforderung sehr wahrscheinlich erfolgreich sein wird. Eine Punktzahl von 1 zeigt an, dass Ihre Spot-Anforderung sehr wahrscheinlich nicht erfolgreich sein wird. Weitere Informationen zur Verwendung von Spot-Platzierungsbewertung finden Sie unter Spot-Platzierungsbewertung im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Flexibel sein bei Instance-Typen

Instance-Fexibilität ist die Verwendung mehrerer Instance-Typen zur Erfüllung der Kapazitätsanforderungen. Die Instance-Flexibilität kommt sowohl der Nutzung von Amazon-EC2-Spot- als auch On-Demand-Instances zugute. Mit Spot Instances ermöglicht die Instance-Flexibilität Amazon EC2 den Start von Instances aus tieferen Kapazitätspools unter Verwendung von Echtzeit-Kapazitätsdaten. Außerdem wird vorhergesagt, welche Instances am verfügbarsten sind. Dies bietet weniger Unterbrechungen und kann die Gesamtkosten eines Workloads reduzieren. Mit On-Demand-

Instances reduziert die Instance-Flexibilität Fehler bei unzureichender Kapazität (ICE), wenn die Gesamtkapazität über eine größere Anzahl von Instance-Pools bereitgestellt wird.

Für Instance-Gruppen-Cluster können Sie bis zu 50 EC2-Instance-Typen angeben. Für Instance-Flotten mit Zuweisungsstrategie können Sie bis zu 30 EC2-Instance-Typen für jede Primär-, Core- und Aufgabenknotengruppe angeben. Eine breitere Palette von Instances verbessert die Vorteile der Instance-Flexibilität.

Ausdrücken der Instance-Flexibilität

Beachten Sie die folgenden bewährten Methoden, um die Instance-Flexibilität für Ihre Anwendung zum Ausdruck zu bringen.

Themen

- Die Instance-Familie und -größe ermitteln
- Zusätzliche Instances hinzufügen

Die Instance-Familie und -größe ermitteln

Amazon EMR unterstützt verschiedene Instance-Typen für unterschiedliche Anwendungsfälle. Diese Instance-Typen sind in der Unterstützte Instance-Typen-Dokumentation aufgeführt. Jeder Instance-Typ gehört zu einer Instance-Familie, die beschreibt, für welche Anwendung der Typ optimiert ist.

Bei neuen Workloads sollten Sie einen Vergleich mit Instance-Typen aus der Allzweckfamilie durchführen, z. B. `m5` oder `c5`. Überwachen Sie anschließend die OS- und YARN-Metriken von Ganglia und Amazon CloudWatch zur Ermittlung von Systemengpässe bei Spitzenlast. Zu Engpässen gehören CPU, Arbeitsspeicher, Speicher und I/O. Nachdem Sie die Engpässe identifiziert haben, wählen Sie rechenoptimiert, arbeitsspeicheroptimiert, speicheroptimiert oder eine andere geeignete Instance-Familie für Ihre Instance-Typen. Weitere Informationen finden Sie auf der Seite Die richtige Infrastruktur für Ihre Spark-Workloads ermitteln im Amazon-EMR-Leitfaden für bewährte Methoden auf GitHub.

Identifizieren Sie als Nächstes den kleinsten YARN-Container oder Spark-Executor, den Ihre Anwendung benötigt. Dies ist die kleinste Instance-Größe, die zum Container passt, und die minimale Instance-Größe für den Cluster. Verwenden Sie diese Metrik, um Instances zu ermitteln, mit denen Sie weiter diversifizieren können. Eine kleinere Instance ermöglicht mehr Instance-Flexibilität.

Für maximale Instance-Flexibilität sollten Sie so viele Instances wie möglich nutzen. Wir empfehlen Ihnen, mit Instances zu diversifizieren, die ähnliche Hardwarespezifikationen haben. Dadurch wird

der Zugriff auf EC2-Kapazitätspools bei minimalen Kosten- und Leistungsschwankungen maximiert. Diversifizieren Sie zwischen verschiedenen Größen. Priorisieren Sie dazu zuerst AWS Graviton und frühere Generationen. Als allgemeine Regel gilt: Versuchen Sie, für jeden Workload flexibel über mindestens 15 Instance-Typen hinweg zu sein. Wir empfehlen, mit allgemeinen, rechenoptimierten oder arbeitsspeicheroptimierten Instances zu beginnen. Diese Instance-Typen bieten die größte Flexibilität.

Zusätzliche Instances hinzufügen

Fügen Sie für eine maximale Vielfalt zusätzliche Instance-Typen hinzu. Priorisieren Sie zuerst die Instance-Größe, Graviton und Generierungsflexibilität. Dies ermöglicht den Zugriff auf zusätzliche EC2-Kapazitätspools mit ähnlichen Kosten- und Leistungsprofilen. Wenn Sie aufgrund von ICE- oder punktuellen Unterbrechungen mehr Flexibilität benötigen, sollten Sie die Flexibilität von Varianten und Produktfamilien in Betracht ziehen. Jeder Ansatz hat Kompromisse, die von Ihrem Anwendungsfall und Ihren Anforderungen abhängen.

- Größenflexibilität – Diversifizieren Sie zunächst mit Instances unterschiedlicher Größe innerhalb derselben Produktfamilie. Instances innerhalb derselben Familie bieten dieselben Kosten und dieselbe Leistung, können aber auf jedem Host eine unterschiedliche Anzahl von Containern starten. Wenn die Mindestgröße des Executors, die Sie benötigen, 2 vCPU und 8 GB Arbeitsspeicher beträgt, beträgt die Mindestgröße der Instance `m5.xlarge`. Geben Sie aus Gründen der Größenflexibilität `m5.xlarge`, `m5.2xlarge`, `m5.4xlarge`, `m5.8xlarge`, `m5.12xlarge`, `m5.16xlarge` und `m5.24xlarge` an.
- Graviton-Flexibilität – Neben der Größe können Sie mit Graviton-Instances auch eine größere Vielfalt an Optionen erzielen. Graviton-Instances werden von AWS-Graviton2-Prozessoren angetrieben, die das beste Preis-Leistungs-Verhältnis für Cloud-Workloads in Amazon EC2 bieten. Mit der minimalen Instance-Größe von `m5.xlarge` können Sie beispielsweise `m6g.xlarge`, `m6g.2xlarge`, `m6g.4xlarge`, `m6g.8xlarge` und `m6g.16xlarge` für die Graviton-Flexibilität einschließen.
- Flexibilität bei der Generierung – Ähnlich wie Graviton und Größenflexibilität haben auch Instances der Familien früherer Generationen dieselben Hardwarespezifikationen. Dies führt zu einem ähnlichen Kosten- und Leistungsprofil mit einer Erhöhung des insgesamt zugänglichen Amazon-EC2-Pools. Für Flexibilität bei der Generierung schließen Sie `m4.xlarge`, `m4.2xlarge`, `m4.10xlarge` und `m4.16xlarge` ein.
- Familien- und Variantenflexibilität
  - Kapazität – Um die Kapazität zu optimieren, empfehlen wir Instance-Flexibilität für alle Instance-Familien. Gängige Instances aus verschiedenen Instance-Familien verfügen über tiefere

Instance-Pools, die bei der Erfüllung der Kapazitätsanforderungen helfen können. Instances aus verschiedenen Familien haben jedoch unterschiedliche Verhältnisse zwischen vCPU und Arbeitsspeicher. Dies führt zu einer Unterauslastung, wenn der erwartete Anwendungscontainer für eine andere Instance dimensioniert ist. Schließen Sie beispielsweise mit `m5.xlarge` für Datenverarbeitung optimierte Instances wie `c5` oder arbeitsspeicheroptimierte Instances wie `r5` ein, um die Flexibilität der Instance-Familie zu gewährleisten.

- Kosten – Zur Kostenoptimierung empfehlen wir die variantenübergreifende Instance-Flexibilität. Diese Instances haben das gleiche Speicher- und vCPU-Verhältnis wie die ursprüngliche Instance. Der Nachteil bei der Variantenflexibilität besteht darin, dass diese Instances kleinere Kapazitätspools haben, was zu begrenzter zusätzlicher Kapazität oder höheren Spot-Unterbrechungen führen kann. Zu `m5.xlarge` zählen beispielsweise AMD-basierte Instances (`m5a`), SSD-basierte Instances (`m5d`) oder netzwerkoptimierte Instances (`m5n`) für beispielsweise Variantenflexibilität.

Bewährte Methoden für die Konfiguration des Clusters

Verwenden Sie die Richtlinien in diesem Abschnitt zum Festlegen der Instance-Typen, Kaufoptionen und Speicherkapazität, die für jeden Knotentyp in einem EMR-Cluster bereitgestellt wird.

Welchen Instance-Typ sollten Sie verwenden?

Es gibt mehrere Möglichkeiten zum Hinzufügen von Amazon-EC2-Instances zu Ihrem Cluster. Welche Methode Sie wählen sollten, hängt davon ab, ob Sie die Instance-Gruppen-Konfiguration oder die Instance-Flotten-Konfiguration für den Cluster verwenden.

- Instance-Gruppen
  - Fügen Sie vorhandenen Core- und Task-Instance-Gruppen manuell Instances desselben Typs hinzu.
  - Fügen Sie manuell eine Task-Instance-Gruppe hinzu, die einen anderen Instance-Typ verwenden kann.
  - Richten Sie automatische Abskalierung von Amazon EMR für eine Instance-Gruppe ein, um Instances basierend auf dem Wert für die von Ihnen angegebene Amazon-CloudWatch-Metrik automatisch hinzuzufügen und zu entfernen. Weitere Informationen finden Sie unter Clusterskalierung verwenden.
- Instance-Flotten
  - Fügen Sie eine einzelne Task-Instance-Flotte hinzu.

- Ändern Sie die Zielkapazität für On-Demand- und Spot-Instances für vorhandene Core- und Task-Instance-Flotten. Weitere Informationen finden Sie unter Instance-Flotten konfigurieren.

Eine Möglichkeit zum Planen der Instances Ihres Clusters ist die Ausführung eines Test-Clusters mit einem repräsentativen Beispielsatz von Daten und die Überwachung der Auslastung der Knoten im Cluster. Weitere Informationen finden Sie unter Einen Cluster anzeigen und überwachen. Eine andere Möglichkeit besteht in der Berechnung der Kapazität der Instances, die Sie erwägen, und im Vergleichen dieses Werts mit der Größe Ihrer Daten.

Im Allgemeinen erfordert Primärknoten, der Aufgaben zuweist, keine EC2-Instance mit viel Verarbeitungsleistung. Amazon-EC2-Instances für den Core-Knotentyp, der Aufgaben verarbeitet und Daten in HDFS speichert benötigen sowohl Verarbeitungsleistung als auch Speicherkapazität. Amazon-EC2-Instances für den Aufgabenknotentyp, der keine Daten speichert, brauchen nur Verarbeitungsleistung. Richtlinien zu verfügbaren Amazon-EC2-Instances und deren Konfiguration finden Sie unter Amazon-EC2-Instances konfigurieren.

Die folgenden Richtlinien gelten für die meisten Amazon-EMR-Cluster.

- Es gibt ein vCPU-Limit für die Gesamtzahl der On-Demand-Amazon-EC2-Instances, die Sie pro AWS-Region auf einem AWS-Konto ausführen. Weitere Informationen zum vCPU-Limit und zum Anfordern einer Limiterhöhung für Ihr Konto finden Sie unter On-Demand-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.
- Der Primärknoten stellt keine großen Datenverarbeitungsanforderungen. Für Cluster mit einer großen Anzahl von Knoten oder für Cluster mit Anwendungen, die speziell auf dem Primärknoten bereitgestellt werden (JupyterHub, Hue usw.), ist möglicherweise ein größerer Primärknoten erforderlich, der zur Verbesserung der Clusterleistung beitragen kann. Erwägen Sie beispielsweise, eine m5.xlarge-Instance für kleine Cluster (50 oder weniger Knoten) zu verwenden und für größere Cluster auf einen größeren Instance-Typ umzusteigen.
- Die benötigte Rechenleistung der Core- und Aufgabenknoten hängt von der Art der Verarbeitung ab, die Ihre Anwendung durchführt. Viele Aufträge können auf Allzweck-Instance-Typen ausgeführt werden, die eine ausgewogene Leistung in Bezug auf CPU, Festplattenspeicher und I/O-Durchsatz bieten. Rechenintensive Cluster profitieren von der Ausführung auf High-CPU-Instances, die proportional über mehr CPU-Leistung verfügen als RAM. Datenbank- und Arbeitsspeicher-Caching-Anwendungen können von der Ausführung auf High-Memory-Instances profitieren. Netzwerkintensive und CPU-intensive Anwendungen wie Analyse-, NLP- und Machine Learning-Tools, können von der Ausführung auf Cluster-Datenverarbeitungs-Instances profitieren, da diese proportional hohe CPU-Ressourcen und eine erhöhten Netzwerkleistung bieten.

- Wenn einzelne Phasen Ihres Clusters unterschiedliche Kapazitätserfordernisse haben, können Sie mit einer geringen Anzahl von Core-Knoten beginnen und die Anzahl von Aufgabenknoten den wechselnden Anforderungen der Auftragsverlaufskapazität entsprechend erhöhen oder verringern.
- Die Menge der Daten, die Sie verarbeiten können, hängt von der Kapazität Ihrer Core-Knoten und der Datenmenge als Eingabe, während der Verarbeitung, und als Ausgabe ab. Die Eingabe-, intermediären und Ausgabedatensätze befinden sich während der Verarbeitung alle auf dem Cluster.

Wann sollten Sie Spot Instances verwenden?

Wenn Sie einen Cluster in Amazon EMR starten, können Sie auswählen, ob Sie Primär-, Core- oder Aufgaben-Instances auf Spot Instances starten möchten. Da jeder Typ von Instance-Gruppe eine andere Rolle im Cluster hat, hat das Starten der einzelnen Knotentypen auf Spot-Instances bestimmte Auswirkungen. Sie können eine Instance-Kaufoption nicht ändern, während der Cluster ausgeführt wird. Um On-Demand-Instances in Spot Instances oder umgekehrt zu ändern, müssen Sie im Fall von Primär- und Core-Knoten den Cluster beenden und einen neuen Cluster starten. Im Fall von Aufgabenknoten können Sie eine neue Aufgaben-Instance-Gruppe oder -Flotte starten und die alte entfernen.

Themen

- Amazon-EMR-Einstellungen, die Aufgabenfehler aufgrund des Beendens von Aufgabenknoten-Spot Instances verhindern
- Primärknoten auf einer Spot Instance
- Core-Knoten auf Spot Instances
- Aufgabenknoten auf Spot Instances
- Instance-Konfigurationen für Anwendungsszenarien

Amazon-EMR-Einstellungen, die Aufgabenfehler aufgrund des Beendens von Aufgabenknoten-Spot Instances verhindern

Da Spot Instances häufig zum Ausführen von Aufgabenknoten verwendet werden, verfügt Amazon EMR über Standardfunktionen für die Planung von YARN-Aufträge, sodass laufende Aufträge nicht fehlschlagen, wenn Aufgabenknoten, die auf Spot Instances ausgeführt werden, beendet werden. Amazon EMR ermöglicht dies, indem Anwendungsmasterprozesse nur auf Core-Knoten ausgeführt werden können. Der Anwendungsmasterprozess steuert die Ausführung von Aufträgen und muss während der gesamten Laufzeit des Auftrags aktiv bleiben.

Amazon-EMR-Version 5.19.0 und höher verwendet zu diesem Zweck das integrierte YARN-Knotenbeschriftungsfeature. (Frühere Versionen verwendeten einen Code-Patch). Die Eigenschaften in den Klassifizierungen `yarn-site` und in der `capacity-scheduler`-Konfiguration sind standardmäßig so konfiguriert, dass der YARN-Kapazitätsplaner und der Fair-Scheduler die Vorteile von Knotenbezeichnungen nutzen. Amazon EMR kennzeichnet Core-Knoten automatisch mit dem `CORE`-Label und legt Eigenschaften fest, sodass Anwendungsmaster nur für Knoten mit dem CORE-Label geplant werden. Durch manuelles Ändern verwandter Eigenschaften in den Konfigurationsklassifizierungen von Yarn-Site und Kapazitätsplaner oder direkt in den zugehörigen XML-Dateien könnte diese Feature beeinträchtigt oder verändert werden.

Amazon EMR konfiguriert die folgenden Eigenschaften und Werte standardmäßig. Seien Sie vorsichtig, wenn Sie diese Eigenschaften konfigurieren.

- yarn-site (yarn-site.xml) auf allen Knoten
  - `yarn.node-labels.enabled: true`
  - `yarn.node-labels.am.default-node-label-expression: 'CORE'`
  - `yarn.node-labels.fs-store.root-dir: '/apps/yarn/nodelabels'`
  - `yarn.node-labels.configuration-type: 'distributed'`
- yarn-site (yarn-site.xml) auf Primär- und Core-Knoten
  - `yarn.nodemanager.node-labels.provider: 'config'`
  - `yarn.nodemanager.node-labels.provider.configured-node-partition: 'CORE'`
- capacity-scheduler (capacity-scheduler.xml) auf allen Knoten
  - `yarn.scheduler.capacity.root.accessible-node-labels: '*'`
  - `yarn.scheduler.capacity.root.accessible-node-labels.CORE.capacity: 100`
  - `yarn.scheduler.capacity.root.default.accessible-node-labels: '*'`
  - `yarn.scheduler.capacity.root.default.accessible-node-labels.CORE.capacity: 100`

> **Note**
>
> Beginnend mit der Amazon-EMR-6.x-Release-Reihe ist das Feature YARN-Knotenbeschriftungen standardmäßig deaktiviert. Die Anwendungs-Primär-Prozesse können standardmäßig sowohl auf Core- als auch auf Aufgabenknoten ausgeführt werden.

Sie können die Funktion für YARN-Knotenbeschriftungen aktivieren, indem Sie folgende Eigenschaften konfigurieren:

- `yarn.node-labels.enabled: true`
- `yarn.node-labels.am.default-node-label-expression: 'CORE'`

Primärknoten auf einer Spot Instance

Der Primärknoten kontrolliert und steuert den Cluster. Wenn er beendet wird, wird der Cluster beendet. Daher sollten Sie den Primärknoten nur als Spot Instance starten, wenn Sie einen Cluster ausführen, dessen plötzliche Beendigung akzeptabel ist. Dies kann der Fall sein, wenn Sie eine neue Anwendung testen, wenn Sie einen Cluster vorliegen haben, der Daten in regelmäßigen Abständen in einem externen Speicher wie Amazon S3 ablegt oder wenn Sie einen Cluster ausführen, bei dem die Kosten eine wichtigere Rollen spielen als der Abschluss des Clusters.

Wenn Sie die Primär-Instance-Gruppe als Spot Instance starten, wird der Cluster erst gestartet, wenn die Spot-Instance-Anforderung erfüllt ist. Diese Tatsache muss bei der Auswahl des maximalen Spot-Preises berücksichtigt werden.

Sie können einen Spot-Instance-Primärknoten nur beim Starten des Clusters hinzufügen. Primärknoten können einem aktuell ausgeführten Cluster weder hinzugefügt noch daraus entfernt werden.

Normalerweise führen Sie den Primärknoten nur als Spot Instance aus, wenn Sie den gesamten Cluster (alle Instance-Gruppen) als Spot Instances ausführen.

Core-Knoten auf Spot Instances

Core-Knoten verarbeiten Daten und speichern Informationen mit HDFS. Das Beenden einer Core-Instance birgt das Risiko eines Datenverlusts. Aus diesem Grund sollten Sie Core-Knoten auf Spot-Instances nur dann ausführen, wenn ein teilweiser Verlust von HDFS-Daten toleriert werden kann.

Beim Starten des Core-Instance-Gruppe als Spot Instances wartet Amazon EMR vor dem Starten der Instance-Gruppe, bis alle angeforderten Core-Instances bereitgestellt werden können. Mit anderen Worten, wenn Sie sechs Amazon-EC2-Instances anfordern und nur fünf zu oder unter Ihrem maximalen Spot-Preis verfügbar sind, wird die Instance-Gruppe nicht gestartet. Amazon EMR wartet weiterhin, bis alle sechs Amazon-EC2-Instances verfügbar sind oder bis Sie den Cluster beenden. Sie können die Anzahl der Spot-Instances in einer Core-Instance-Gruppe ändern, um

einem ausgeführten Cluster Kapazitäten hinzuzufügen. Weitere Informationen zum Arbeiten mit Instance-Gruppen und zur Art, wie Spot-Instances mit Instance-Flotten funktionieren, finden Sie unter the section called “Instance-Flotten oder Instance-Gruppen konfigurieren”.

Aufgabenknoten auf Spot Instances

Die Aufgabenknoten verarbeiten Daten, bewahren jedoch keine persistente Daten in HDFS auf. Wenn sie beendet werden da der Spot-Preis über Ihren maximalen Spot-Preis geklettert ist, gehen keine Daten verloren und die Auswirkung auf Ihrem Cluster ist minimal.

Wenn Sie einen oder mehrere Aufgaben-Instance-Gruppen als Spot Instances starten, stellt Amazon EMR so viele Aufgabenknoten wie zu Ihrem maximalen Spot-Preis möglich bereit. Das bedeutet, dass wenn Sie eine Aufgaben-Instance-Gruppe mit sechs Knoten anfordern und nur fünf Spot Instances zu oder unter Ihrem maximalen Spot-Preis verfügbar sind, Amazon EMR die Instance-Gruppe mit fünf Knoten startet und den sechsten nach Möglichkeit später hinzufügt.

Das Starten von Aufgaben-Instance-Gruppen als Spot-Instances stellt eine strategische Möglichkeit dar, die Kapazität Ihres Clusters zu erweitern und gleichzeitig die Kosten zu minimieren. Wenn Sie Ihre Primär- und Kern-Instance-Gruppen als On-Demand-Instances starten, ist ihre Kapazität für die Ausführung des Clusters garantiert. Sie können Ihren Instance-Gruppen nach Bedarf Task-Instances hinzufügen, um ein Spitzenaufkommen an Datenverkehr zu verarbeiten oder die Datenverarbeitung zu beschleunigen.

Sie können Aufgabenknoten über die Konsole, die AWS CLI oder die API hinzufügen oder entfernen. Sie können auch zusätzliche Aufgabengruppen hinzufügen, können aber diese nach dem Erstellen nicht mehr entfernen.

Instance-Konfigurationen für Anwendungsszenarien

Die folgende Tabelle stellt eine kurze Referenz für Knotentyp-Kaufoptionen und -Konfigurationen dar, die für bestimmte Anwendungsszenarien in der Regel geeignet sind. Klicken Sie auf den Link, um weitere Informationen zu den einzelnen Szenariotypen anzuzeigen.

Anwendungsszenario	Kaufoption für Primärknoten	Kaufoption für Core-Knoten	Kaufoption für Aufgabenknoten
Langläufer-Cluster und Data Warehouses	On-Demand	On-Demand oder Instance-Flottenkombination	Spot- oder Instance-Flottenkombination

Anwendungsszenario	Kaufoption für Primärknoten	Kaufoption für Core-Knoten	Kaufoption für Aufgabenknoten
Kostengesteuerte Workloads	Spot-Instances	Spot-Instances	Spot-Instances
Datenkritische Workloads	On-Demand	On-Demand	Spot- oder Instance-Flottenkombination
Testen von Anwendungen	Spot-Instances	Spot-Instances	Spot-Instances

Es gibt verschiedene Szenarien, in denen Spot Instances für die Ausführung eines Amazon-EMR-Clusters nützlich sind.

Langläufer-Cluster und Data Warehouses

Wenn Sie einen permanenten Amazon-EMR-Cluster, z. B. ein Data Warehouse, ausführen, der vorhersehbare Schwankungen der Rechenkapazität bietet, können Sie die Nachfrage in Spitzenzeiten mit Spot Instances kostengünstiger bewältigen. Sie können Ihre Primär- und Core-Instance-Gruppen als On-Demand starten, um die normale Kapazität zu bewältigen, und die Aufgaben-Instance-Gruppe als Spot Instances für Ihre maximale Workload-Anforderungen starten.

Kostengesteuerte Workloads

Wenn Sie kurzlebige Cluster ausführen, für die niedrige Kosten wichtiger sind als die Zeit bis zum Abschluss des Vorgangs, der Verlust von Teilarbeiten akzeptabel ist, können Sie den gesamten Cluster (Primär-, Core- und Aufgaben-Instance-Gruppen) als Spot Instances ausführen, um von den größten Kosteneinsparungen zu profitieren.

Datenkritische Workloads

Wenn Sie einen Cluster ausführen, für den niedrige Kosten wichtiger sind als die Zeit bis zum Abschluss des Vorgangs, der Verlust von Teilarbeiten jedoch nicht akzeptabel ist, können Sie die Primär- und Core-Instance-Gruppen als On-Demand-Instances starten und durch eine oder mehrere Aufgaben-Instance-Gruppen der Spot Instances ergänzen. Wenn Sie die Primär- und Core-Instance-Gruppen als On-Demand-Instance ausführen, wird sichergestellt, dass Ihre Daten in HDFS persistent sind und dass der Cluster vor einer Beendigung aufgrund der Fluktuation des Spot-Markts geschützt ist. Gleichzeitig profitieren Sie von Kosteneinsparungen, die aus der Ausführung der Aufgaben-Instance-Gruppen als Spot Instances resultieren.

Testen von Anwendungen

Wenn Sie eine neue Anwendung testen, um sie für den Start in einer Produktionsumgebung vorzubereiten, können Sie den gesamten Cluster (Primär-, Core- und Aufgaben-Instance-Gruppen) als Spot Instances ausführen, um die Kosten der Tests zu senken.

Berechnen der erforderlichen HDFS-Kapazität eines Clusters

Die Größe des verfügbaren HDFS-Speicher für Ihren Cluster hängt von den folgenden Faktoren ab:

- Die Anzahl der Amazon-EC2-Instances, die für Core-Knoten verwendet werden.
- Die Kapazität des Amazon-EC2-Instance-Speichers für den verwendeten Instance-Typ. Weitere Informationen zu Instance-Speicher-Volumes finden Sie unter Amazon-EC2-Instance-Speicher im Amazon-EC2-Benutzerhandbuch für Linux-Instances.
- Anzahl und Größe von Amazon-EBS-Volumes, die Core-Knoten angefügt sind.
- Ein Replikationsfaktor, der bestimmt, wie jeder Datenblock in HDFS für RAID-Redundanz gespeichert wird. Standardmäßig beträgt der Replikationsfaktor 3 für einen Cluster mit 10 oder mehr Core-Knoten, 2 für einen Cluster mit 4 bis 9 Core-Knoten und 1 für einen Cluster mit maximal 3 Knoten.

Zum Berechnen der Kapazität eines HDFS-Clusters addieren Sie für jeden Core-Knoten die Instance-Speicher-Volume-Kapazität zu der Amazon-EBS-Speicherkapazität (falls verwendet). Multiplizieren Sie das Ergebnis mit der Anzahl der Core-Knoten und dividieren Sie dann die Summe durch den Replikationsfaktor basierend auf der Anzahl der Core-Knoten. Beispiel: Ein Cluster mit 10 Core-Knoten des Typs i2.xlarge, die 800 GB Instance-Speicher ohne angeschlossenen Amazon-EBS-Volumes haben, besitzt insgesamt etwa 2 666 GB für HDFS (10 Knoten x 800 GB ÷ 3 Replikationsfaktor).

Wenn der berechnete HDFS-Kapazitätswert kleiner ist als Ihre Daten, können Sie die HDFS-Speicherkapazität wie folgt erhöhen:

- Erstellen eines Clusters mit zusätzlichen Amazon-EBS-Volumes oder Hinzufügen von Instance-Gruppen mit angefügten Amazon-EBS-Volumes zu einem vorhandenen Cluster
- Hinzufügen weiterer Core-Knoten
- Auswählen eines Amazon-EC2-Instance-Typs mit größerer Speicherkapazität
- Verwenden der Datenkomprimierung
- Ändern der Hadoop-Konfigurationseinstellungen zum Verringern des Replikationsfaktors

Verwenden Sie diese Option mit Bedacht, da durch Verringern des Replikationsfaktors die Redundanz der HDFS-Daten sowie die Cluster-Funktion zur Wiederherstellung von verlorenen oder beschädigten HDFS-Blöcken beeinträchtigt wird.

Konfigurieren der Cluster-Protokollierung und des Debuggings

Bei der Planung Ihres Clusters müssen Sie sich unter anderem für die verfügbare Debugging-Unterstützung entscheiden. Wenn Sie Ihre Datenverarbeitungsanwendung erstmals entwickeln, empfehlen wir Ihnen, die Anwendung auf einem Cluster zu testen, indem Sie eine kleine, aber repräsentative Untermenge Ihrer Daten verarbeiten. Wenn Sie dies tun, möchten Sie wahrscheinlich die Vorteile all der Debugging-Tools in Amazon EMR nutzen, z. B. die Archivierung von Protokolldateien in Amazon S3.

Wenn Sie die Entwicklung Ihrer Anwendung abgeschlossen haben und die Datenverarbeitung in die Produktionsumgebung wechselt, können Sie das Debuggen verringern. Auf diese Weise können Sie die Kosten für die Speicherung von Protokolldateiarchiven in Amazon S3 einsparen und die Verarbeitungslast für den Cluster reduzieren, da dieser den Zustand nicht mehr zu Amazon S3 schreiben muss. Der Nachteil ist, das Ihnen bei Problemen weniger Tools zur Verfügung stehen, um das Problem zu untersuchen.

Standardmäßige Protokolldateien

Standardmäßig schreibt jeder Cluster Protokolldateien auf dem Primärknoten. Die Dateien werden in das `/mnt/var/log/`-Verzeichnis geschrieben. Sie können darauf zugreifen, indem Sie sich, wie in Mit dem Primärknoten über SSH verbinden beschrieben, per SSH mit dem Primärknoten verbinden.

> **Note**
>
> Wenn Sie Amazon-EMR-Version 6.8.0 oder früher verwenden, werden Protokolldateien während der Clusterbeendigung in Amazon S3 gespeichert, sodass Sie nicht mehr auf die Protokolldateien zugreifen können, wenn der Primärknoten beendet wird. Amazon EMR veröffentlicht 6.9.0 und höher und archiviert Protokolle während der Cluster-Herunterskalierung in Amazon S3, sodass die auf dem Cluster generierten Protokolldateien auch nach dem Beenden des Knotens bestehen bleiben.

Sie müssen nicht alles aktivieren, um die Protokolldateien auf dem Primärknoten schreiben zu lassen. Dies ist das Standardverhalten von Amazon EMR und Hadoop.

Ein Cluster generiert mehrere Arten von Protokolldateien. Diese umfassen unter anderem:

- Schritt-Protokolle – Diese Protokolle werden vom Amazon-EMR-Service generiert und enthalten Informationen über den Cluster und die Ergebnisse der einzelnen Schritte. Die Protokolldateien werden im `/mnt/var/log/hadoop/steps/`-Verzeichnis auf dem Primärknoten gespeichert. Jeder Schritt protokolliert seine Ergebnisse in einem separaten, nummerierten Unterverzeichnis: `/mnt/var/log/hadoop/steps/s-stepId1/` für den ersten Schritt, `/mnt/var/log/hadoop/steps/s-stepId2/` für den zweiten Schritt, und so weiter. Die 13-stellige Schritt-ID (z. B. stepId1 stepId2) ist für einen Cluster eindeutig.
- Hadoop- und YARN-Komponentenprotokolle – Die Protokolle für Komponenten (z. B. Apache YARN und MapReduce) befinden sich in separaten Ordnern in `/mnt/var/log`. Die Speicherorte der Protokolldateien für die Hadoop-Komponenten unter `/mnt/var/log` lauten folgendermaßen: hadoop-hdfs, hadoop-mapreduce, hadoop-httpfs und hadoop-yarn. Das Verzeichnis hadoop-state-pusher ist für die Ausgabe des State-Pusher-Prozesses von Hadoop vorgesehen.
- Bootstrap-Aktion-Protokolle – Wenn Ihr Auftrag Bootstrap-Aktionen verwendet, werden die Ergebnisse dieser Aktionen protokolliert. Die Protokolldateien werden in /mnt/var/log/bootstrap-actions/ auf dem Primärknoten gespeichert. Jede Bootstrap-Aktion protokolliert ihre Ergebnisse in einem separaten, nummerierten Unterverzeichnis: `/mnt/var/log/bootstrap-actions/1/` für die erste Bootstrap-Aktion, `/mnt/var/log/bootstrap-actions/2/` für die zweite, und so weiter.
- Instance-Statusprotokolle – Diese Protokolle enthalten Informationen über die CPU, den Arbeitsspeicher und die Garbage Collector-Threads des Knotens. Die Protokolldateien werden in `/mnt/var/log/instance-state/` auf dem Primärknoten gespeichert.

Archivieren von Protokolldateien in Amazon S3

> **Note**
>
> Sie können mit dem `yarn logs`-Dienstprogramm derzeit keine Protokollzusammenführung in Amazon S3 durchführen.

Amazon EMR veröffentlicht 6.9.0 und höher und archiviert Protokolle während der Cluster-Herunterskalierung in Amazon S3, sodass die auf dem Cluster generierten Protokolldateien auch nach dem Beenden des Knotens bestehen bleiben. Dieses Verhalten wird automatisch aktiviert, sodass Sie nichts unternehmen müssen, um es zu aktivieren. Für Amazon-EMR-Versionen 6.8.0

und früher können Sie einen Cluster so konfigurieren, dass die auf dem Primärknoten gespeicherten Protokolldateien regelmäßig in Amazon S3 archiviert werden. Auf diese Weise wird sichergestellt, dass die Protokolldateien verfügbar sind, nachdem der Cluster beendet wird (unabhängig davon, ob dieser normal heruntergefahren wurde oder ob ein Fehler aufgetreten ist). Amazon EMR archiviert die Protokolldateien in 5-Minuten-Intervallen in Amazon S3.

Um die Protokolldateien in Amazon S3 für Amazon-EMR-Versionen 6.8.0 zu archivieren, müssen Sie dieses Feature beim Start des Clusters aktivieren. Sie können dies entweder über Konsole, die CLI oder die API erledigen. Die Protokollierung ist bei über die Konsole gestarteten Clustern standardmäßig aktiviert. Für Cluster, die per CLI oder über die API gestartet wurden, muss die Protokollierung in Amazon S3 manuell aktiviert werden.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Wie Sie Protokolldateien auf Amazon S3 mit der neuen Konsole archivieren

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Aktivieren Sie unter Cluster-Protokolle das Kontrollkästchen Cluster-spezifische Protokolle in Amazon S3 veröffentlichen.
4. Geben Sie im Feld Speicherort von Amazon S3 einen Amazon-S3-Pfad zum Speichern Ihrer Protokolle ein. Wenn Sie den Namen eines Ordners eingeben, der nicht im Bucket vorhanden ist, wird er von Amazon S3 erstellt.

   Wenn Sie diesen Wert festlegen, kopiert Amazon EMR die Protokolldateien von den EC2-Instances im Cluster nach Amazon S3. Dadurch wird verhindert, dass die Protokolldateien verloren gehen, wenn der Cluster beendet wird und EC2 die Instances, die den Cluster hosten, beendet. Diese Protokolle sind bei der Fehlerbehebung hilfreich. Weitere Informationen finden Sie unter Protokolldateien anzeigen.

5. Aktivieren Sie optional das Kontrollkästchen Clusterspezifische Protokolle verschlüsseln. Wählen Sie dann einen AWS KMS-Schlüssel aus der Liste aus, geben Sie einen Schlüssel-ARN ein oder erstellen Sie einen neuen Schlüssel. Diese Option ist nur mit Amazon-EMR-Version 5.30.0 und höher verfügbar, mit Ausnahme von Version 6.0.0. Um diese Option zu verwenden, fügen Sie AWS KMS-Berechtigungen für Ihr EC2-Instance-Profil und die Amazon-EMR-Rolle hinzu. Weitere Informationen finden Sie unter So verschlüsseln Sie Protokolldateien, die Amazon S3 mit einem kundenverwalteten AWS-KMS-Schlüssel gespeichert sind.
6. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
7. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Archivieren Sie Protokolldateien auf Amazon S3 mit der alten Konsole wie folgt

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Belassen Sie im Abschnitt General options (Allgemeine Optionen) im Feld Logging (Protokollierung) die Standardoption Enabled (Aktiviert) bei.

   Diese Option legt fest, ob Amazon EMR detaillierte Protokolldaten in Amazon S3 erfasst. Sie kann nur festgelegt werden, wenn der Cluster erstellt wird. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.
5. Geben Sie im Feld S3-Ordner einen Amazon-S3-Pfad zum Speichern Ihrer Protokolle ein (oder navigieren Sie zu einem Pfad). Sie können auch von der Konsole einen Amazon-S3-Pfad generieren lassen. Wenn Sie den Namen eines Ordners eingeben, der im Bucket nicht existiert, wird der Ordner erstellt.

   Wenn dieser Wert festgelegt ist, kopiert Amazon EMR die Protokolldateien aus den EC2-Instances im Cluster zu Amazon S3. Dadurch können die Protokolldateien nicht verloren gehen, wenn das Cluster beendet wird und die EC2-Instances, von denen das Cluster gehostet wird, beendet werden. Diese Protokolle sind bei der Fehlerbehebung hilfreich.

   Weitere Informationen finden Sie unter Protokolldateien anzeigen.

6. Wählen Sie im Feld Protokollverschlüsselung die Option Protokolle verschlüsseln, die in S3 mit einem kundenverwalteten AWS-KMS-Schlüssel gespeichert sind. Wählen Sie dann einen AWS-KMS-Schlüssel aus der Liste aus oder geben Sie einen Schlüssel-ARN ein. Sie können auch einen neuen AWS KMS-Schlüssel erstellen.

   Diese Option ist nur mit Amazon-EMR-Version 5.30.0 und höher verfügbar, mit Ausnahme von Version 6.0.0. Um diese Option zu verwenden, fügen Sie AWS KMS-Berechtigungen für Ihr EC2-Instance-Profil und die Amazon-EMR-Rolle hinzu. Weitere Informationen finden Sie unter So verschlüsseln Sie Protokolldateien, die Amazon S3 mit einem kundenverwalteten AWS-KMS-Schlüssel gespeichert sind.
7. Fahren Sie mit der Erstellung des Clusters wie unter Cluster planen und konfigurieren beschrieben fort.

CLI

Um Protokolldateien auf Amazon S3 zu archivieren mit AWS CLI

Um Protokolldateien über Amazon S3 zu AWS CLI zu archivieren, geben Sie den Befehl `create-cluster` ein und geben mittels des Parameters `--log-uri` den Amazon-S3-Protokollpfad an.

1. Um Protokolldateien zu Amazon S3 zu archivieren, geben Sie den folgenden Befehl ein und ersetzen *myKey* durch den Namen Ihres EC2-Schlüsselpaars.

```
aws emr create-cluster --name "Test cluster" --release-label emr-5.36.1 --log-
uri s3://DOC-EXAMPLE-BUCKET/logs --applications Name=Hadoop Name=Hive Name=Pig
 --use-default-roles --ec2-attributes KeyName=myKey --instance-type m5.xlarge --
instance-count 3
```

2. Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige Amazon-EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie `aws emr create-default-roles` ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

So verschlüsseln Sie Protokolldateien, die Amazon S3 mit einem kundenverwalteten AWS-KMS-Schlüssel gespeichert sind

Mit Amazon-EMR-Version 5.30.0 und höher (außer Amazon EMR 6.0.0) können Sie in Amazon S3 gespeicherte Protokolldateien mit einem vom Kunden verwalteten AWS-KMS-Schlüssel verschlüsseln. Um diese Option über die Konsole zu aktivieren, führen Sie die Schritte unter Archivieren von Protokolldateien in Amazon S3 aus. Ihr Amazon-EC2-Instance-Profil und Ihre Amazon-EMR-Rolle müssen die folgenden Voraussetzungen erfüllen:

- Das für den Cluster verwendete Amazon-EC2-Instance-Profil muss über die Berechtigung `kms:GenerateDataKey` verfügen.
- Die für den Cluster verwendete Amazon-EMR-Rolle muss über die Berechtigung `kms:DescribeKey` verfügen.
- Das Amazon-EC2-Instance-Profil und die Amazon-EMR-Rolle müssen der Liste der Schlüsselbenutzer für den angegebenen kundenverwalteten AWS-KMS-Schlüssel hinzugefügt werden, wie in den folgenden Schritten gezeigt:
  1. Öffnen Sie die AWS Key Management Service (AWS KMS)-Konsole unter https://console.aws.amazon.com/kms.
  2. Um die AWS-Region zu ändern, verwenden Sie den Region selector (Regionsauswahl) in der oberen rechten Ecke der Seite.
  3. Wählen Sie den Alias des zu ändernden KMS-Schlüssels aus.
  4. Wählen Sie auf der Seite mit den Schlüsseldetails unter Key Users (Schlüsselbenutzer(die Option Add (Hinzufügen) aus.
  5. Wählen Sie im Dialogfeld Schlüsselbenutzer hinzufügen Ihr Amazon-EC2-Instance-Profil und Ihre Amazon-EMR-Rolle aus.
  6. Wählen Sie Add (Hinzufügen) aus.

Weitere Informationen finden Sie unter Von Amazon EMR verwendete IAM-Servicerollen und Verwendung von Schlüsselrichtlinien im AWS-Key-Management-Service-Entwicklerhandbuch.

So aggregieren Sie Protokolle in Amazon S3 über die AWS CLI

> **Note**
>
> Sie können mit dem `yarn logs`-Dienstprogramm derzeit keine Protokollzusammenführung durchführen. Sie können die durch dieses Verfahren unterstützte Aggregation nutzen.

Bei der Protokollaggregation (Hadoop 2.x) werden Protokolle für eine bestimmte Anwendung aus allen Containern in einer einzigen Datei zusammengestellt. Um die Protokollaggregation zu Amazon S3 über die AWS CLI zu aktivieren, verwenden Sie beim Starten des Clusters eine Bootstrap-Aktion, um die Protokollaggregation zu aktivieren und den Bucket zum Speichern der Protokolle anzugeben.

- Um die Protokollaggregation zu aktivieren, erstellen Sie die folgende Konfigurationsdatei mit dem Namen `myConfig.json`, die Folgendes enthält:

```
[
  {
    "Classification": "yarn-site",
    "Properties": {
      "yarn.log-aggregation-enable": "true",
      "yarn.log-aggregation.retain-seconds": "-1",
      "yarn.nodemanager.remote-app-log-dir": "s3:\/\/DOC-EXAMPLE-BUCKET\/logs"
    }
  }
]
```

  Geben Sie den folgenden Befehl ein und ersetzen Sie *myKey* durch den Namen Ihres EC2-Schlüsselpaars. Sie können zusätzlich jeden der roten Texte durch Ihre eigenen Konfigurationen ersetzen.

```
aws emr create-cluster --name "Test cluster" \
--release-label emr-5.36.1 \
--applications Name=Hadoop \
--use-default-roles \
--ec2-attributes KeyName=myKey \
--instance-type m5.xlarge \
--instance-count 3 \
--configurations file://./myConfig.json
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, führen Sie `aws emr create-default-roles` aus, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` ausführen.

Weitere Informationen zu den Amazon-EMR-Befehlen finden Sie unter AWS CLI in der AWS CLI-Befehlsreferenz.

Protokollspeicherorte

Die folgende Liste enthält alle Protokolltypen und ihre Speicherorte in Amazon S3. Sie können diese zur Behebung von Problemen mit Amazon EMR verwenden.

Schrittprotokolle

`s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/steps/<step-id>/`

Anwendungsprotokolle

`s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/containers/`

Dieser Speicherort umfasst Container `stderr` und `stdout`, `directory.info`, `prelaunch.out` und `launch_container.sh`-Protokolle.

Resource-Manager-Protokolle

`s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<leader-instance-id>/applications/hadoop-yarn/`

Hadoop HDFS

`s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<all-instance-id>/applications/hadoop-hdfs/`

Dieser Speicherort umfasst NameNode-, DataNode- und YARN-TimelineServer-Protokolle.

Knoten-Manager-Protokolle

```
s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<all-instance-id>/
applications/hadoop-yarn/
```

Instance-Statusprotokolle

```
s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<all-instance-id>/daemons/
instance-state/
```

Bereitstellungsprotokolle für Amazon EMR

```
s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<leader-instance-id>/
provision-node/*
```

Hive-Protokolle

```
s3://DOC-EXAMPLE-LOG-BUCKET/<cluster-id>/node/<leader-instance-id>/
applications/hive/*
```

- Um Hive-Protokolle in Ihrem Cluster zu finden, entfernen Sie das Sternchen (*) und fügen Sie `/var/log/hive/` an den obigen Link an.
- Um HiveServer2-Protokolle zu finden, entfernen Sie das Sternchen (*) und fügen Sie `var/log/hive/hiveserver2.log` an den obigen Link an.
- Um HiveCLI-Protokolle zu finden, entfernen Sie das Sternchen (*) und fügen Sie `/var/log/hive/user/hadoop/hive.log` an den obigen Link an.
- Um Hive-Metastore-Server-Protokolle zu finden, entfernen Sie das Sternchen (*) und fügen Sie `/var/log/hive/user/hive/hive.log` an den obigen Link an.

Wenn Ihr Fehler im Primär- oder Aufgabenknoten Ihrer Tez-Anwendung auftritt, stellen Sie die Protokolle des entsprechenden Hadoop-Containers bereit.

Das Debugging-Tool aktivieren

Das Debugging-Tool ermöglicht Ihnen, Protokolldateien aus der Amazon-EMR-Konsole zu durchsuchen. Weitere Informationen finden Sie unter Protokolldateien im Debugging-Tool anzeigen. Wenn Sie in einem Cluster Debugging aktivieren, archiviert Amazon EMR die Protokolldateien zu Amazon S3 und indiziert anschließend diese Dateien. Sie können dann die Konsole zum intuitiven Durchsuchen der Schritt-, Auftrags-, Aufgaben- und Aufgabenversuchsprotokolle für den Cluster nutzen.

Um das Debugging-Tool in der Amazon-EMR-Konsole zu verwenden, müssen Sie das Debugging aktivieren, wenn Sie den Cluster mithilfe der Konsole, der Befehlszeilen-Schnittstelle oder der API starten. Beachten Sie, dass die neue Amazon-EMR-Konsole das Debugging-Tool nicht bietet.

Old console

So schalten Sie das Debugging-Tool mit der alten Konsole ein

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Wählen Sie Go to advanced options (Zu erweiterten Optionen navigieren) aus.
4. Wählen Sie im Abschnitt Cluster Configuration (Clusterkonfiguration) im Feld Logging (Protokollierung) die Standardoption Enabled (Aktiviert) aus. Sie können die Debugging-Funktion nicht ohne die Aktivierung der Protokollierung aktivieren.
5. Geben Sie im Feld Speicherort von Amazon S3 einen Amazon-S3-Pfad zum Speichern Ihrer Protokolle ein.
6. Wählen Sie im Feld Debugging (Debuggen) die Option Enabled (Aktiviert) aus. Die Debugging-Option erstellt einen Amazon-SQS-Austausch zur Veröffentlichung von Debugging-Meldungen zum Backend des Amazon-EMR-Services. Möglicherweise fallen Gebühren für die Veröffentlichung von Nachrichten über den Austausch an. Weitere Informationen finden Sie auf der Produktseite für Amazon SQS.
7. Fahren Sie mit der Erstellung des Clusters wie unter Cluster planen und konfigurieren beschrieben fort.

AWS CLI

So aktivieren Sie das Debugging-Tool mit dem AWS CLI

Um das Debugging über die AWS CLI zu aktivieren, geben Sie den Unterbefehl `create-cluster` mit dem Parameter `--enable-debugging` ein. Außerdem müssen Sie den `--log-uri`-Parameter beim Aktivieren des Debuggings angeben.

- Um das Debugging über die AWS CLI zu aktivieren, geben Sie den folgenden Befehl ein und ersetzen *myKey* durch den Namen Ihres EC2-Schlüsselpaars.

```
aws emr create-cluster --name "Test cluster" \
--release-label emr-5.36.1 \
--log-uri s3://DOC-EXAMPLE-BUCKET/logs \
--enable-debugging \
--applications Name=Hadoop Name=Hive Name=Pig \
--use-default-roles \
--ec2-attributes KeyName=myKey \
--instance-type m5.xlarge \
--instance-count 3
```

Wenn Sie die Instance-Anzahl ohne den `--instance-groups`-Parameter angeben, wird ein einzelner Primärknoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

> **Note**
>
> Wenn Sie zuvor nicht die standardmäßige EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie "aws `emr create-default-roles`" ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

API

So aktivieren Sie das Debugging-Tool mit der Amazon-EMR-API

- Aktivieren Sie das Debuggen mit der folgenden Java-SDK-Konfiguration.

```
    StepFactory stepFactory = new StepFactory();
StepConfig enabledebugging = new StepConfig()
    .withName("Enable debugging")
    .withActionOnFailure("TERMINATE_JOB_FLOW")
    .withHadoopJarStep(stepFactory.newEnableDebuggingStep());
```

In diesem Beispiel verwendet `new StepFactory()` `us-east-1` als Standardregion. Wenn der Cluster in einer anderen Region gestartet wird, müssen Sie die Region mit `new StepFactory("region.elasticmapreduce")` angeben, z. B. `new StepFactory("ap-northeast-2.elasticmapreduce")`.

Informationen zur Debugging-Option

Die Amazon-EMR-Versionen 4.1.0 bis 5.27.0 unterstützen Debugging in allen Regionen. Andere Amazon-EMR-Versionen unterstützen die Debugging-Option nicht. Mit Wirkung zum 23. Januar 2023 wird Amazon EMR das Debugging-Tool für alle Versionen einstellen.

Amazon EMR erstellt eine Amazon-SQS-Warteschlange zum Verarbeiten der Debugging-Daten. Möglicherweise fallen Kosten für Nachrichten an. Amazon SQS bietet jedoch ein kostenloses Kontingent von bis zu 1 000 000 Anforderungen. Weitere Informationen finden Sie unter https://aws.amazon.com/https://aws.amazon.com/sqs.

Das Debugging erfordert die Verwendung von Rollen. Ihre Servicerolle und das Instance-Profil müssen die Verwendung aller Amazon-SQS-API-Operationen zulassen. Wenn Ihre Rollen zu verwalteten Amazon-EMR-Richtlinien zugeordnet sind, müssen Sie keine Änderungen an Ihren Rollen vornehmen. Wenn Sie benutzerdefinierte Rollen nutzen, müssen Sie `sqs:*`-Berechtigungen hinzufügen. Weitere Informationen finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.

Tag-Cluster

Es kann nützlich sein, Ihre AWS-Ressourcen auf unterschiedliche Weise zu kategorisieren (z. B. nach Zweck, Eigentümer oder Umgebung). Sie können dies in Amazon EMR durch Zuweisen benutzerdefinierter Metadaten zu Ihren Amazon-EMR-Clustern mithilfe von Tags erreichen. Ein Tag besteht aus einem Schlüssel und einem Wert, die Sie beide selbst definieren können. Für Amazon EMR stellt der Cluster die Ressourcenebene dar, die Sie taggen können. Sie können beispielsweise eine Gruppe von Tags für die Cluster Ihres Kontos definieren, mit deren Hilfe Sie den Besitzer der einzelnen Cluster verfolgen oder eine Produktions-Cluster von einem Test-Cluster unterscheiden können. Wir empfehlen das Erstellen eines einheitlichen Satzes von Tags, um Anforderungen Ihres Unternehmens zu erfüllen.

Wenn Sie einem Amazon-EMR-Cluster ein Tag hinzufügen, wird das Tag zu allen aktiven Amazon-EC2-Instances verteilt, die dem Cluster zugeordnet sind. Entsprechend wird beim Entfernen eines Tags aus einem Amazon-EMR-Cluster das Tag auch aus der zugeordneten aktiven Amazon-EC2-Instance entfernt.

> **Important**
>
> Sie sollten die Amazon-EMR-Konsole oder -CLI verwenden, um Tags in Amazon-EC2-Instances zu verwalten, die Teil eines Clusters sind, und nicht die Amazon-EC2-Konsole

oder -CLI, da in Amazon EC2 durchgeführte Änderungen nicht zurück zum Amazon-EMR-Markierungssystem synchronisiert werden.

Sie können eine Amazon-EC2-Instance identifizieren, die Teil eines Amazon-EMR-Clusters ist, indem Sie die folgenden System-Tags suchen. In diesem Beispiel sind *CORE* der Wert für die Rolle der Instance-Gruppe und *j-12345678* ein Beispiel-ID-Wert für den Auftragsverlauf (Cluster):

- aws:elasticmapreduce:instance-group-role=*CORE*
- aws:elasticmapreduce:job-flow-id=*j-12345678*

> **Note**
>
> Amazon EMR und Amazon EC2 interpretieren Ihre Tags als Zeichenfolge ohne semantische Bedeutung.

Sie können mit der AWS Management Console, CLI und API mit Tags arbeiten.

Sie können Tags beim Erstellen eines neuen Amazon-EMR-Clusters hinzufügen. Außerdem können Sie Tags einem ausgeführten Amazon-EMR-Cluster hinzufügen, in diesem bearbeiten oder aus diesem entfernen. Die Bearbeitung eines Tags bezieht sich auf die Amazon-EMR-Konsole. Wenn Sie die CLI und API zum Bearbeiten eines Tags verwenden, entfernen Sie das alte Tag und fügen ein neues hinzu. Sie können Tag-Schlüssel und Werte bearbeiten und Tags jederzeit aus einer Ressource entfernen, während der Cluster ausgeführt wird. Sie können Tags jedoch nicht hinzufügen, bearbeiten oder aus einem beendeten Cluster oder beendeten Instances entfernen, die zuvor einem Cluster zugeordnet waren, der noch aktiv ist. Darüber hinaus können Sie den Wert eines Tags zwar auf eine leere Zeichenfolge, jedoch nicht auf Null festlegen.

Wenn Sie AWS Identity and Access Management (IAM) mit Ihren Amazon-EC2-Instances für ressourcenbasierte Berechtigungen nach Tag verwenden, werden Ihre IAM-Richtlinien auf Tags angewendet, die Amazon EMR an die Amazon-EC2-Instances eines Clusters weitergibt. Damit Amazon-EMR-Tags an Ihre Amazon-EC2-Instances weitergegeben werden können, muss Ihre IAM-Richtlinie für Amazon EC2 Berechtigungen zum Aufrufen der Amazon-EC2-APIs „CreateTags“ und „DeleteTags“ zulassen. Außerdem können sich verteilte Tags auf die ressourcenbasierten Berechtigungen in Amazon EC2 auswirken. Tags, die zu Amazon EC2 verteilt werden, können genau wie andere Amazon-EC2-Tags als Bedingungen in Ihrer IAM-Richtlinie gelesen werden. Denken Sie

an Ihre IAM-Richtlinie, wenn Sie Ihren Amazon-EMR-Clustern Tags hinzufügen, um zu verhindern, dass Benutzer falsche Berechtigungen für einen Cluster erhalten. Stellen Sie sicher, dass Ihre IAM-Richtlinien keine Bedingungen für Tags enthalten, die Sie auch in Ihrem Amazon-EMR-Cluster verwenden möchten. Andernfalls können Probleme auftreten. Weitere Informationen finden Sie unter Steuern des Zugriffs auf Amazon-EC2-Ressourcen.

Tag (Markierung)-Einschränkungen

Die folgenden grundlegenden Einschränkungen gelten für Tags (Markierungen):

- Einschränkungen für Amazon-EC2-Ressourcen gelten auch für Amazon EMR. Weitere Informationen finden Sie unter https://docs.aws.amazon.com/AWSEC2/latest/UserGuide/Using_Tags.html#tag-restrictions.
- Verwenden Sie in Tag-Namen und -Werten nicht das Präfix `aws:`, da es für die Verwendung durch AWS reserviert ist. Sie können darüber hinaus keine Tag-Namen oder Werte mit diesem Präfix bearbeiten oder löschen.
- Sie können Tags in einem beendeten Cluster nicht ändern oder bearbeiten.
- Ein Tag-Wert kann eine leere Zeichenfolge, aber nicht null sein. Darüber hinaus kann ein Tag-Schlüssel keine leere Zeichenfolge sein.
- Schlüssel und Werte können alphabetische Zeichen in jeder Sprache, numerische Zeichen, Leerzeichen, unsichtbare Trennzeichen und die folgenden Symbole sein: _ . : / = + - @.

Weitere Informationen zum Verwenden von Tags mit der AWS Management Console unter Arbeiten mit Tags in der Konsole im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Weitere Informationen zum Verwenden von Tags mit der Amazon-EC2-API oder Befehlszeilen finden Sie unter Übersicht über API und CLI im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Markieren von Ressourcen für die Fakturierung

Sie können Tags auch zum Strukturieren Ihrer AWS-Abrechnung verwenden, um Ihre eigene Kostenstruktur darzustellen. Dazu müssen Sie sich registrieren, um Ihre AWS-Kontorechnung mit Tag (Markierung)-Schlüsselwerten zu erhalten. Anschließend können Sie Ihre Abrechnungsdaten nach Tag-Schlüsselwerten organisieren, um die Kosten kombinierter Ressourcen zu ermitteln. Obwohl Amazon EMR und Amazon EC2 unterschiedliche Abrechnungen besitzen, werden die Tags für jeden Cluster auch in jede verknüpfte Instance platziert, sodass Sie Tags zum Verknüpfen ähnlicher Amazon-EMR- und Amazon-EC2-Kosten verwenden können.

Beispielsweise können Sie mehrere Ressourcen mit einem bestimmten Anwendungsnamen markieren und dann Ihre Fakturierungsinformationen so organisieren, dass Sie die Gesamtkosten dieser Anwendung über mehrere Services hinweg sehen können. Weitere Informationen finden Sie unter Kostenzuordnung und Tagging im AWS Billing-Benutzerhandbuch.

Hinzufügen von Tags zu einem Cluster

Sie können dem Cluster auch Tags hinzufügen, wenn Sie ihn erstellen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So fügen Sie Tags hinzu, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Tags die Option Neuen Tag hinzufügen aus. Geben Sie im Feld Schlüssel ein Tag an. Geben Sie optional ein Tag im Feld Wert an.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So fügen Sie Tags hinzu, wenn Sie einen Cluster mit der alten Konsole erstellen

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.

3. Geben Sie auf der Seite Step 3: General Cluster Settings (Schritt 3: Allgemeine Cluster-Einstellungen) im Abschnitt Tags einen Schlüssel für Ihr Tag ein.

   Wenn Sie mit der Eingabe des neuen Werts für den Schlüssel beginnen, wird automatisch eine neue Zeile für das nächste neue Tag angezeigt.
4. Optional können Sie einen Wert für das Tag eingeben.
5. Wiederholen Sie die vorherigen Schritte für jedes Tag-Schlüssel/Wert-Paar, das zum Cluster hinzugefügt werden soll. Wenn der Cluster startet, werden alle eingegebenen Tags automatisch mit dem Cluster verknüpft.

AWS CLI

So fügen Sie Tags beim Erstellen eines Clusters mit AWS CLI hinzu

Im folgenden Beispiel wird gezeigt, wie ein Tag einem neuen Cluster über die AWS CLI hinzugefügt wird. Zum Hinzufügen von Tags beim Erstellen eines Clusters geben Sie den Unterbefehl `create-cluster` mit dem Parameter `--tags` ein.

- Um beim Erstellen eines Clusters ein Tag mit dem Namen *costCenter* und dem Schlüsselwert *marketing* hinzuzufügen, geben Sie den folgenden Befehl ein und ersetzen *myKey* durch den Namen Ihres EC2-Schlüsselpaars.

```
aws emr create-cluster --name "Test cluster" --release-label emr-4.0.0 --
applications Name=Hadoop Name=Hive Name=Pig --tags "costCenter=marketing" --
use-default-roles --ec2-attributes KeyName=myKey --instance-type m5.xlarge --
instance-count 3
```

  Wenn Sie die Instance-Anzahl ohne den Parameter `--instance-groups` angeben, wird ein einzelner Master-Knoten gestartet. Die verbleibenden Instances werden dabei als Core-Knoten gestartet. Alle Knoten verwenden den im Befehl angegebenen Instance-Typ.

  > **Note**
  >
  > Wenn Sie zuvor nicht die standardmäßige EMR-Servicerolle und das EC2-Instance-Profil erstellt haben, geben Sie "aws `emr create-default-roles`" ein, um sie zu erstellen, bevor Sie den Unterbefehl `create-cluster` eingeben.

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Sie können Tags auch einem vorhandenen Cluster hinzufügen.

New console

So fügen Sie Tags zu einem vorhandenen Cluster über die neue Konsole hinzu

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Wählen Sie auf der Cluster-Detailseite auf der Registerkarte Tags die Option Tags verwalten aus. Geben Sie im Feld Schlüssel ein Tag an. Geben Sie optional ein Tag im Feld Wert an.
4. Wählen Sie Save Changes (Änderungen speichern) aus. Die Registerkarte Tags wird mit der neuen Anzahl von Tags aktualisiert, die Sie in Ihrem Cluster haben. Wenn Sie jetzt beispielsweise zwei Tags haben, lautet die Bezeichnung Ihres Tabs Tags (2).

Old console

So fügen Sie Tags einem vorhandenen Cluster über die alte Konsole hinzu

1. Wählen Sie in der Amazon-EMR-Konsole die Seite Cluster List aus und klicken Sie auf den Cluster, dem Sie Tags hinzufügen möchten.
2. Klicken Sie auf der Seite Cluster Details (Cluster-Details) im Feld Tags (Tags) auf View All/Edit (Alle anzeigen/Bearbeiten).
3. Klicken Sie auf der Seite View All/Edit (Alle anzeigen/Bearbeiten) auf Add (Hinzufügen).
4. Klicken Sie auf das leere Feld in der Spalte Key (Schlüssel) und geben Sie den Namen Ihres Schlüssels ein.
5. Optional können Sie auf das leere Feld in der Spalte Value (Wert) klicken und den Namen Ihres Werts eingeben.
6. Bei jedem neuen Tag, das Sie eingeben, erscheint eine weitere, leere Tag-Zeile unter dem Tag, den Sie gerade bearbeiten. Wiederholen Sie die vorherigen Schritte für die neue Tag-Zeile für jedes Tag, den Sie hinzufügen möchten.

AWS CLI

So fügen Sie Tags einem aktiven Cluster über die AWS CLI hinzu

- Geben Sie den Unterbefehl `add-tags` mit dem Parameter `--tag` ein, um der Cluster-ID Tags zuzuweisen. Sie können die Cluster-ID mithilfe der Konsole oder des Befehls `list-clusters` finden. Der Unterbefehl `add-tags` akzeptiert derzeit nur einen Ressourcenbezeichner.

  Um beispielsweise zwei Tags zu einem laufenden Cluster hinzuzufügen, eines mit einem Schlüssel namens *`costCenter`* und dem Wert *`marketing`* und ein weiteres mit dem Namen *`other`* mit dem Wert *`accounting`*, geben Sie den folgenden Befehl ein und ersetzen Sie *`j-KT4XXXXXXXX1NM`* durch Ihre Cluster-ID.

  ```
  aws emr add-tags --resource-id j-KT4XXXXXXXX1NM --tag "costCenter=marketing" --
  tag "other=accounting"
  ```

  Beachten Sie, dass beim Hinzufügen von Tags über die AWS-CLI keine Ausgabe des Befehls erfolgt. Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Tags in einem Cluster anzeigen

Wenn Sie alle Tags anzeigen möchten, die mit einem Cluster verknüpft sind, können Sie diese in der Konsole oder AWS CLI ansehen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So zeigen Sie Tags in einem Cluster mit der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.

2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Um alle Ihre Tags anzuzeigen, wählen Sie auf der Cluster-Detailseite die Registerkarte Tags aus.

Old console

So zeigen Sie Tags in einem Cluster mit der alten Konsole an

1. Wählen Sie in der Amazon-EMR-Konsole die Seite Cluster-Liste aus und klicken Sie auf einen Cluster, um die Tags anzeigen.
2. Auf der Seite Cluster Details (Cluster-Details) im Feld Tags (Tags) werden einige Tags angezeigt. Klicken Sie auf View All/Edit (Alle anzeigen/Bearbeiten), um alle verfügbaren Tags im Cluster anzuzeigen.

AWS CLI

Lassen Sie Tags zu einem Cluster mit AWS CLI anzeigen wie folgt

Um die Tags in einem Cluster über die AWS CLI anzuzeigen, geben Sie den Unterbefehl `describe-cluster` mit dem Parameter `--query` ein.

- Um die Tags eines Clusters anzuzeigen, geben Sie den folgenden Befehl ein und ersetzen *`j-KT4XXXXXXXX1NM`* durch Ihre Cluster-ID.

  ```
  aws emr describe-cluster --cluster-id j-KT4XXXXXX1NM --query Cluster.Tags
  ```

  Die Ausgabe enthält alle Tag-Informationen über den Cluster ähnlich wie diese:

  ```
  Value: accounting     Value: marketing
  Key: other            Key: costCenter
  ```

  Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Tags aus einem Cluster entfernen

Wenn Sie ein Tag nicht mehr benötigen, können Sie es aus dem Cluster entfernen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So entfernen Sie Tags in einem Cluster mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Wählen Sie auf der Cluster-Detailseite auf der Registerkarte Tags die Option Tags verwalten aus.
4. Wählen Sie Entfernen für jedes Schlüssel-Wert-Paar, das Sie entfernen möchten.
5. Wählen Sie Save Changes.

Old console

So entfernen Sie Tags in einem Cluster mit der alten Konsole

1. Wählen Sie in der Amazon-EMR-Konsole die Seite Cluster List aus und klicken Sie auf den Cluster, aus dem Sie Tags entfernen möchten.
2. Klicken Sie auf der Seite Cluster Details (Cluster-Details) im Feld Tags (Tags) auf View All/Edit (Alle anzeigen/Bearbeiten).
3. Klicken Sie im Dialogfeld View All/Edit (Alle anzeigen/Bearbeiten) auf das Symbol X neben dem zu löschenden Tag und dann auf Save (Speichern).
4. (Optional) Wiederholen Sie den vorherigen Schritt für jedes Tag-Schlüssel/Wert-Paar, das aus dem Cluster entfernt werden soll.

AWS CLI

So entfernen Sie Tags in einem Cluster mit AWS CLI

Geben Sie den `remove-tags`-Unterbefehl mit dem `--tag-keys`-Parameter ein. Beim Entfernen eines Tags ist nur der Schlüsselname erforderlich.

- Um ein Tag aus einem Cluster zu entfernen, geben Sie den folgenden Befehl ein und ersetzen *j-KT4XXXXXXXX1NM* durch Ihre Cluster-ID.

```
aws emr remove-tags --resource-id j-KT4XXXXXX1NM --tag-keys "costCenter"
```

> **Note**
>
> Sie können derzeit nicht mehrere Tags mit einem einzigen Befehl entfernen.

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Treiber und Drittanbieter-Anwendungsintegration

Sie können verschiedene beliebte Big-Data-Anwendungen in Amazon EMR zu Preisen eines Dienstprogramms ausführen. Das bedeutet, dass Sie eine geringe zusätzliche Gebühr pro Stunde für die Drittanbieter-Anwendung zahlen, während der Cluster ausgeführt wird. So können Sie die Anwendung nutzen, ohne eine Jahreslizenz erwerben zu müssen. Die folgenden Abschnitte beschreiben einige der Tools, die Sie mit EMR verwenden können.

Themen

- Verwenden von Business-Intelligence-Tools in Amazon EMR

Verwenden von Business-Intelligence-Tools in Amazon EMR

Sie können beliebte Business-Intelligence-Tools wie Microsoft Excel, MicroStrategy, QlikView und Tableau mit Amazon EMR verwenden, um Daten zu erkunden und zu visualisieren. Viele dieser Tools erfordern einen ODBC- (Open Database Connectivity) oder JDBC-Treiber (Java Database

Connectivity). Informationen zum Herunterladen und Installieren der neuesten Treiber finden Sie unter http://awssupportdatasvcs.com/bootstrap-actions/Simba/latest/.

Ältere Versionen von Treibern finden Sie unter http://awssupportdatasvcs.com/bootstrap-actions/Simba/.

Sicherheit in Amazon EMR

Die Sicherheit in der Cloud hat bei AWS höchste Priorität. Als AWS-Kunde profitieren Sie von einer Rechenzentrums- und Netzwerkarchitektur, die zur Erfüllung der Anforderungen von Organisationen entwickelt wurden, für die Sicherheit eine kritische Bedeutung hat.

Sicherheit gilt zwischen AWS und Ihnen eine geteilte Verantwortung. Das Modell der geteilten Verantwortung beschreibt dies als Sicherheit der Cloud und Sicherheit in der Cloud:

- Sicherheit der Cloud – AWS ist dafür verantwortlich, die Infrastruktur zu schützen, mit der AWS-Services in der AWS-Cloud ausgeführt werden. AWS stellt Ihnen außerdem Services bereit, die Sie sicher nutzen können. Auditoren von Drittanbietern testen und überprüfen die Effektivität unserer Sicherheitsmaßnahmen im Rahmen der AWS-Compliance-Programme regelmäßig. Informationen zu den Compliance-Programmen, die für Amazon EMR gelten, finden Sie unter AWS-Services im Geltungsbereich nach Compliance-Programm.
- Sicherheit in der Cloud – Ihr Verantwortungsumfang wird durch den AWS-Service bestimmt, den Sie verwenden. Sie sind auch für andere Faktoren verantwortlich, einschließlich der Vertraulichkeit Ihrer Daten, für die Anforderungen Ihres Unternehmens und für die geltenden Gesetze und Vorschriften.

Diese Dokumentation zeigt Ihnen, wie Sie das Modell der übergreifenden Verantwortlichkeit bei der Verwendung von Amazon EMR einsetzen können. Wenn Sie Lösungen in Amazon EMR entwickeln, verwenden Sie die folgenden Technologien, um Cluster-Ressourcen und -Daten entsprechend Ihren Geschäftsanforderungen zu sichern. Die Themen in diesem Kapitel zeigen Ihnen, wie Sie Amazon EMR und andere AWS-Services konfigurieren und verwenden, um Ihre Sicherheits- und Compliance-Ziele zu erfüllen.

Sicherheitskonfigurationen

Bei den Sicherheitskonfigurationen in Amazon EMR handelt es sich um Vorlagen für eine Sicherheitseinrichtung. Sie können eine Sicherheitskonfiguration erstellen, um eine Sicherheitseinrichtung wiederverwenden zu können, wenn Sie einen Cluster erstellen. Weitere Informationen finden Sie unter Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden.

Datenschutz

Sie können Datenverschlüsselung implementieren, um Daten im Ruhezustand in Amazon S3, Daten im Ruhezustand im Cluster-Instance-Speicher und Daten während der Übertragung zu schützen. Weitere Informationen finden Sie unter Verschlüsseln von Daten im Ruhezustand und im Transit.

AWS Identity and Access Management mit Amazon EMR

AWS Identity and Access Management (IAM) ist ein AWS-Service, mit dem ein Administrator den Zugriff auf AWS-Ressourcen sicher steuern kann. IAM-Administratoren steuern, wer authentifiziert (angemeldet) und autorisiert (im Besitz von Berechtigungen) ist, Amazon-EMR-Ressourcen zu nutzen. IAM ist ein AWS-Service, den Sie ohne zusätzliche Kosten verwenden können.

- IAM Identitätsbasierte-Richtlinien erteilen oder verweigern – IAM-Richtlinien erlauben oder verweigern Benutzern und Gruppen Berechtigungen für die Ausführung von Aktionen. Richtlinien können mit Tagging kombiniert werden, um den Zugriff auf Basis einzelner Cluster zu kontrollieren. Weitere Informationen finden Sie unter AWS Identity and Access Management für Amazon EMR.
- IAM Rollen – Die Amazon-EMR-Servicerolle, das Instance-Profil und die serviceverknüpfte Rolle steuern den Zugriff von Amazon EMR auf andere AWS-Services. Weitere Informationen finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.
- IAM-Rollen für EMRFS-Anfragen an Amazon S3 – Wenn Amazon EMR auf Amazon S3 zugreift, können Sie die zu verwendende Rolle basierend auf dem Benutzer, der Gruppe oder dem Speicherort der EMRFS-Daten in Amazon S3 angeben. Auf diese Weise können Sie genau steuern, ob Cluster-Benutzer auf Dateien aus Amazon EMR heraus zugreifen können. Weitere Informationen finden Sie unter Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3.

Kerberos

Sie können Kerberos zur Bereitstellung einer starken Authentifizierung mit Geheimschlüsselkryptografie einrichten. Weitere Informationen finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.

Lake Formation

Sie können Lake Formation-Berechtigungen zusammen mit AWS verwenden, um differenzierten Zugriff auf Spaltenebene auf Datenbanken und Tabellen in AWS Glue Data Catalog zu ermöglichen. ermöglicht Lake Formation über ein Unternehmens-Identitätssystem eine verbundene einmalige Anmeldung bei EMR Notebooks oder Apache Zeppelin. Weitere Informationen finden Sie unter Integrieren Sie Amazon EMR mit AWS Lake Formation.

Secure Socket Shell (SSH)

SSH bietet eine sichere Möglichkeit für Benutzer, Verbindungen mit der Befehlszeile auf Cluster-Instances herzustellen. Außerdem bietet es Tunneling zur Anzeige von Weboberflächen, die von Anwendungen auf dem Master-Knoten gehostet werden. Clients können sich mit Kerberos oder einem Amazon-EC2-Schlüsselpaar authentifizieren. Weitere Informationen finden Sie unter Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen und Verbinden mit einem Cluster.

Amazon EC2-Sicherheitsgruppen

Sicherheitsgruppen dienen als virtuelle Firewall für EMR-Cluster-Instances und begrenzen den ein- und ausgehenden Netzwerkverkehr. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Updates des standardmäßigen Amazon Linux AMI für Amazon EMR

> **Important**
>
> Amazon-EMR-Cluster, auf denen Amazon-Linux- oder Amazon-Linux-2-AMIs (Amazon Linux Machine Images) ausgeführt werden, verwenden das Standardverhalten von Amazon Linux und laden wichtige und kritische Kernel-Updates, die einen Neustart erfordern, nicht automatisch herunter und installieren sie. Dies ist dasselbe Verhalten wie bei anderen Amazon-EC2-Instances, auf denen das standardmäßige Amazon-Linux-AMI ausgeführt wird. Wenn neue Amazon-Linux-Softwareupdates, die einen Neustart erfordern (wie Kernel-, NVIDIA- und CUDA-Updates), nach der Veröffentlichung einer Amazon-EMR-Version

verfügbar werden, laden Amazon-EMR-Cluster-Instances, auf denen das Standard-AMI ausgeführt wird, diese Updates nicht automatisch herunter und installieren sie. Um Kernel-Updates zu erhalten, können Sie Ihr Amazon-EMR-AMI so anpassen, dass es das neueste Amazon-Linux-AMI verwendet.

Abhängig von der Sicherheit Ihrer Anwendung und der Dauer der Ausführung eines Clusters können Sie wählen, ob Sie Ihr Cluster regelmäßig neu starten, um Sicherheitsupdates anzuwenden, oder ob Sie eine Bootstrap-Aktion zum Anpassen von Paketinstallation und Updates erstellen. Sie können außerdem Sicherheitsupdates erst testen und dann auf ausgeführten Cluster-Instances installieren. Weitere Informationen finden Sie unter Verwenden des Standard-Amazon-Linux-AMI für Amazon EMR. Beachten Sie, dass Ihre Netzwerkkonfiguration den HTTP- und HTTPS-Ausgang zu Amazon-Linux-Repositorys in Amazon S3 zulassen muss, da andernfalls Sicherheitsupdates nicht erfolgreich sein werden.

Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden

Mit Amazon-EMR-Version 4.8.0 oder höher können Sie Sicherheitskonfigurationen verwenden, um die Datenverschlüsselung, die Kerberos-Authentifizierung (verfügbar in den Version 5.10.0 und höher) und die Amazon-S3-Autorisierung für EMRFS (verfügbar in den Version 5.10.0 oder höher) zu konfigurieren.

Nach dem Erstellen einer Sicherheitskonfiguration geben Sie an, wenn Sie einen Cluster erstellen. Sie können sie für eine beliebige Anzahl von Clustern verwenden.

Sie können die Konsole, die AWS Command Line Interface (AWS CLI) oder die AWS SDKs verwenden, um eine Sicherheitskonfiguration zu erstellen. Sie können zum Erstellen einer Sicherheitskonfiguration auch eine AWS CloudFormation-Vorlage verwenden. Weitere Informationen finden Sie unter AWS CloudFormation Benutzerhandbuch und in der Vorlagenreferenz für AWS::EMR::SecurityConfiguration.

Themen

- Eine Sicherheitskonfiguration erstellen
- Angabe einer Sicherheitskonfiguration für einen Cluster

Eine Sicherheitskonfiguration erstellen

In diesem Thema werden allgemeine Prozeduren für das Erstellen einer Sicherheitskonfiguration mithilfe der EMR-Konsole und der AWS CLI, behandelt. Zudem enthält es eine Referenz der Parameter, die für eine Verschlüsselung und Authentifizierung sowie für IAM-Rollen für EMRFS verwendet werden. Weitere Informationen zu diesen Funktionen finden Sie in den folgenden Themen:

- Verschlüsseln von Daten im Ruhezustand und im Transit
- Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR
- Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3

So erstellen Sie eine Sicherheitskonfiguration mithilfe der Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Wählen Sie im Navigationsbereich Security Configurations (Sicherheitskonfigurationen), Create security configuration (Sicherheitskonfiguration erstellen) aus.
3. Geben Sie in Name (Name) einen Namen für die Sicherheitskonfiguration ein.
4. Wählen Sie Optionen für Verschlüsselung, und Authentifizierung aus wie in den folgenden Abschnitten beschrieben. Wählen Sie anschließend Erstellen aus.

So erstellen Sie eine Sicherheitskonfiguration mithilfe der AWS CLI

- Verwenden Sie den Befehl `create-security-configuration` wie im folgenden Beispiel gezeigt.
  - Geben Sie in *`SecConfigName`* den Namen der Sicherheitskonfiguration an. Dies ist der Name, den Sie angeben, wenn Sie einen Cluster erstellen, der diese Sicherheitskonfiguration verwendet.
  - Geben Sie in *`SecConfigDef`* eine Inline-JSON-Struktur oder den Pfad zu einer lokalen JSON-Datei an, z. B. *`file://MySecConfig.json`*. Die JSON-Parameter definieren Optionen für Verschlüsselung, IAM Rollen für EMRFS-Zugriff auf Amazon S3 und Authentifizierung, wie in den folgenden Abschnitten beschrieben.

```
aws emr create-security-configuration --name "SecConfigName" --security-
configuration SecConfigDef
```

Datenverschlüsselung konfigurieren

Bevor Sie die Verschlüsselung in einer Sicherheitskonfiguration konfigurieren, erstellen Sie die Schlüssel und Zertifikate, die für die Verschlüsselung verwendet werden. Weitere Informationen finden Sie unter Bereitstellen von Schlüsseln für die Verschlüsselung von Daten im Ruhezustand mit Amazon EMR und Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung.

Beim Erstellen einer Sicherheits-Konfiguration legen Sie zwei Verschlüsselungsoptionen fest: Verschlüsselung von Daten während der Übertragung und im Ruhezustand. Die Optionen für die Datenverschlüsselung im Ruhezustand umfassen sowohl die Amazon S3-Verschlüsselung mit EMRFS und die lokale Laufwerksverschlüsselung. Die Optionen für die Verschlüsselung von Daten während der Übertragung aktivieren die Open-Source-Verschlüsselungsfunktionen für bestimmte Anwendungen, die Transport Layer Security (TLS) unterstützen. Die Optionen für die Verschlüsselung während der Übertragung und im Ruhezustand können gemeinsam oder einzeln aktiviert werden. Weitere Informationen finden Sie unter Verschlüsseln von Daten im Ruhezustand und im Transit.

> **Note**
>
> Wenn Sie AWS KMS auswählen, fallen für die Speicherung und Nutzung der Verschlüsselungsschlüssel Gebühren an. Weitere Informationen finden Sie unter AWS KMS-Preisgestaltung.

Angeben von Verschlüsselungsoptionen mit der Konsole

Wählen Sie Optionen unter Encryption (Verschlüsselung) entsprechend den folgenden Anleitungen aus.

- Wählen Sie Optionen unter At rest encryption (Verschlüsselung im Ruhezustand) aus, um innerhalb des Dateisystems gespeicherte Daten zu verschlüsseln.

  Sie können Daten in Amazon S3, auf lokalen Datenträgern oder in beiden Speichern verschlüsseln.
- Unter S3-Datenverschlüsselung, für die Option Verschlüsselungsmodus wählen Sie einen Wert aus, der festlegt, wie Amazon EMR; die Amazon-S3-Daten mit EMRFS verschlüsselt.

  Der nächste Schritt hängt von dem von Ihnen gewählten Verschlüsselungsmodus ab:
  - SSE-S3 (SSE-S3)

Angaben zur serverseitigen Verschlüsselung mit von Amazon S3 verwalteten Schlüsseln. Sie müssen nicht mehr tun, da Amazon S3 die Handhabung der Schlüssel für Sie übernimmt.

- SSE-KMS (SSE-KMS) oder CSE-KMS (CSE-KMS)

  Gibt serverseitige Verschlüsselung mit AWS KMS-verwalteten Schlüsseln (SSE-KMS) oder clientseitige Verschlüsselung mit AWS KMS-verwalteten Schlüsseln (CSE-KMS) an. Wählen Sie für AWS KMS key einen Schlüssel aus. Der Schlüssel muss sich in derselben Region befinden wie Ihr EMR-Cluster. Schlüsselanforderungen finden Sie unter Verwenden von AWS KMS keys für die Verschlüsselung.

- CSE-Custom (CSE-Custom)

  Gibt clientseitige Verschlüsselung mit einem benutzerdefinierten clientseitigen Masterschlüssel (CSE-Custom) an. Geben Sie für das S3-Objekt den Speicherort Ihrer benutzerdefinierten Schlüsselanbieter-JAR-Datei in Amazon S3 oder den Amazon-S3-ARN ein. Geben Sie dann im Feld Key provider class (Schlüsselanbieterklasse) den vollständigen Klassennamen einer in Ihrer Anwendung deklarierten Klasse ein, die die EncryptionMaterialsProvider-Schnittstelle implementiert.

- Wählen Sie unter Local disk encryption (Lokale Laufwerksverschlüsselung) einen Wert für Key provider type (Schlüsselanbietertyp) aus.

  - AWS KMS key

    Wählen Sie diese Option, um eine AWS KMS key anzugeben. Wählen Sie für AWS KMS key einen Schlüssel aus. Der Schlüssel muss sich in derselben Region befinden wie Ihr EMR-Cluster. Weitere Informationen zu den Anforderungen für Schlüssel finden Sie unter Verwenden von AWS KMS keys für die Verschlüsselung.

    EBS Encryption (EBS-Verschlüsselung)

    Wenn Sie AWS KMS als Schlüsselanbieter angeben, können Sie die EBS-Verschlüsselung aktivieren, um EBS-Root-Volumes und Speicher-Volumes zu verschlüsseln. Um diese Option zu aktivieren, müssen Sie der EMR-Servicerolle `EMR_DefaultRole` Berechtigungen zur Verwendung des von Ihnen angegebenen Kundenmasterschlüssels (CMK) AWS KMS key erteilen. Weitere Informationen zu den Anforderungen für Schlüssel finden Sie unter Aktivieren der EBS-Verschlüsselung durch Bereitstellung zusätzlicher Berechtigungen für KMS-Schlüssel.

  - Custom (Benutzerdefiniert)

Wählen Sie diese Option aus, um einen benutzerdefinierten Schlüsselanbieter festzulegen. Geben Sie für das S3-Objekt den Speicherort Ihrer benutzerdefinierten Schlüsselanbieter-JAR-Datei in Amazon S3 oder den Amazon-S3-ARN ein. Geben Sie im Feld Key provider class (Schlüsselanbieterklasse) den vollständigen Klassennamen einer in der Anwendung deklarierten Klasse ein, die die EncryptionMaterialsProvider-Schnittstelle implementiert. Der Klassenname, den Sie hier angeben, muss sich von dem Klassennamen für CSE-Custom unterscheiden.

- Wählen Sie In-transit encryption (Verschlüsselung bei Übertragung) aus, um die Open-Source-TLS-Verschlüsselungsfunktionen für Daten während der Übertragung zu aktivieren. Wählen Sie anhand der folgenden Anleitungen einen Certificate provider type (Zertifikatanbietertyp) aus:
  - PEM (PEM)

    Wählen Sie diese Option zur Verwendung von PEM-Dateien aus, die Sie in einer ZIP-Datei bereitstellen. Zwei Artefakte sind innerhalb der ZIP-Datei erforderlich: privateKey.pem und certificateChain.pem. Eine dritte Datei, trustedCertificates.pem, ist optional. Details dazu finden Sie unter Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung. Geben Sie in S3-Objekt den Speicherort in Amazon S3 oder den Amazon-S3-ARN des ZIP-Datei-Felds an.
  - Custom (Benutzerdefiniert)

    Wählen Sie diese Option aus, um einen benutzerdefinierten Zertifikatanbieter anzugeben. Geben Sie anschließend in S3-Objekt den Speicherort in Amazon S3 oder den Amazon-S3-ARN der JAR-Datei Ihres benutzerdefinierten Zertifikatanbieters ein. Geben Sie in Key provider class (Schlüsselanbieterklasse) den vollständigen Klassennamen einer in der Anwendung deklarierten Klasse ein, die die TLSArtifactsProvider-Schnittstelle implementiert.

Angeben von Verschlüsselungsoptionen mit der AWS CLI

Die folgenden Abschnitte enthalten Beispielszenarien mit ordnungsgemäß formatiertem --security-configuration JSON für verschiedene Konfigurationen und Schlüsselanbieter, gefolgt von einer Referenz für JSON-Parameter und geeignete Werte.

Beispiel der Datenverschlüsselungsoptionen während der Übertragung

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist aktiviert und die Verschlüsselung von Daten im Ruhezustand ist deaktiviert.

- Eine ZIP-Datei mit Zertifikaten in Amazon S3 wird als Schlüsselanbieter verwendet (die Zertifikatanforderungen finden Sie unter Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung).

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": true,
  "EnableAtRestEncryption": false,
  "InTransitEncryptionConfiguration": {
   "TLSCertificateConfiguration": {
    "CertificateProviderType": "PEM",
    "S3Object": "s3://MyConfigStore/artifacts/MyCerts.zip"
   }
  }
 }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist aktiviert und die Verschlüsselung von Daten im Ruhezustand ist deaktiviert.
- Ein benutzerdefinierter Schlüsselanbieter wird verwendet (die Zertifikatanforderungen finden Sie unter Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung).

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": true,
  "EnableAtRestEncryption": false,
  "InTransitEncryptionConfiguration": {
   "TLSCertificateConfiguration": {
    "CertificateProviderType": "Custom",
    "S3Object": "s3://MyConfig/artifacts/MyCerts.jar",
    "CertificateProviderClass": "com.mycompany.MyCertProvider"
   }
  }
  }
```

```
}'
```

Beispiel der Datenverschlüsselungsoptionen im Ruhezustand

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist deaktiviert und die Verschlüsselung von Daten im Ruhezustand ist aktiviert.
- Für die Amazon-S3-Verschlüsselung wird SSE-S3 verwendet.
- Die lokale Laufwerksverschlüsselung verwendet AWS KMS als Schlüsselanbieter.

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": false,
  "EnableAtRestEncryption": true,
  "AtRestEncryptionConfiguration": {
   "S3EncryptionConfiguration": {
    "EncryptionMode": "SSE-S3"
   },
   "LocalDiskEncryptionConfiguration": {
    "EncryptionKeyProviderType": "AwsKms",
    "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
   }
  }
  }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Datenverschlüsselung während der Übertragung ist aktiviert und verweist unter Verwendung der ARN auf eine ZIP-Datei mit PEM-Zertifikaten in Amazon S3.
- Für die KMS-Verschlüsselung wird SSE-Amazon S3 verwendet.
- Die lokale Laufwerksverschlüsselung verwendet AWS KMS als Schlüsselanbieter.

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": true,
```

```
  "EnableAtRestEncryption": true,
  "InTransitEncryptionConfiguration": {
   "TLSCertificateConfiguration": {
    "CertificateProviderType": "PEM",
    "S3Object": "arn:aws:s3:::MyConfigStore/artifacts/MyCerts.zip"
   }
  },
  "AtRestEncryptionConfiguration": {
   "S3EncryptionConfiguration": {
    "EncryptionMode": "SSE-KMS",
    "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
   },
   "LocalDiskEncryptionConfiguration": {
    "EncryptionKeyProviderType": "AwsKms",
    "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
   }
  }
 }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Datenverschlüsselung während der Übertragung ist aktiviert und verweist auf eine ZIP-Datei mit PEM-Zertifikaten in Amazon S3.
- Für die Amazon-S3-Verschlüsselung wird CSE-KMS verwendet.
- Die lokale Laufwerksverschlüsselung verwendet einen benutzerdefinierten Schlüsselanbieter, auf den anhand des ARN verwiesen wird.

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": true,
  "EnableAtRestEncryption": true,
  "InTransitEncryptionConfiguration": {
   "TLSCertificateConfiguration": {
    "CertificateProviderType": "PEM",
    "S3Object": "s3://MyConfigStore/artifacts/MyCerts.zip"
   }
  },
```

```
  "AtRestEncryptionConfiguration": {
   "S3EncryptionConfiguration": {
    "EncryptionMode": "CSE-KMS",
    "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
   },
   "LocalDiskEncryptionConfiguration": {
    "EncryptionKeyProviderType": "Custom",
    "S3Object": "arn:aws:s3:::artifacts/MyKeyProvider.jar",
    "EncryptionKeyProviderClass": "com.mycompany.MyKeyProvider"
   }
  }
 }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung anhand eines benutzerdefinierten Schlüsselanbieters ist aktiviert.
- CSE-Custom wird für Amazon-S3-Daten verwendet.
- Die lokale Laufwerksverschlüsselung verwendet einen benutzerdefinierten Schlüsselanbieter.

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
 "EncryptionConfiguration": {
  "EnableInTransitEncryption": "true",
  "EnableAtRestEncryption": "true",
  "InTransitEncryptionConfiguration": {
   "TLSCertificateConfiguration": {
    "CertificateProviderType": "Custom",
    "S3Object": "s3://MyConfig/artifacts/MyCerts.jar",
    "CertificateProviderClass": "com.mycompany.MyCertProvider"
   }
  },
  "AtRestEncryptionConfiguration": {
   "S3EncryptionConfiguration": {
    "EncryptionMode": "CSE-Custom",
    "S3Object": "s3://MyConfig/artifacts/MyCerts.jar",
    "EncryptionKeyProviderClass": "com.mycompany.MyKeyProvider"
    },
   "LocalDiskEncryptionConfiguration": {
```

```
    "EncryptionKeyProviderType": "Custom",
    "S3Object": "s3://MyConfig/artifacts/MyCerts.jar",
    "EncryptionKeyProviderClass": "com.mycompany.MyKeyProvider"
   }
  }
 }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist deaktiviert und die Verschlüsselung von Daten im Ruhezustand ist aktiviert.
- Die Amazon S3-Verschlüsselung ist mit SSE-KMS aktiviert.
- Es werden mehrere AWS KMS Schlüssel verwendet, einer pro S3-Bucket, und Verschlüsselungsausnahmen werden auf diese einzelnen S3-Buckets angewendet.
- Die lokale Laufwerksverschlüsselung ist deaktiviert.

```
aws emr create-security-configuration --name "MySecConfig" --security-configuration '{
   "EncryptionConfiguration": {
     "AtRestEncryptionConfiguration": {
             "S3EncryptionConfiguration": {
           "EncryptionMode": "SSE-KMS",
           "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012",
           "Overrides": [
              {
                "BucketName": "sse-s3-bucket-name",
                "EncryptionMode": "SSE-S3"
              },
              {
                "BucketName": "cse-kms-bucket-name",
                "EncryptionMode": "CSE-KMS",
                "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
              },
              {
                "BucketName": "sse-kms-bucket-name",
                "EncryptionMode": "SSE-KMS",
                "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
              }
```

```
            ]
            }
          },
     "EnableInTransitEncryption": false,
      "EnableAtRestEncryption": true
  }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist deaktiviert und die Verschlüsselung von Daten im Ruhezustand ist aktiviert.
- Die Amazon S3-Verschlüsselung wird mit SSE-S3 aktiviert und die lokale Laufwerksverschlüsselung ist deaktiviert.

```
aws emr create-security-configuration --name "MyS3EncryptionConfig" --security-
configuration '{
    "EncryptionConfiguration": {
        "EnableInTransitEncryption": false,
        "EnableAtRestEncryption": true,
        "AtRestEncryptionConfiguration": {
            "S3EncryptionConfiguration": {
                "EncryptionMode": "SSE-S3"
            }
        }
     }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist deaktiviert und die Verschlüsselung von Daten im Ruhezustand ist aktiviert.
- Die lokale Laufwerksverschlüsselung wird mit AWS KMS als Schlüsselanbieter aktiviert und die Amazon-S3-Verschlüsselung ist deaktiviert.

```
aws emr create-security-configuration --name "MyLocalDiskEncryptionConfig" --security-
configuration '{
    "EncryptionConfiguration": {
        "EnableInTransitEncryption": false,
```

```
        "EnableAtRestEncryption": true,
        "AtRestEncryptionConfiguration": {
            "LocalDiskEncryptionConfiguration": {
                "EncryptionKeyProviderType": "AwsKms",
                "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
            }
        }
    }
}'
```

Das nachstehende Beispiel veranschaulicht das folgende Szenario:

- Die Verschlüsselung von Daten während der Übertragung ist deaktiviert und die Verschlüsselung von Daten im Ruhezustand ist aktiviert.
- Die lokale Laufwerksverschlüsselung wird mit AWS KMS als Schlüsselanbieter aktiviert und die Amazon-S3-Verschlüsselung ist deaktiviert.
- Die EBS-Verschlüsselung ist aktiviert.

```
aws emr create-security-configuration --name "MyLocalDiskEncryptionConfig" --security-
configuration '{
    "EncryptionConfiguration": {
        "EnableInTransitEncryption": false,
        "EnableAtRestEncryption": true,
        "AtRestEncryptionConfiguration": {
            "LocalDiskEncryptionConfiguration": {
                "EnableEbsEncryption": true,
                "EncryptionKeyProviderType": "AwsKms",
                "AwsKmsKey": "arn:aws:kms:us-
east-1:123456789012:key/12345678-1234-1234-1234-123456789012"
            }
        }
    }
}'
```

JSON-Referenz für Verschlüsselungseinstellungen

In der folgenden Tabelle finden Sie die JSON-Parameter für die Verschlüsselungseinstellungen sowie eine Beschreibung der zulässigen Werte für die einzelnen Parameter.

Parameter	Beschreibung
`"EnableInTransitEncryption" : true | false`	Specify `true` to enable in-transit encryption and `false` to disable it. If omitted, `false` is assumed, and in-transit encryption is disabled.
`"EnableAtRestEncryption": true | false`	Specify `true` to enable at-rest encryption and `false` to disable it. If omitted, `false` is assumed and at-rest encryption is disabled.
Parameter für die Verschlüsselung während der Übertragung	
`"InTransitEncryptionConfiguration" :`	Specifies a collection of values used to configure in-transit encryption when `EnableInTransitEncryption` is `true`.
`"CertificateProviderType": "PEM" | "Custom"`	Specifies whether to use `PEM (PEM)` certificates referenced with a zipped file, or a `Benutzerdefiniert` certificate provider. If `PEM (PEM)` is specified, `S3Objekt` must be a reference to the location in Amazon S3 of a zip file containing the certificates. If Custom is specified, `S3Objekt` must be a reference to the location in Amazon S3 of a JAR file, followed by a `CertificateProviderClass` entry.
`"S3Object" : " ZipLocation "| "JarLocation "`	Provides the location in Amazon S3 to a zip file when `PEM (PEM)` is specified, or to a JAR file when `Benutzerdefiniert` is specified. The format can be a path (for example, `s3://MyConfig/artifacts/CertFiles.zip`) or an ARN (for example, `arn:aws:s3:::Code/MyCertProvider.jar`). If a zip file is specified, it must contain files named exactly `privateKey.pem` and `certificateChain.pem`. A

Parameter	Beschreibung
	file named `trustedCertificates.pem` is optional.
`"CertificateProviderClass" : "MyClassID "`	Required only if `Benutzerdefiniert` is specified for `CertificateProvideрType` . *`MyClassID`* specifies a full class name declared in the JAR file, which implements the TLSArtifactsProvider interface . For example, `com.mycompany.MyCertProvider` .
Parameter für die Verschlüsselung im Ruhezustand	
`"AtRestEncryptionConfiguration" :`	Specifies a collection of values for at-rest encryption when `EnableAtRestEncryption` is `true`, including Amazon S3 encryption and local disk encryption.
Parameter für die Amazon-S3-Verschlüsselung	
`"S3EncryptionConfiguration" :`	Specifies a collection of values used for Amazon S3 encryption with the EMR File System (EMRFS).
`„EncryptionMode“ : „SSE-S3“ | „SSE-KMS“ | „CSE-KMS“ | „CSE-Custom“`	Specifies the type of Amazon S3 encryption to use. If `SSE-S3 (SSE-S3)` is specified, no further Amazon S3 encryption values are required. If either `SSE-KMS` or `CSE-KMS` is specified, an AWS KMS key ARN must be specified as the `AwsKmsKey` value. If `CSE-Custom (CSE-Custom)` is specified, `S3Objekt` and `EncryptionKeyProviderClass` values must be specified.

Parameter	Beschreibung
"AwsKmsKey" : " *MyKeyARN*"	Required only when either SSE-KMS or CSE-KMS is specified for EncryptionMode . *MyKeyARN* must be a fully specified ARN to a key (for example, arn:aws:kms:us-east-1:123456789012:key/12345678-1234-1234-1234-123456789012).
"S3Object" : "*JarLocation* "	Required only when CSE-Custom (CSE-Custom) is specified for CertificateProviderType . *JarLocation* provides the location in Amazon S3 to a JAR file. The format can be a path (for example, s3://MyConfig/artifacts/MyKeyProvider.jar) or an ARN (for example, arn:aws:s3:::Code/MyKeyProvider.jar) .
"EncryptionKeyProviderClass" : "*MyS3KeyClassID* "	Required only when CSE-Custom (CSE-Custom) is specified for EncryptionMode . *myS3KeyClass-ID* specifies a full class name of a class declared in the application that implements the EncryptionMaterialsProvider interface; for example, *com.mycompany.MyS3KeyProvider* .

Parameter für Verschlüsselung auf dem lokalen Datenträger

"LocalDiskEncryptionConfiguration"	Specifies the key provider and corresponding values to be used for local disk encryption.
"EnableEbsEncryption": true | false	Specify true to enable EBS encryption. EBS encryption encrypts the EBS root device volume and attached storage volumes. To use EBS encryption, you must specify AwsKms as your EncryptionKeyProviderType .

Parameter	Beschreibung
`"EncryptionKeyProviderType": "AwsKms" | "Custom"`	Specifies the key provider. If `AwsKms` is specified, an KMS key ARN must be specified as the `AwsKmsKey` value. If **`Benutzerdefiniert`** is specified, `S3Objekt` and `EncryptionKeyProviderClass` values must be specified.
`"AwsKmsKey : " MyKeyARN"`	Required only when `AwsKms` is specified for `Typ`. *`MyKeyARN`* must be a fully specified ARN to a key (for example, `arn:aws:kms:us-east-1:123456789012:key/12345678-1234-1234-1234-456789012123`).
`"S3Object" : "JarLocation "`	Required only when `CSE-Custom (CSE-Custom)` is specified for `CertificateProviderType`. *`JarLocation`* provides the location in Amazon S3 to a JAR file. The format can be a path (for example, `s3://MyConfig/artifacts/MyKeyProvider.jar`) or an ARN (for example, `arn:aws:s3:::Code/MyKeyProvider.jar)`.
`"EncryptionKeyProviderClass" : "MyLocalDiskKeyClassID "`	Required only when `Benutzerdefiniert` is specified for `Typ`. *`MyLocalDiskKeyClassID`* specifies a full class name of a class declared in the application that implements the EncryptionMaterialsProvider interface; for example, *`com.mycompany.MyLocalDiskKeyProvider`*.

Konfiguration der Kerberos-Authentifizierung

Eine Sicherheitskonfiguration mit Kerberos-Einstellungen kann nur von einem Cluster verwendet werden, das mit Kerberos-Attributen erstellt wurde, andernfalls tritt ein Fehler auf. Weitere

Informationen finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR. Kerberos ist nur in Amazon-EMR-Version 5.10.0 und höher verfügbar.

Kerberos-Einstellungen unter Verwendung der Konsole angeben

Wählen Sie anhand der folgenden Anleitungen Optionen in Kerberos authentication (Kerberos-Authentifizierung) aus.

Parameter		Beschreibung
Kerberos		Gibt an, dass Kerberos für Cluster aktiviert ist, die diese Sicherheitskonfiguration verwenden. Wenn ein Cluster diese Sicherheitskonfiguration verwendet, müssen für den Cluster auch Kerberos-Einstellungen angegeben sein, andernfalls tritt ein Fehler auf.
Anbieter	Cluster-dediziertes KDC	Gibt an, dass Amazon EMR einen KDC auf dem Primärknoten eines Clusters erstellt, der diese Sicherheitskonfiguration verwendet. Sie geben den Bereichsnamen und das KDC-Administratorkennwort an, wenn Sie den Cluster erstellen. Bei Bedarf können Sie von anderen Clustern aus auf diesen KDC verweisen. Erstellen Sie diese Cluster mit einer anderen Sicherheitskonfiguration, geben Sie ein externes KDC an und verwenden Sie den Bereichsn amen und das KDC-Administratorkennwort, die Sie für das clusterspezifische KDC angeben.
	Externes KDC	Nur in Amazon EMR-Version 5.20.0 und höher verfügbar. Gibt an, dass Cluster, die diese Sicherhei tskonfiguration verwenden, Kerberos-Prinzipale mithilfe eines KDC-Servers außerhalb des Clusters authentifizieren. Auf dem Cluster wird kein KDC erstellt. Sie geben den Bereichsnamen und das KDC-Administratorkennwort an, wenn Sie den Cluster erstellen.

Parameter		Beschreibung
Gültigkeitsdauer des Tickets		Optional. Gibt den Zeitraum an, für den ein vom KDC ausgestelltes Kerberos-Ticket auf Clustern gültig ist, die diese Sicherheitskonfiguration verwenden. Ticket-Gültigkeitsdauern werden aus Sicherhei tsgründen beschränkt. Cluster-Anwendungen und Services verlängern Tickets automatisch, wenn sie ablaufen. Benutzer, die eine Verbindung mit dem Cluster über SSH mit Kerberos-Anmeldeinformation en einrichten, müssen `kinit` von der Befehlszeile des Primärknoten aus ausführen, um eine Verlängerung auszuführen, nachdem ein Ticket abgelaufen ist.
Bereichsübergreifende Vertrauen sstellung		Gibt eine bereichsübergreifende Vertrauensstellung zwischen einem clusterspezifischen KDC auf Clustern, die diese Sicherheitskonfiguration verwenden, und einem KDC in einem anderen Kerberos-Bereich an. Prinzipale (in der Regel Benutzer) aus einem anderen Bereich werden gegenüber Clustern authentifiziert, die diese Konfiguration verwenden. Eine zusätzlic he Konfiguration im anderen Kerberos-Bereich ist erforderlich. Weitere Informationen finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.
Realitäts übergreif ende Vertrauen seigensch aften	Bereich	Gibt den Kerberos-Bereichsnamen des anderen Bereichs in der Vertrauensstellung an. Gemäß der Konvention sind Kerberos-Bereichsnamen mit dem Domainnamen identisch, jedoch ausschließlich in Großbuchstaben.
	Bereich	Gibt den Domain-Namen des anderen Bereichs in der Vertrauensstellung an.

Parameter		Beschreibung
	Admin-Server	Gibt den Fully Qualified Domain Name (FQDN, vollständig qualifizierter Domainname) oder IP-Adresse des Admin-Servers im anderen Bereich der Vertrauensstellung an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet , da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com :749`).
	KDC-Server	Gibt den vollständig qualifizierten Domain-Namen (FQDN, Fully Qualified Domain Name) oder IP-Adresse des KDC-Servers im anderen Bereich der Vertrauensstellung an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet , da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com :88`).
Externes KDC		Gibt an, dass das externe KDC des Clusters vom Cluster verwendet wird.

Parameter			Beschreibung
Eigenschaften des externen KDCs	Admin-Server		Gibt den vollqualifizierten Domainnamen oder die IP-Adresse des externen Admin-Servers an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:749`*).
	KDC-Server		Gibt den vollqualifizierten Domainnamen des externen KDC-Servers an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:88`*).
	Active-Directory-Integration		Gibt an, dass die Kerberos-Prinzipalauthentifizierung in eine Microsoft-Active-Directory-Domain integriert ist.
	Active-Directory-Integrationseigenschaften	Active-Directory-Bereich	Gibt den Kerberos-Bereichsnamen der Active-Directory-Domain an. Gemäß der Konvention sind Kerberos-Bereichsnamen in der Regel identisch mit dem Domainnamen, jedoch ausschließlich in Großbuchstaben.
		Active-Directory-Domain	Gibt den Active-Directory-Domainnamen an.

Parameter			Beschreibung
		Active-Directory-Server	Gibt den vollqualifizierten Domainnamen des Microsoft Active Directory-Domain-Controllers an.

Angeben von Kerberos-Einstellungen unter Verwendung der AWS CLI

Die folgende Referenztabelle zeigt JSON-Parameter für Kerberos-Einstellungen in einer Sicherheitskonfiguration. Beispielkonfigurationen finden Sie unter Beispiele für Konfigurationen.

Parameter	Beschreibung
`"AuthenticationConfiguration": {`	Erforderlich für Kerberos. Gibt an, dass eine Authentifizierungskonfiguration Teil dieser Sicherheitskonfiguration ist.
`"KerberosConfiguration": {`	Erforderlich für Kerberos. Gibt die Kerberos-Konfigurationseigenschaften an.

`"Provider": "ClusterDedicatedKdc",`
–oder–
`"Provider": "ExternalKdc",`
	`ClusterDedicatedKdc` gibt an, dass Amazon EMR einen KDC auf dem Primärknoten eines Clusters erstellt, der diese Sicherheitskonfiguration verwendet. Sie geben den Bereichsnamen und das KDC-Administratorkennwort an, wenn Sie den Cluster erstellen. Bei Bedarf können Sie von anderen Clustern aus auf diesen KDC verweisen. Erstellen Sie diese Cluster mit einer anderen Sicherheitskonfiguration, geben Sie einen externen KDC an und verwenden Sie den Bereichsnamen und das KDC-Administratorkennwort,

Parameter	Beschreibung
	die Sie beim Erstellen des Clusters mit dem Cluster-dedizierten KDC angegeben haben. *ExternalKdc* gibt an, dass der Cluster ein externes KDC verwendet . Amazon EMR erstellt kein KDC auf dem Primärknoten. Ein Cluster, der diese Sicherheitskonfiguration verwendet, muss den Bereichsn amen und das KDC-Administratork ennwort des externen KDC angeben.
`"ClusterDedicatedK dcConfiguration": {`	Erforderlich, wenn *ClusterDe dicatedKdc* angegeben ist.
`"TicketLifetimeInH ours": 24,`	Optional. Gibt den Zeitraum an, für den ein vom KDC ausgestelltes Kerberos-Ticket auf Clustern gültig ist, die diese Sicherheitskonfiguration verwenden. Ticket-Gültigkeitsdauern werden aus Sicherheitsgründen beschränkt. Cluster-Anwendungen und Services verlängern Tickets automatisch, wenn sie ablaufen. Benutzer, die eine Verbindung mit dem Cluster über SSH mit Kerberos-Anmeldein formationen einrichten, müssen `kinit` von der Befehlszeile des Primärknoten aus ausführen, um eine Verlängerung auszuführen, nachdem ein Ticket abgelaufen ist.

Parameter	Beschreibung
"CrossRealmTrustConfiguration": {	Gibt eine bereichsübergreifende Vertrauensstellung zwischen einem clusterspezifischen KDC auf Clustern, die diese Sicherheitskonfiguration verwenden, und einem KDC in einem anderen Kerberos-Bereich an. Prinzipale (in der Regel Benutzer) aus einem anderen Bereich werden gegenüber Clustern authentifiziert, die diese Konfiguration verwenden. Eine zusätzliche Konfiguration im anderen Kerberos-Bereich ist erforderlich. Weitere Informationen finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.
"Realm": "*KDC2.COM*",	Gibt den Kerberos-Bereichsnamen des anderen Bereichs in der Vertrauensstellung an. Gemäß der Konvention sind Kerberos-Bereichsnamen mit dem Domainnamen identisch, jedoch ausschließlich in Großbuchstaben.
"Domain": "*kdc2.com*",	Gibt den Domain-Namen des anderen Bereichs in der Vertrauensstellung an.

Parameter	Beschreibung
"AdminServer": "*kdc.com:749* ",	Gibt den Fully Qualified Domain Name (FQDN, vollständig qualifizierter Domainname) oder IP-Adresse des Admin-Servers im anderen Bereich der Vertrauensstellung an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:749`*).
"KdcServer": "*kdc.com:88* "	Gibt den vollständig qualifizierten Domain-Namen (FQDN, Fully Qualified Domain Name) oder IP-Adresse des KDC-Servers im anderen Bereich der Vertrauensstellung an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:88`*).

Parameter	Beschreibung
}	
}	
"ExternalKdcConfiguration": {	Erforderlich, wenn *ExternalKdc* angegeben ist.
"TicketLifetimeInHours": *24*,	Optional. Gibt den Zeitraum an, für den ein vom KDC ausgestelltes Kerberos-Ticket auf Clustern gültig ist, die diese Sicherheitskonfiguration verwenden. Ticket-Gültigkeitsdauern werden aus Sicherheitsgründen beschränkt. Cluster-Anwendungen und Services verlängern Tickets automatisch, wenn sie ablaufen. Benutzer, die eine Verbindung mit dem Cluster über SSH mit Kerberos-Anmeldeinformationen einrichten, müssen `kinit` von der Befehlszeile des Primärknoten aus ausführen, um eine Verlängerung auszuführen, nachdem ein Ticket abgelaufen ist.
"KdcServerType": "Single",	Gibt an, dass auf einen einzelnen KDC-Server verwiesen wird. `Single` ist derzeit der einzige unterstützte Wert.

Parameter				Beschreibung
			"AdminServer": "*kdc.com:749* ",	Gibt den vollqualifizierten Domainnamen oder die IP-Adresse des externen Admin-Servers an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:749`*).
			„KdcServer“: "*kdc.com:88* ",	Gibt den vollqualifizierten Domainnamen des externen KDC-Servers an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:88`*).
			`"AdIntegrationConfiguration": {`	Gibt an, dass die Kerberos-Prinzipal authentifizierung in eine Microsoft-Active-Directory-Domain integriert ist.

Parameter	Beschreibung
"AdRealm": "*AD.DOMAIN.COM* ",	Gibt den Kerberos-Bereichsnamen der Active-Directory-Domain an. Gemäß der Konvention sind Kerberos-Bereichsnamen in der Regel identisch mit dem Domainnamen, jedoch ausschließlich in Großbuchstaben.
"AdDomain": "*ad.domain.com* "	Gibt den Active-Directory-Domainnamen an.
"AdServer": "*ad.domain.com* "	Gibt den vollqualifizierten Domainnamen des Microsoft Active Directory-Domain-Controllers an.
}	
}	
}	
}	

Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3

Mit IAM-Rollen für EMRFS können Sie unterschiedliche Berechtigungen für EMRFS-Daten in Amazon S3 bereitstellen. Sie erstellen Rollenzuordnungen, die eine IAM-Rolle spezifizieren, die für Berechtigungen verwendet wird, wenn eine Zugriffsanforderung eine von Ihnen angegebene Kennung enthält. Bei der ID kann es sich um einen Hadoop-Benutzer oder eine Hadoop-Rolle oder ein Amazon-S3-Präfix handeln.

Weitere Informationen finden Sie unter Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3.

Angeben von IAM-Rollen für EMRFS über die AWS CLI

Im Folgenden finden Sie ein JSON-Beispiel für die Angabe benutzerdefinierter IAM-Rollen für EMRFS innerhalb einer Sicherheitskonfiguration. Es zeigt Rollenzuordnungen für die drei verschiedenen Identifier-Typen, gefolgt von einer Parameterreferenz.

```
{
  "AuthorizationConfiguration": {
    "EmrFsConfiguration": {
      "RoleMappings": [{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_for_user1",
        "IdentifierType": "User",
        "Identifiers": [ "user1" ]
      },{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_to_MyBuckets",
        "IdentifierType": "Prefix",
        "Identifiers": [ "s3://MyBucket/","s3://MyOtherBucket/" ]
      },{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_for_AdminGroup",
        "IdentifierType": "Group",
        "Identifiers": [ "AdminGroup" ]
      }]
    }
  }
}
```

Parameter	Beschreibung
`"AuthorizationConfiguration":`	Erforderlich.
`"EmrFsConfiguration":`	Erforderlich. Enthält Rollenzuordnungen.
`"RoleMappings":`	Erforderlich. Enthält eine oder mehrere Rollenzuordnungsdefinitionen. Rollenzuordnungen werden in der Reihenfolge bewertet, in der sie von oben nach unten angezeigt werden. Wenn eine Rollenzuweisung für einen EMRFS-Datenaufruf in Amazon S3 als wahr bewertet wird, werden keine weiteren Rollenzuordnungen ausgewertet und EMRFS

Parameter	Beschreibung
	verwendet die angegebene IAM-Rolle für die Anfrage. Rollenzuordnungen bestehen aus den folgenden erforderlichen Parametern:
`"Role":`	Gibt den ARN-Bezeichner einer IAM-Rolle im Format `arn:aws:iam::` *`account-id`* `:role/`*`role-name`* an. Dies ist die IAM-Rolle, die Amazon EMR übernimmt, wenn die EMRFS-Anfrage an Amazon S3 mit einer der angegebenen `Identifiers` übereinstimmt.
`"IdentifierType":`	Kann einer der folgenden sein: • `"User"` gibt an, dass es sich bei den Kennungen um einen oder mehrere Hadoop-Benutzer handelt, bei denen es sich um Linux-Kontobenutzer oder Kerberos-Prinzipale handeln kann. Wenn die EMRFS-Anfrage von dem oder den angegebenen Benutzern stammt, wird die IAM-Rolle übernommen. • `"Prefix"` gibt an, dass der Identifier ein Amazon-S3-Speicherort ist. Die IAM-Rolle wird für Anrufe an den Standort oder die Standorte mit den angegebenen Präfixen übernommen. Das Präfix `s3://mybucket/` entspricht beispielsweise `s3://mybucket/mydir` und `s3://mybucket/yetanotherdir` . • `"Group"` gibt an, dass es sich bei den Identifikatoren um eine oder mehrere Hadoop-Gruppen handelt. Die IAM-Rolle wird übernommen, wenn die Anfrage von einem Benutzer in der oder den angegebenen Gruppen stammt.

Parameter	Beschreibung
`"Identifiers":`	Gibt einen oder mehrere Kennungen des entsprechenden Kennungstyps an. Trennen Sie mehrere Bezeichner durch Kommas ohne Leerzeichen.

Metadaten-Serviceanfragen an Amazon EC2-Instances konfigurieren

Instance-Metadaten sind Daten über eine Instance, mit denen Sie die ausgeführte Instance konfigurieren und verwalten können. Sie können mit einer der folgenden Methoden auf Instance-Metadaten aus einer laufenden Instance zugreifen:

- Instance-Metadatenservice Version 1 (IMDSv1) – Ein Anfrage/Antwort-Verfahren
- Instance-Metadatenservice Version 2 (IMDSv2) – Ein sitzungsorientiertes Verfahren

Während Amazon EC2 sowohl IMDSv1 als auch IMDSv2 unterstützt, unterstützt Amazon EMR IMDSv2 in Amazon EMR 5.23.1, 5.27.1, 5.32 oder höher und 6.2 oder höher. In diesen Versionen verwenden Amazon EMR-Komponenten IMDSv2 für alle IMDS-Aufrufe. Für IMDS-Aufrufe in Ihrem Anwendungscode können Sie sowohl IMDSv1 als auch IMDSv2 verwenden oder das IMDS so konfigurieren, dass es aus Sicherheitsgründen nur IMDSv2 verwendet. Wenn Sie angeben, dass IMDSv2 verwendet werden muss, funktioniert IMDSv1 nicht mehr.

Weitere Informationen finden Sie unter Konfigurieren von Instance Metadata Service im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

> **Note**
>
> In früheren Amazon EMR 5.x- oder 6.x-Versionen führt das Ausschalten von IMDSv1 zu einem Cluster-Startup-Fehler, da Amazon-EMR-Komponenten IMDSv1 für alle IMDS-Aufrufe verwenden. Stellen Sie beim Ausschalten von IMDSv1 sicher, dass jede benutzerdefinierte Software, die IMDSv1 verwendet, auf IMDSv2 aktualisiert wird.

Spezifizieren Sie die Konfiguration des Instance Metadata Services mit dem AWS CLI

Nachfolgend finden Sie ein JSON-Beispiel-Snippet für die Spezifizierung des Amazon EC2 Instance Metadata Service (IMDS) in einer Sicherheitskonfiguration.

```
{
  "InstanceMetadataServiceConfiguration" : {
      "MinimumInstanceMetadataServiceVersion": integer,
      "HttpPutResponseHopLimit": integer
   }
}
```

Parameter	Beschreibung
`"InstanceMetadataServiceConfiguration":`	Erforderlich.
`"MinimumInstanceMetadataServiceVersion":`	Erforderlich. Geben Sie 1 oder 2 an. Der Wert 1 ermöglicht IMDSv1 und IMDSv2. Ein Wert von 2 erlaubt nur IMDSv2.
`"HttpPutResponseHopLimit":`	Erforderlich. Das gewünschte HTTP PUT-Antwort-Hop-Limit für Instance-Metadaten anfragen. Je größer die Zahl ist, desto weiter können sich die Instance-Metadatenanfragen bewegen. Standard: 1. Einen Ganzzahlwert von 1 bis 64 angeben.

Die Konfiguration des Instance Metadata Services mit der Konsole angeben

Sie können die Verwendung von IMDS für einen Cluster konfigurieren, wenn Sie ihn von der Amazon-EMR-Konsole aus starten.
Steuerung der IMDS-Sicherheitskonfigurationen in der Amazon EMR-Konsole

So konfigurieren Sie die Verwendung von IMDS mithilfe der Konsole:

1. Wenn Sie auf der Seite Sicherheitskonfigurationen eine neue Sicherheitskonfiguration erstellen, wählen Sie unter der Einstellung EC2-Instance Metadata Service die Option EC2-Instance-

Metadatenservice konfigurieren aus. Diese Konfiguration wird nur in Amazon EMR 5.23.1, 5.27.1, 5.32 oder höher und 6.2 oder höher unterstützt.

2. Für Minimum Instance Metadata Service Version wählen Sie eine der folgenden Optionen aus:
   - Schalten Sie IMDSv1 aus und lassen Sie nur IMDSv2 zu, wenn Sie nur IMDSv2 auf diesem Cluster zulassen möchten. Informationen finden Sie unter Umstieg auf die Verwendung der Instance-Metadaten-Service-Version 2 im Benutzerhandbuch von Amazon EC2 für Linux-Instances.
   - Erlauben Sie sowohl IMDSv1 als auch IMDSv2 auf dem Cluster, wenn Sie IMDSv1 und sitzungsorientierte IMDSv2 auf diesem Cluster zulassen möchten.
3. Für IMDSv2 können Sie auch die zulässige Anzahl von Netzwerk-Hops für das Metadaten-Token konfigurieren, indem Sie das HTTP-Put-Antwort-Hop-Limit auf eine Ganzzahl zwischen 1 und 64 festlegen.

Weitere Informationen finden Sie unter Konfigurieren von Instance Metadata Service im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Weitere Informationen finden Sie unter Instance-Details konfigurieren und Instance Metadata Service konfigurieren im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Angabe einer Sicherheitskonfiguration für einen Cluster

Sie können bei der Erstellung eines Clusters die Verschlüsselungseinstellungen festlegen, indem Sie eine Sicherheitskonfiguration angeben. Sie können die AWS Management Console oder die AWS CLI verwenden.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Eine Sicherheitskonfiguration mithilfe der Konsole angeben

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.

2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Suchen Sie unter Sicherheitskonfiguration und Berechtigungen das Feld Sicherheitskonfiguration. Wählen Sie das Dropdownmenü oder klicken Sie auf Durchsuchen, um den Namen einer Sicherheitskonfiguration auszuwählen, die Sie zuvor erstellt haben. Wählen Sie alternativ VPC erstellen, um eine VPC zu erstellen, die Sie für Ihren Cluster verwenden können.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Wie Sie eine Sicherheitskonfiguration mithilfe der Konsole festlegen

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.
3. Wählen Sie im Bildschirm Schritt 1: Software und Schritte in der Liste Version die Option emr-4.8.0 oder eine neuere Version aus. Wählen Sie die gewünschten Einstellungen aus und klicken Sie auf Next (Weiter).
4. Wählen Sie im Bildschirm Step 2: Hardware (Schritt 2: Hardware) die gewünschten Einstellungen aus und klicken Sie auf Next (Weiter). Wiederholen Sie dies in Step 3: General Cluster Settings (Schritt 3: Allgemeine Cluster-Einstellungen).
5. Wählen Sie im Bildschirm Step 4: Security (Schritt 4: Sicherheit) in Encryption Options (Verschlüsselungsoptionen)einen Wert für Security configuration (Sicherheitskonfiguration) aus.
6. Wählen Sie weitere Sicherheitsoptionen wie gewünscht und wählen Sie anschließend Create cluster (Cluster erstellen) aus.

CLI

Wie Sie eine Sicherheitskonfiguration mit dem AWS CLI angeben

- Verwenden Sie `aws emr create-cluster` und Sie können mithilfe von `--security-configuration` *`MySecConfig`* wahlweise eine Sicherheitskonfiguration verwenden, wobei *`MySecConfig`* der Name der Sicherheitskonfiguration ist, wie im folgenden Beispiel

dargestellt. Der angegebene `--release-label` muss 4.8.0 oder höher sein und `--instance-type` kann als jeder verfügbare Typ ausgewählt werden.

```
aws emr create-cluster --instance-type m5.xlarge --release-label emr-5.0.0 --
security-configuration mySecConfig
```

Datenschutz bei Amazon EMR

Das AWS-Modell der geteilten Verantwortung wird auf den Datenschutz in Amazon EMR angewendet. Wie in diesem Modell beschrieben, ist AWS für den Schutz der globalen Infrastruktur verantwortlich, auf der die gesamte AWS-Cloud läuft. Sie sind dafür verantwortlich, die Kontrolle über Ihre in dieser Infrastruktur gehosteten Inhalte zu behalten. Dieser Inhalt enthält die Sicherheitskonfigurations- und Verwaltungsaufgaben für die von Ihnen verwendeten AWS. Weitere Informationen zum Datenschutz finden Sie unter Häufig gestellte Fragen zum Datenschutz. Informationen zum Datenschutz in Europa finden Sie im Blog-Beitrag -Modell der geteilten Verantwortung und in der DSGVO im AWS-Sicherheitsblog.

Wir empfehlen aus Gründen des Datenschutzes, dass Sie AWS-Anmeldeinformationen schützen und die Konten jeweils mit AWS Identity and Access Management einrichten. So erhält jeder Benutzer nur die Berechtigungen, die zum Durchführen seiner Aufgaben erforderlich sind. Außerdem sollten Sie die Daten mit folgenden Methoden schützen:

- Verwenden Sie für jedes Konto die Multi-Faktor Authentifizierung (MFA).
- Verwenden Sie TLS für die Kommunikation mit AWS-Ressourcen. Wir erfordern TLS 1.2.
- Richten Sie die API und die Protokollierung von Benutzeraktivitäten mit ein AWS CloudTrail.
- Verwenden Sie AWS-Verschlüsselungslösungen zusammen mit allen Standardsicherheitskontrollen in AWS-Services.
- Verwenden Sie erweiterte verwaltete Sicherheitsservices wie Amazon Macie, die dabei helfen, in Amazon S3 gespeicherte persönliche Daten zu erkennen und zu sichern.
- Wenn Sie für den Zugriff auf AWS über eine Befehlszeilenschnittstelle oder über eine API FIPS 140-2-validierte kryptografische Module benötigen, verwenden Sie einen FIPS-Endpunkt. Weitere Informationen über verfügbare FIPS-Endpunkte finden Sie unter Federal Information Processing Standard (FIPS) 140-2.

Wir empfehlen dringend, in Freitextfeldern wie z. B. im Feld Name keine sensiblen, identifizierenden Informationen wie Kontonummern von Kunden einzugeben. Dies gilt auch, wenn Sie mit Amazon EMR oder anderen AWS-Services unter Verwendung der Konsole, API, AWS CLI oder AWS-SDKs arbeiten. Alle Daten, die Sie in Amazon EMR oder andere Services eingeben, werden möglicherweise in Diagnoseprotokolle aufgenommen. Wenn Sie eine URL für einen externen Server bereitstellen, schließen Sie keine Anmeldeinformationen zur Validierung Ihrer Anforderung an den betreffenden Server in die URL ein.

Verschlüsseln von Daten im Ruhezustand und im Transit

Die Datenverschlüsselung verhindert, dass nicht autorisierte Benutzer Daten auf einem Cluster und in den dazugehörigen Datenspeichersystemen lesen können. Dies gilt für auf persistenten Medien gespeicherte Daten, auch als Daten im Ruhezustand bezeichnet, und für Daten, die während der Übertragung im Netzwerk möglicherweise abgefangen werden, auch als Daten während der Übertragung bezeichnet.

Ab Amazon-EMR-Version 4.8.0 können Sie mit Amazon-EMR-Sicherheitskonfigurationen Datenverschlüsselungseinstellungen für Cluster einfacher konfigurieren. Sicherheitskonfigurationen stellen Einstellungen bereit, um die Sicherheit von Daten während der Übertragung und im Ruhezustand in Amazon Elastic Block Store (Amazon EBS)-Volumen und EMRFS in Amazon S3 zu unterstützen.

Optional können Sie ab Amazon EMR Version 4.1.0 und höher eine transparente Verschlüsselung in HDFS konfigurieren, die nicht unter Verwendung von Sicherheitskonfigurationen konfiguriert ist. Weitere Informationen finden Sie unter Transparente Verschlüsselung in HDFS in Amazon EMR in Amazon-EMR-Versionenhinweise.

Themen

- Verschlüsselungsoptionen
- Schlüssel und Zertifikate für die Datenverschlüsselung erstellen

Verschlüsselungsoptionen

Ab der Amazon-EMR-Version 4.8.0 können Sie eine Sicherheitskonfiguration verwenden, um Einstellungen für die Verschlüsselung von Daten im Ruhezustand, Daten während der Übertragung oder beides anzugeben. Wenn Sie die Datenverschlüsselung im Ruhezustand aktivieren, können Sie wählen, ob Sie EMRFS-Daten in Amazon S3, Daten auf lokalen Festplatten oder beide verschlüsseln

möchten. Jede von Ihnen erstellte Sicherheitskonfiguration wird in Amazon EMR und nicht in der Cluster-Konfiguration gespeichert. Daher können Sie die Konfiguration bei jeder Cluster-Erstellung problemlos wiederverwenden, um die Datenverschlüsselung zu konfigurieren. Weitere Informationen finden Sie unter Eine Sicherheitskonfiguration erstellen.

Das folgende Diagramm zeigt die verschiedenen Datenverschlüsselungsoptionen, die für die Sicherheitskonfigurationen zur Verfügung stehen.

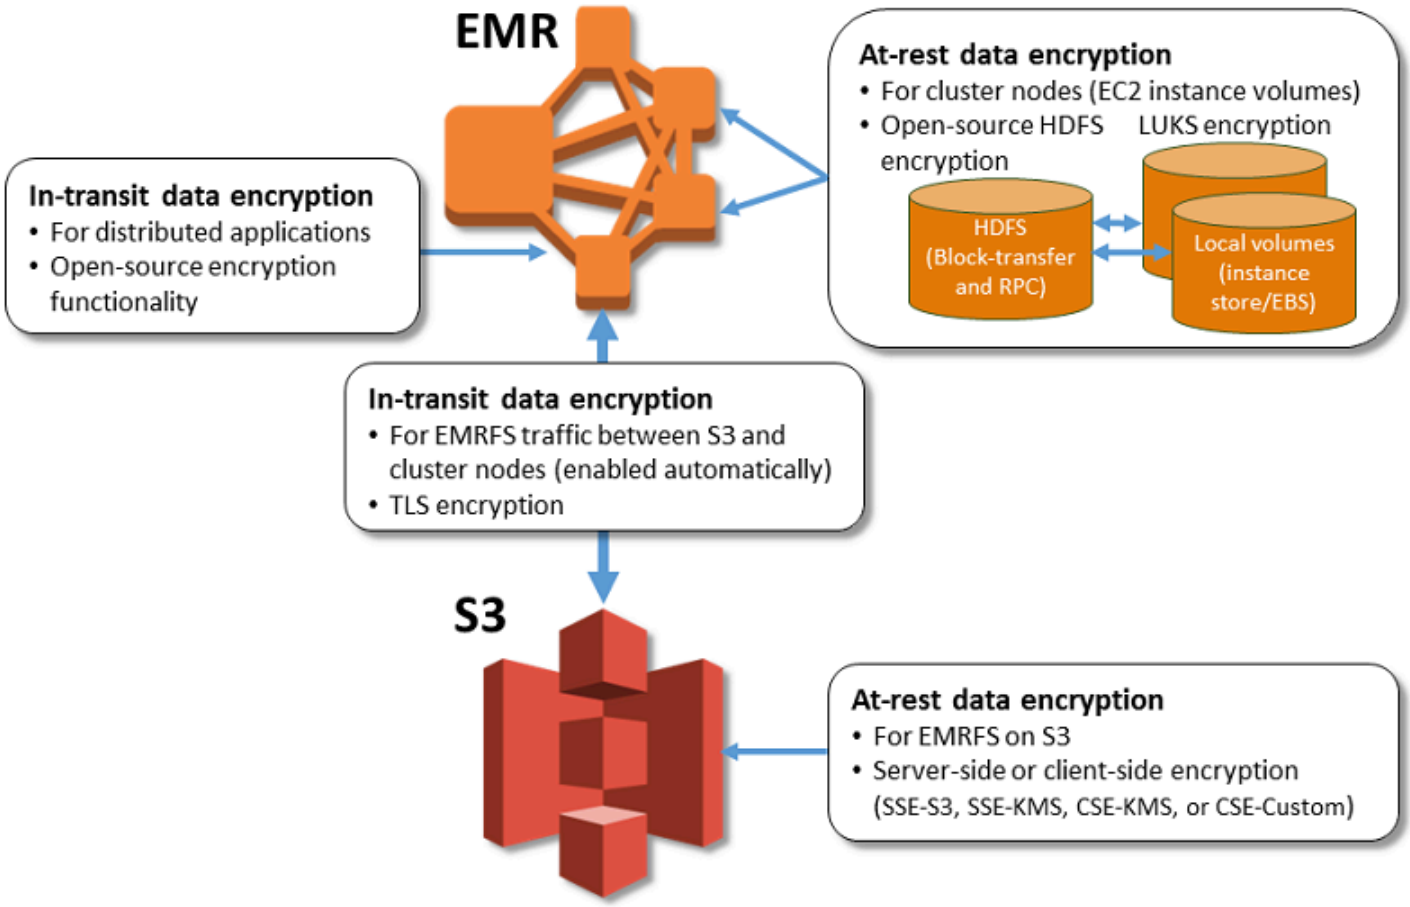

Die folgenden Verschlüsselungsoptionen stehen ebenfalls zur Verfügung und werden nicht mit einer Sicherheitskonfiguration konfiguriert:

- Optional können Sie mit Amazon EMR-Versionen 4.1.0 und höher eine transparente Verschlüsselung in HDFS konfigurieren. Weitere Informationen finden Sie unter Transparente Verschlüsselung in HDFS in Amazon EMR in Amazon-EMR-Versionenhinweise.
- Wenn Sie eine Version von Amazon EMR verwenden, die Sicherheitskonfigurationen nicht unterstützt, können Sie die Verschlüsselung für EMRFS-Daten in Amazon S3 manuell konfigurieren. Weitere Informationen finden Sie unter Amazon-S3-Verschlüsselung mithilfe von EMRFS-Eigenschaften angeben.

- Wenn Sie eine Amazon-EMR-Version vor 5.24.0 verwenden, wird ein verschlüsseltes EBS-Root-Volume nur unterstützt, wenn Sie ein benutzerdefiniertes AMI verwenden. Weitere Informationen finden Sie unter Erstellen eines benutzerdefinierten AMI mit einem verschlüsselten Amazon EBS-Root-Volume im Amazon EMR Managementhandbuch.

> **Note**
>
> Ab Amazon-EMR-Version 5.24.0 können Sie eine Sicherheitskonfigurationsoption zum Verschlüsseln von EBS-Root-Geräten und Speicher-Volumes verwenden, wenn Sie AWS KMS als Ihren Schlüsselanbieter angeben. Weitere Informationen finden Sie unter Verschlüsselung lokaler Datenträger.

Die Datenverschlüsselung erfordert Aktivierungsschlüssel und Zertifikate. Eine Sicherheitskonfiguration ermöglicht Ihnen die Wahl zwischen verschiedenen Optionen, einschließlich Schlüsseln, die von AWS Key Management Service verwaltet werden, Schlüsseln, die von Amazon S3 verwaltet werden, sowie Schlüsseln und Zertifikaten, die von Anbietern bereitgestellt werden, die Sie angeben. Wenn Sie AWS KMS als Ihren Schlüsselanbieter auswählen, fallen für die Speicherung und Nutzung der Verschlüsselungsschlüssel Gebühren an. Weitere Informationen finden Sie unter AWS KMS Preise.

Bevor Sie die Verschlüsselungsoptionen angeben, legen Sie fest, welche Verwaltungssysteme Sie für die Schlüssel und Zertifikate verwenden möchten. Auf diese Weise können Sie zunächst die Schlüssel und Zertifikate bzw. die von Ihnen bestimmten Anbieter erstellen, die Sie als Teil der Verschlüsselungseinstellungen verwenden möchten.

Verschlüsselung im Ruhezustand von EMRFS-Daten in Amazon S3

Die Amazon-S3-Verschlüsselung funktioniert mit EMR File System (EMRFS)-Objekten, die gelesen werden und zu Amazon S3 geschrieben werden. Sie geben serverseitige Verschlüsselung (SSE) von Amazon S3 oder clientseitige Verschlüsselung (CSE) als Standardverschlüsselungsmodus an, wenn Sie die Verschlüsselung im Ruhezustand aktivieren. Optional können Sie verschiedene Verschlüsselungsmethoden für einzelne Buckets mithilfe von Per bucket encryption overrides (Bucket-weises Überschreiben der Verschlüsselung) angeben. Unabhängig davon, ob Amazon-S3-Verschlüsselung aktiviert ist, verschlüsselt Transport Layer Security (TLS) EMRFS-Objekte bei der Übertragung zwischen EMR-Cluster-Knoten und Amazon S3. Ausführliche Informationen zur Amazon-S3-Verschlüsselung finden Sie unter Schützen von Daten mithilfe von Verschlüsselung im Entwicklerhandbuch für Amazon Simple Storage Service.

> **Note**
>
> Wenn Sie AWS KMS auswählen, fallen für die Speicherung und Nutzung der Verschlüsselungsschlüssel Gebühren an. Weitere Informationen finden Sie unter AWS KMS-Preisgestaltung.

Serverseitige Verschlüsselung im Amazon S3

Wenn Sie die Amazon-S3-Verschlüsselung einrichten, verschlüsselt Amazon S3 die Daten auf der Objektebene, während die Daten auf den Datenträger geschrieben werden, und entschlüsselt sie, wenn auf sie zugegriffen wird. Weitere Informationen über SSE finden Sie unter Schutz von Daten durch serverseitige Verschlüsselung im Amazon Simple Storage Service User Guide.

Wenn Sie SSE in Amazon EMR einrichten, haben Sie die Wahl zwischen zwei verschiedenen Systemen für die Schlüsselverwaltung:

- SSE-S3 – Hierbei verwaltet Amazon S3 die Aktivierungsschlüssel für Sie.
- SSE-KMS – Sie verwenden eine AWS KMS key, um Richtlinien einzurichten, die für Amazon EMR geeignet sind. Weitere Informationen zu den wichtigsten Anforderungen für Amazon EMR finden Sie unter Verwenden von AWS KMS keys zur Verschlüsselung.

SSE mit vom Kunden bereitgestellten Schlüsseln (SSE-C) ist für Amazon EMR nicht verfügbar.

Clientseitige Verschlüsselung für Amazon S3

Mit Amazon S3 bei der clientseitigen Verschlüsselung erfolgt der Amazon-S3-Ver- und Entschlüsselungsvorgang im EMRFS-Client auf Ihrem EMR-Cluster. Objekte werden vor dem Hochladen nach Amazon S3 verschlüsselt und nach dem Herunterladen entschlüsselt. Der von Ihnen festgelegte Anbieter stellt den vom Client verwendeten Verschlüsselungsschlüssel bereit. Der Client kann vom AWS KMS bereitgestellte Schlüssel (CSE-KMS) oder eine benutzerdefinierte Java-Klasse verwenden, die den clientseitigen Root-Schlüssel (CSE-C) bereitstellt. Die Verschlüsselungseigenschaften unterscheiden sich geringfügig zwischen CSE-KMS und CSE-C, abhängig vom festgelegten Anbieter und von den Metadaten des Objekts, das entschlüsselt oder verschlüsselt werden soll. Weitere Informationen zu diesen Unterschieden finden Sie unter Schützen von Daten durch clientseitige Verschlüsselung im Entwicklerhandbuch von Amazon Simple Storage Service.

> **Note**
>
> Amazon S3 CSE stellt nur sicher, dass EMRFS-Daten, die mit Amazon S3 ausgetauscht werden, verschlüsselt sind. Nicht alle Daten auf den Cluster-Instance-Volumes werden verschlüsselt. Da Hue EMRFS nicht verwendet, werden darüber hinaus Objekte, die vom Hue-S3-Dateibrowser in Amazon S3 geschrieben werden, nicht verschlüsselt.

Verschlüsselung lokaler Datenträger

Die folgenden Mechanismen arbeiten zusammen, um lokale Datenträger zu verschlüsseln, wenn Sie die lokale Laufwerksverschlüsselung mithilfe einer Amazon EMR-Sicherheitskonfiguration aktivieren.

Open-Source-HDFS-Verschlüsselung

HDFS tauscht im Rahmen der verteilten Verarbeitung Daten zwischen Cluster-Instances aus. Außerdem werden Daten aus Instance-Speicher-Volumes und die an Instances angehängten EBS-Volumes gelesen und in sie geschrieben. Wenn Sie die lokale Laufwerksverschlüsselung aktivieren, werden die folgenden Open-Source-Hadoop-Verschlüsselungsoptionen aktiviert:

- Secure Hadoop RPC ist auf die Option `Privacy` festgelegt, die Simple Authentication Security Layer (SASL) verwendet.
- Datenverschlüsselung für HDFS-Block-Datenübertragungen ist auf `true` festgelegt und für die Verwendung der AES 256-Verschlüsselung konfiguriert.

> **Note**
>
> Sie können zusätzlich die Apache Hadoop-Verschlüsselung verwenden, indem Sie die Verschlüsselung während der Übertragung aktivieren. Weitere Informationen finden Sie unter Verschlüsselung während der Übertragung. Diese Verschlüsselungseinstellungen aktivieren die transparente HDFS-Verschlüsselung nicht, Sie können sie jedoch manuell konfigurieren. Weitere Informationen finden Sie unter Transparente Verschlüsselung in HDFS in Amazon EMR in Amazon-EMR-Versionenhinweise.

Instance-Speicher-Verschlüsselung

Bei EC2-Instance-Typen, die NVMe-basierte SSDs als Instance-Speicher-Volume verwenden, wird unabhängig von den Amazon-EMR-Verschlüsselungseinstellungen die NVMe-Verschlüsselung verwendet. Weitere Informationen finden Sie unter NVMe-SSD-Volume-Typen im Benutzerhandbuch von Amazon EC2 für Linux-Instances. Für andere Instance-Speicher-Volumes verwendet Amazon EMR unabhängig davon, ob EBS-Volumes mit der EBS-Verschlüsselung oder LUKS verschlüsselt werden, LUKS zum Verschlüsseln des Instance-Speicher-Volumes, wenn die lokale Laufwerksverschlüsselung aktiviert ist.

EBS-Volume-Verschlüsselung

Wenn Sie einen Cluster in einer Region erstellen, in der die Amazon EC2-Verschlüsselung von EBS-Volumes standardmäßig für Ihr Konto aktiviert ist, werden EBS-Volumes auch dann verschlüsselt, wenn die lokale Laufwerksverschlüsselung nicht aktiviert ist. Weitere Informationen dazu finden Sie unter Gerätebenennung bei Linux-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Wenn die lokale Laufwerksverschlüsselung in einer Sicherheitskonfiguration aktiviert ist, haben die Amazon EMR-Einstellungen Vorrang vor den standardmäßigen Amazon EC2-Verschlüsselungseinstellungen für Cluster-EC2-Instances.

Die folgenden Optionen stehen zum Verschlüsseln von EBS-Volumes mithilfe einer Sicherheitskonfiguration zur Verfügung:

- EBS-Verschlüsselung – Ab Amazon EMR Version 5.24.0 können Sie wählen, ob Sie die EBS-Verschlüsselung aktivieren möchten. Die EBS-Verschlüsselungsoption verschlüsselt das EBS-Root-Volume und die angefügten Speicher-Volumes. Die EBS-Verschlüsselungsoption ist nur verfügbar, wenn Sie AWS Key Management Service als Schlüsselanbieter angeben. Wir empfehlen die Verwendung der EBS-Verschlüsselung.
- LUKS-Verschlüsselung – Wenn Sie die LUKS-Verschlüsselung für Amazon EBS-Volumes verwenden, gilt die LUKS-Verschlüsselung nur für angeschlossene Speichervolumes, nicht für das Root-Geräte-Volume. Weitere Informationen zur LUKS-Verschlüsselung finden Sie unter LUKS-Datenträger-Spezifikation.

  Als Schlüsselanbieter können Sie AWS KMS key mit für Amazon EMR geeigneten Richtlinien verwenden oder eine benutzerdefinierte Java-Klasse, die die Verschlüsselungsartefakte bereitstellt. Wenn Sie AWS KMS auswählen, fallen für die Speicherung und Nutzung der Verschlüsselungsschlüssel Gebühren an. Weitere Informationen finden Sie unter AWS KMS Preise.

> **Note**
>
> Um zu überprüfen, ob die EBS-Verschlüsselung auf Ihrem Cluster aktiviert ist, wird empfohlen, den `DescribeVolumes` API-Aufruf zu verwenden. Weitere Informationen finden Sie unter DescribeVolumes. Bei Ausführung von `lsblk` auf dem Cluster wird nur der Status der LUKS-Verschlüsselung anstelle der EBS-Verschlüsselung überprüft.

Verschlüsselung während der Übertragung

Bei der Verschlüsselung während der Übertragung sind mehrere Verschlüsselungsmechanismen aktiviert. Dabei handelt es sich um Open-Source-Features, die anwendungsspezifisch sind und je nach Amazon-EMR-Version variieren können. Mithilfe von Sicherheitskonfigurationen können die folgenden anwendungsspezifischen Verschlüsselungsfeatures Apache aktiviert werden. Weitere Informationen finden Sie unter Konfigurieren von Anwendungen.

Hadoop

- Hadoop-MapReduce-verschlüsselter Shuffle verwendet TLS.
- Secure Hadoop RPC ist auf „Datenschutz“ festgelegt und verwendet SASL (aktiviert in Amazon EMR, wenn die Verschlüsselung von Daten im Ruhezustand ausgewählt ist).
- Datenverschlüsselung bei der HDFS-Blockdatenübertragung verwendet AES 256 (in Amazon EMR aktiviert, wenn in der Sicherheitskonfiguration die Verschlüsselung von Daten im Ruhezustand aktiviert ist).
- Weitere Informationen finden Sie unter Hadoop in Secure Mode in der Apache-Hadoop-Dokumentation.

HBase

- Wenn Kerberos aktiviert ist, wird die `hbase.rpc.protection`-Eigenschaft für verschlüsselte Kommunikation auf `privacy` gesetzt.
- Weitere Informationen finden Sie unter Clientseitige Konfiguration für sicheren Betrieb in der Apache-HBase-Dokumentation.
- Weitere Informationen über Kerberos mit Amazon EMR finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.

Hive

- Die JDBC/ODBC-Client-Kommunikation mit HiveServer2 (HS2) wird in Amazon EMR-Versionen 6.9.0 und höher mithilfe von SSL-Konfigurationen verschlüsselt.
- Weitere Informationen zur Sicherheit von Kafka finden Sie unter SSL Verschlüsselung in der Apache-Hive-Dokumentation.

Spark

- Interne RPC-Kommunikationen zwischen Spark-Komponenten, z. B. dem Blocktransferdienst und dem externen Shuffle-Service, werden in Amazon-EMR-Version 5.9.0 und höher mit der AES-256-Bit-Verschlüsselung verschlüsselt. In früheren Versionen werden interne RPC-Kommunikationen mithilfe des Verschlüsselungsverfahrens SASL mit DIGEST-MD5 verschlüsselt.
- HTTP-Protokollkommunikationen mit Benutzeroberflächen wie Spark History Server und HTTPS-fähigen Dateiservern werden mithilfe der SSL-Konfiguration von Spark verschlüsselt. Weitere Informationen finden Sie unter SSL-Konfiguration in der Spark-Dokumentation.
- Weitere Informationen finden Sie unter Sicherheitseinstellungen von Spark in der Apache-Spark-Dokumentation.

Tez

- Der Tez-Shuffle-Handler verwendet TLS (`tez.runtime.ssl.enable`).

Presto

- Die interne Kommunikation zwischen Presto-Knoten verwendet SSL/TLS (nur Amazon-EMR-Version 5.6.0 und höher).

Für die Verwendung der Verschlüsselungsartefakte bei der Verschlüsselung von Daten während der Übertragung stehen Ihnen zwei Optionen zur Verfügung: die Bereitstellung einer ZIP-Datei mit den Zertifikaten, die Sie auf Amazon S3 hochladen, oder der Verweis auf eine benutzerdefinierte Java-Klasse, die Verschlüsselungsartefakte bereitstellt. Weitere Informationen finden Sie unter Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung.

Schlüssel und Zertifikate für die Datenverschlüsselung erstellen

Bevor Sie Verschlüsselungsoptionen unter Verwendung einer Sicherheitskonfiguration angeben, legen Sie zunächst den Anbieter der Schlüssel und Verschlüsselungsartefakte fest. Sie können beispielsweise AWS KMS oder einen benutzerdefinierten, von Ihnen erstellten Anbieter verwenden. Erstellen Sie als Nächstes die erforderlichen Schlüssel oder den Schlüsselanbieter, wie in diesem Abschnitt beschrieben.

Bereitstellen von Schlüsseln für die Verschlüsselung von Daten im Ruhezustand mit Amazon EMR

Sie können AWS Key Management Service (AWS KMS) oder einen benutzerdefinierten Schlüsselanbieter für die Datenverschlüsselung im Ruhezustand in Amazon EMR verwenden. Wenn Sie AWS KMS auswählen, fallen für die Speicherung und Nutzung der Verschlüsselungsschlüssel Gebühren an. Weitere Informationen finden Sie unter AWS KMS Preise.

In diesem Thema finden Sie Schlüsselrichtliniendetails für KMS Schlüssel zur Verwendung mit Amazon EMR sowie Anleitungen und Codebeispiele für das Schreiben einer benutzerdefinierten Schlüsselanbieterklasse für die Amazon S3-Verschlüsselung. Weitere Informationen zum Erstellen von -Schlüsseln finden Sie unter Erstellen von Schlüsseln im AWS Key Management Service-Entwicklerhandbuch.

Verwenden von AWS KMS keys für die Verschlüsselung

Der AWS KMS-Verschlüsselungsschlüssel muss in derselben Region erstellt werden wie Ihre Amazon EMR-Cluster-Instance und die mit EMRFS verwendeten Amazon-S3-Buckets. Wenn sich der von Ihnen angegebene Schlüssel in einem anderen Konto befindet als dem, das Sie zur Konfiguration eines Clusters verwenden, müssen Sie den Schlüssel mit seinem ARN angeben.

Die Rolle für das Amazon-EC2-Instance-Profil muss über die Berechtigung zur Nutzung des von Ihnen angegebenen KMS-Schlüssels verfügen. Die Standardrolle für das Instance-Profil in Amazon EMR ist`EMR_EC2_DefaultRole`. Wenn Sie eine andere Rolle für das Instance-Profil oder IAM-Rollen für EMRFS-Anfragen an Amazon S3 verwenden, stellen Sie sicher, dass jede Rolle je nach Bedarf als Schlüsselbenutzer hinzugefügt wird. So erhält die Rolle die Berechtigung, den KMS-Schlüssel zu verwenden. Weitere Informationen finden Sie unter Nutzung von Schlüsselrichtlinien im AWS Key Management Service-Entwicklerhandbuch und Konfigurieren von IAM-Rollen für EMRFS-Anfragen an Amazon S3.

Mithilfe der AWS Management Console können Sie Ihr Instance-Profil oder das EC2-Instance-Profil der Liste der Schlüsselbenutzer für den angegebenen KMS-Schlüssel hinzufügen oder Sie können AWS CLI oder ein AWS-SDK verwenden, um eine entsprechende Schlüsselrichtlinie anzufügen.

Hinweis: Amazon EMR unterstützt nur symmetrische KMS-Schlüssel. Sie können keinen asymmetrischen KMS-Schlüssel verwenden, um Data-at-Rest in einem Amazon-EMR-Cluster zu verschlüsseln. Wie Sie feststellen, ob ein KMS-Schlüssel symmetrisch oder asymmetrisch ist, erfahren Sie unter Erkennen symmetrischer und asymmetrischer KMS-Schlüssel.

Im folgenden Verfahren wird beschrieben, wie Sie das Amazon-EMR-Instance-Profil mithilfe der `EMR_EC2_DefaultRole` als Schlüsselbenutzer mit AWS Management Console hinzufügen. Dabei wird davon ausgegangen, dass Sie bereits einen KMS-Schlüssel erstellt haben. Weitere Informationen über die Erstellung eines neuen KMS-Schlüsseln finden Sie unter Erstellen von Schlüsseln im AWS Key Management Service-Entwicklerhandbuch.

So fügen Sie das EC2-Instance-Profil für Amazon EMR zur Liste der Verschlüsselungsschlüssel-Benutzer hinzu

1. Melden Sie sich bei der AWS Management Console an und öffnen Sie die AWS Key Management Service (AWS KMS)-Konsole unter https://console.aws.amazon.com/kms.
2. Wenn Sie die AWS-Region ändern möchten, verwenden Sie die Regionsauswahl in der oberen rechten Ecke der Seite.
3. Wählen Sie den Alias des zu ändernden KMS-Schlüssels aus.
4. Wählen Sie auf der Seite mit den Schlüsseldetails unter Key Users (Schlüsselbenutzer(die Option Add (Hinzufügen) aus.
5. Wählen Sie die entsprechende Rolle im Dialogfeld Add key users (Schlüsselbenutzer hinzufügen) aus. Der Name der Standardrolle lautet `EMR_EC2_DefaultRole`.
6. Wählen Sie Add (Hinzufügen) aus.

Aktivieren der EBS-Verschlüsselung durch Bereitstellung zusätzlicher Berechtigungen für KMS-Schlüssel

Ab Amazon EMR Version 5.24.0 können Sie EBS-Root-Volumes und Speicher-Volumes mithilfe einer Sicherheitskonfigurationsoption verschlüsseln. Um eine solche Option zu aktivieren, müssen Sie AWS KMS als Schlüsselanbieter angeben. Darüber hinaus müssen Sie der EMR-Servicerolle `EMR_DefaultRole` Berechtigungen zur Verwendung des von Ihnen angegebenen AWS KMS key erteilen.

Sie können mit der AWS Management Console die EMR-Servicerolle der Liste der Schlüsselbenutzer für den angegebenen AWS CLI-CMK hinzufügen. Alternativ können Sie AWS oder ein KMS Schlüssel verwenden, um eine entsprechende Schlüsselrichtlinie anzufügen.

Im folgenden Verfahren wird beschrieben, wie Sie die Standard-EMR-Servicerolle `EMR_DefaultRole` als Schlüsselbenutzer über die AWS Management Console hinzufügen. Dabei wird davon ausgegangen, dass Sie bereits einen KMS-Schlüssel erstellt haben. Weitere Informationen über die Erstellung eines neuen KMS Schlüssels finden Sie unter Erstellen von Schlüsseln im AWS Key Management Service Entwicklerhandbuch.

So fügen Sie der Liste der Verschlüsselungsschlüsselbenutzer eine EMR-Servicerolle hinzu

1. Melden Sie sich bei der AWS Management Console an und öffnen Sie die AWS Key Management Service (AWS KMS)-Konsole unter https://console.aws.amazon.com/kms.
2. Wenn Sie die AWS-Region ändern möchten, verwenden Sie die Regionsauswahl in der oberen rechten Ecke der Seite.
3. Wählen Sie links Vom Kunden verwaltete Schlüssel aus.
4. Wählen Sie den Alias des zu ändernden KMS-Schlüssels aus.
5. Wählen Sie auf der Seite mit den Schlüsseldetails unter Key Users (Schlüsselbenutzer(die Option Add (Hinzufügen) aus.
6. Wählen Sie die entsprechende Rolle im Dialogfeld Add key users (Schlüsselbenutzer hinzufügen) aus. Der Name der Standard-EMR-Servicerolle lautet `EMR_DefaultRole`.
7. Wählen Sie Add (Hinzufügen) aus.

Erstellen eines benutzerdefinierten Schlüsselanbieters

Wenn Sie eine Sicherheitskonfiguration verwenden, müssen Sie einen anderen Anbieterklassennamen für die Verschlüsselung lokaler Datenträger und die Amazon-S3-Verschlüsselung angeben.

Wenn Sie einen benutzerdefinierten Schlüsselanbieter erstellen, implementiert die Anwendung die EncryptionMaterialsProvider-Schnittstelle, die ab der AWS SDK for Java-Version 1.11.0 und höher verfügbar ist. Die Implementierung kann jede Strategie zur Bereitstellung der Verschlüsselungsmaterialien verwenden. Sie können beispielsweise die Bereitstellung statischer Verschlüsselungsmaterialien oder die Integration mit einem komplexeren Schlüsselverwaltungssystem wählen.

Der für benutzerdefinierte Verschlüsselungsmaterialien verwendete Verschlüsselungsalgorithmus muss AES/GCM/NoPadding sein.

Die EncryptionMaterialsProvider-Klasse ruft Verschlüsselungsmaterialien nach Verschlüsselungskontext ab. Amazon EMR aktualisiert die Verschlüsselungskontextinformationen während der Laufzeit. So wird der Aufrufer bei der Entscheidung unterstützt, welche korrekten Verschlüsselungsmaterialien zurückzugeben sind.

Example Beispiel: Verwenden eines benutzerdefinierten Schlüsselanbieters für die Amazon-S3-Verschlüsselung mit EMRFS

Wenn Amazon EMR die Verschlüsselungsmaterialien von der EncryptionMaterialsProvider-Klasse abruft, um die Verschlüsselung durchzuführen, füllt EMRFS optional das materialsDescription-Argument mit zwei Feldern auf: die Amazon S3 URI für das Objekt und die JobFlowId des Clusters, die von der EncryptionMaterialsProvider-Klasse verwendet werden kann, um Verschlüsselungsmaterialien selektiv zurückzugeben.

Beispielsweise kann der Anbieter unterschiedliche Schlüssel für unterschiedliche Amazon-S3-URI-Präfixe zurückgeben. Es ist die Beschreibung der zurückgegebenen Verschlüsselungsmaterialien, die schließlich mit dem Amazon-S3-Objekt gespeichert wird, und nicht der materialsDescription-Wert, der von EMRFS generiert und an den Anbieter weitergeleitet wird. Beim Entschlüsseln eines Amazon-S3-Objekts wird die Verschlüsselungsmateriabeschreibung an die EncryptionMaterialsProvider-Klasse übergeben, sodass diese selektiv den passenden Schlüssel zum Entschlüsseln des Objekts zurückgeben kann.

Nachstehend finden Sie eine EncryptionMaterialsProvider-Referenzimplementierung. Ein weiterer benutzerdefinierter Anbieter, EMRFSRSAEncryptionMaterialsProvider, ist auf GitHub verfügbar.

```
import com.amazonaws.services.s3.model.EncryptionMaterials;
import com.amazonaws.services.s3.model.EncryptionMaterialsProvider;
import com.amazonaws.services.s3.model.KMSEncryptionMaterials;
import org.apache.hadoop.conf.Configurable;
import org.apache.hadoop.conf.Configuration;

import java.util.Map;

/**
 * Provides KMSEncryptionMaterials according to Configuration
 */
public class MyEncryptionMaterialsProviders implements EncryptionMaterialsProvider,
 Configurable{
  private Configuration conf;
  private String kmsKeyId;
  private EncryptionMaterials encryptionMaterials;
```

```
  private void init() {
    this.kmsKeyId = conf.get("my.kms.key.id");
    this.encryptionMaterials = new KMSEncryptionMaterials(kmsKeyId);
  }

  @Override
  public void setConf(Configuration conf) {
    this.conf = conf;
    init();
  }

  @Override
  public Configuration getConf() {
    return this.conf;
  }

  @Override
  public void refresh() {

  }

  @Override
  public EncryptionMaterials getEncryptionMaterials(Map<String, String>
 materialsDescription) {
    return this.encryptionMaterials;
  }

  @Override
  public EncryptionMaterials getEncryptionMaterials() {
    return this.encryptionMaterials;
  }
}
```

Bereitstellen von Zertifikaten für die Verschlüsselung von Daten während der Übertragung mit der Amazon-EMR-Verschlüsselung

Mit Version Amazon EMR 4.8.0 oder höher haben Sie zwei Möglichkeiten für die Angabe von Artefakten für die Verschlüsselung von Daten während der Übertragung mithilfe einer Sicherheitskonfiguration:

- Sie können PEM-Zertifikate manuell erstellen, diese in einer ZIP-Datei einschließen und anschließend in Amazon S3 auf die ZIP-Datei verweisen.

- Sie können einen benutzerdefinierten Zertifikatanbieter als Java-Klasse implementieren. Geben Sie dazu die JAR-Datei der Anwendung in Amazon S3 an und nennen Sie anschließend den vollständigen Klassennamen des Anbieters, wie in der Anwendung deklariert. Die Klasse muss die Schnittstelle TLSArtifactsProvider implementieren, die ab AWS SDK for Java Version 1.11.0 verfügbar ist.

Amazon EMR lädt automatisch Artefakte auf jeden Knoten im Cluster herunter und verwendet sie später dazu, um die Open-Source-Features für die Verschlüsselung von Daten während der Übertragung zu implementieren. Weitere Informationen zu den verfügbaren Optionen finden Sie unter Verschlüsselung während der Übertragung.

Verwenden der PEM-Zertifikate

Wenn Sie eine ZIP-Datei für die Verschlüsselung von Daten während der Übertragung angeben, müssen die PEM-Dateien innerhalb der ZIP-Datei für die Sicherheitskonfiguration genau wie nachfolgend angegeben benannt sein:

Zertifikate für Verschlüsselung von Daten während der Übertragung

Dateiname	Erforderlich/optional	Details
privateKey.pem	Erforderlich	Privater Aktivierungsschlüssel
certificateChain.pem	Erforderlich	Zertifikatskette
trustedCertificates.pem	Optional	Erforderlich, wenn das bereitgestellte Zertifikat nicht entweder von der standardmäßigen vertrauenswürdige Java-Stammzertifizierungsstelle (Certification Authority, CA) oder einer CA-Zwischenzertifizierungsstelle, die eine Verbindung zur Java-Standard-Stammzertifizierungsstelle herstellen kann, signiert wurde. Die standardmäßigen vertrauenswürdigen

Dateiname	Erforderlich/optional	Details
		Java-CAs finden Sie unter `jre/lib/security/cacerts` .

Möglicherweise sollten Sie die private Schlüssel-PEM-Datei als Platzhalterzertifikat konfigurieren, so gewähren Sie Zugriff auf die Amazon VPC-Domain, in der Ihre Cluster-Instances gespeichert sind. Wenn sich Ihr Cluster beispielsweise in der Region us-east-1 (N. Virginia) befindet, könnten Sie in der Zertifikatskonfiguration einen allgemeinen Namen angeben, der durch die Angabe von `CN=*.ec2.internal` in der Zertifikatsubjektdefinition Zugriff auf den Cluster gewährt. Wenn sich Ihr Cluster in der Region us-west-2 (Oregon) befindet, könnten Sie `CN=*.us-west-2.compute.internal` angeben.

Wenn die bereitgestellte PEM-Datei im Verschlüsselungsartefakt kein Platzhalterzeichen im CN für die Domain enthält, müssen Sie den Wert von `hadoop.ssl.hostname.verifier` zu `ALLOW_ALL` ändern. Dies erfolgt mit der `core-site` Klassifizierung beim Senden von Konfigurationen an einen Cluster oder durch Hinzufügen dieses Werts zur Datei `core-site.xml`. Diese Änderung ist erforderlich, da die standardmäßige Hostnamen-Verifizierung keinen Hostnamen ohne Platzhalter akzeptiert, was zu einem Fehler führt. Weitere Informationen zur EMR-Clusterkonfiguration innerhalb einer Amazon VPC finden Sie unter .Netzwerk konfigurieren

Das folgende Beispiel zeigt die Verwendung von OpenSSL zur Generierung eines selbstsignierten X.509-Zertifikats mit einem privaten 1024-Bit-RSA-Schlüssel. Der Schlüssel ermöglicht den Zugriff auf die Amazon-EMR-Cluster-Instances des Ausstellers in der Region `us-west-2` (Oregon), wie durch den Domainnamen *`*.us-west-2.compute.internal`* als allgemeiner Name angegeben.

Es können weitere optionale Subjektelemente wie Land (Country, C), Status (Status, S), Gebietsschema (Locale, L) usw. angegeben werden. Da ein selbstsigniertes Zertifikat generiert wird, kopiert der zweite Befehl im Beispiel die Datei `certificateChain.pem` zur Datei `trustedCertificates.pem`. Der dritte Befehl verwendet `zip` zum Erstellen der Datei `my-certs.zip`, die die Zertifikate enthält.

> **Important**
>
> Dieses Beispiel ist lediglich eine Machbarkeitsnachweis-Demonstration. Die Verwendung von selbstsignierten Zertifikaten wird nicht empfohlen und stellt ein potenzielles Sicherheitsrisiko

dar. Verwenden Sie eine vertrauenswürdige Zertifizierungsstelle (CA), um die Zertifikate für Produktionssysteme auszustellen.

```
$ openssl req -x509 -newkey rsa:1024 -keyout privateKey.pem -out certificateChain.pem
 -days 365 -nodes -subj '/C=US/ST=Washington/L=Seattle/O=MyOrg/OU=MyDept/CN=*.us-
west-2.compute.internal'
$ cp certificateChain.pem trustedCertificates.pem
$ zip -r -X my-certs.zip certificateChain.pem privateKey.pem trustedCertificates.pem
```

AWS Identity and Access Management für Amazon EMR

AWS Identity and Access Management (IAM) ist ein AWS-Service, mit dem ein Administrator den Zugriff auf AWS-Ressourcen sicher steuern kann. IAM-Administratoren steuern, wer authentifiziert (angemeldet) und autorisiert (im Besitz von Berechtigungen) ist, Amazon-EMR-Ressourcen zu nutzen. IAM ist ein AWS-Service, den Sie ohne zusätzliche Kosten verwenden können.

Themen

- Zielgruppe
- Authentifizierung mit Identitäten
- Verwalten des Zugriffs mit Richtlinien
- Funktionsweise von Amazon EMR mit IAM
- Schritte für Laufzeit-Rollen für Amazon EMR
- Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen
- Beispiele für identitätsbasierte Amazon-EMR-Richtlinien

Zielgruppe

Wie Sie AWS Identity and Access Management (IAM) verwenden, unterscheidet sich je nach Ihrer Arbeit in Amazon EMR.

Service-Benutzer - wenn Sie den Amazon EMR-Service zur Ausführung von Aufgaben verwenden, stellt Ihnen Ihr Administrator die Anmeldeinformationen und Berechtigungen bereit, die Sie benötigen.

Wenn Sie zur Ausführung von Aufgaben weitere Amazon-EMR-Features verwenden, benötigen Sie möglicherweise zusätzliche Berechtigungen. Wenn Sie die Funktionsweise der Zugriffskontrolle nachvollziehen, wissen Sie bereits, welche Berechtigungen Sie von Ihrem Administrator anzufordern müssen. Wenn Sie auf ein Feature in Amazon EMR nicht zugreifen können, siehe Fehlerbehebung für Amazon-EMR-Identität und -Zugriff.

Service-Administrator – Wenn Sie in Ihrem Unternehmen für die Amazon EMR-Ressourcen zuständig sind, haben Sie wahrscheinlich vollen Zugriff auf Amazon EMR. Ihre Aufgabe besteht darin, zu bestimmen, auf welche Amazon-EMR-Feature und -Ressourcen Ihre Servicebenutzer zugreifen sollen. Sie müssen dann Anträge an Ihren IAM-Administrator stellen, um die Berechtigungen Ihrer Servicenutzer zu ändern. Lesen Sie die Informationen auf dieser Seite, um die Grundkonzepte von IAM nachzuvollziehen. Weitere Informationen dazu, wie Ihr Unternehmen IAM mit Amazon EMR verwenden kann, finden Sie unter Funktionsweise von Amazon EMR mit IAM.

IAM-Administrator – Wenn Sie ein IAM-Administrator sind, möchten Sie vielleicht Details darüber erfahren, wie Sie Richtlinien zur Verwaltung des Zugriffs auf Amazon EMR erstellen können. Beispiele für identitätsbasierte Amazon-EMR-Richtlinien, die Sie in IAM verwenden können, finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.

Authentifizierung mit Identitäten

Die Authentifizierung ist die Art und Weise, wie Sie sich mit Ihren Anmeldeinformationen bei AWS anmelden. Die Authentifizierung (Anmeldung bei AWS) muss als Root-Benutzer des AWS-Kontos, als IAM-Benutzer oder durch Übernahme einer IAM-Rolle erfolgen.

Sie können sich bei AWS als Verbundidentität mit Anmeldeinformationen anmelden, die über eine Identitätsquelle bereitgestellt werden. Benutzer von AWS IAM Identity Center. (IAM Identity Center), die Single-Sign-on-Authentifizierung Ihres Unternehmens und Anmeldeinformationen für Google oder Facebook sind Beispiele für Verbundidentitäten. Wenn Sie sich als Verbundidentität anmelden, hat der Administrator vorher mithilfe von IAM-Rollen einen Identitätsverbund eingerichtet. Wenn Sie auf AWS mithilfe des Verbunds zugreifen, übernehmen Sie indirekt eine Rolle.

Je nachdem, welcher Benutzertyp Sie sind, können Sie sich bei der AWS Management Console oder beim AWS-Zugriffsportal anmelden. Weitere Informationen zum Anmelden bei AWS finden Sie unter Anmelden bei Ihrem AWS-Konto im Benutzerhandbuch von AWS-Anmeldung.

Bei programmgesteuerten Zugriff auf AWS bietet AWS ein Software Development Kit (SDK) und eine Command Line Interface (CLI, Befehlszeilenschnittstelle) zum kryptographischen Signieren Ihrer Anfragen mit Ihren Anmeldeinformationen. Wenn Sie keine AWS-Tools verwenden, müssen

Sie Anforderungen selbst signieren. Weitere Informationen zur Verwendung der empfohlenen Methode zum eigenen Signieren von Anforderungen finden Sie unter Signieren von AWS-API-Anforderungen im IAM-Benutzerhandbuch.

Unabhängig von der verwendeten Authentifizierungsmethode müssen Sie möglicherweise zusätzliche Sicherheitsinformationen angeben. AWS empfiehlt beispielsweise die Verwendung von Multi-Factor Authentication (MFA), um die Sicherheit Ihres Kontos zu verbessern. Weitere Informationen finden Sie unter Multi-Faktor-Authentifizierung im AWS IAM Identity Center-Benutzerhandbuch und Verwenden der Multi-Faktor-Authentifizierung (MFA) in AWS im IAM-Benutzerhandbuch.

AWS-Konto-Stammbenutzer

Wenn Sie ein AWS-Konto neu erstellen, beginnen Sie mit einer Anmeldeidentität, die vollständigen Zugriff auf alle AWS-Services und Ressourcen des Kontos hat. Diese Identität wird als AWS-Konto-Root-Benutzer bezeichnet. Für den Zugriff auf den Root-Benutzer müssen Sie sich mit der E-Mail-Adresse und dem Passwort anmelden, die zur Erstellung des Kontos verwendet wurden. Wir raten ausdrücklich davon ab, den Root-Benutzer für Alltagsaufgaben zu verwenden. Schützen Sie Ihre Root-Benutzer-Anmeldeinformationen und verwenden Sie diese, um die Aufgaben auszuführen, die nur der Root-Benutzer ausführen kann. Eine vollständige Liste der Aufgaben, für die Sie sich als Root-Benutzer anmelden müssen, finden Sie unter Aufgaben, die Root-Benutzer-Anmeldeinformationen erfordern im IAM-Benutzerhandbuch.

Verbundidentität

Als bewährte Methode empfiehlt es sich, menschliche Benutzer, einschließlich Benutzer, die Administratorzugriff benötigen, aufzufordern, den Verbund mit einem Identitätsanbieter zu verwenden, um auf AWS-Services mit temporären Anmeldeinformationen zuzugreifen.

Eine Verbundidentität ist ein Benutzer aus dem Benutzerverzeichnis Ihres Unternehmens, ein Web Identity Provider, AWS Directory Service , das Identity-Center-Verzeichnis oder jeder Benutzer, der mit Anmeldeinformationen, die über eine Identitätsquelle bereitgestellt werden, auf AWS-Services zugreift. Wenn Verbundidentitäten auf AWS-Konten zugreifen, übernehmen sie Rollen und die Rollen stellen temporäre Anmeldeinformationen bereit.

Für die zentrale Zugriffsverwaltung empfehlen wir Ihnen, AWS IAM Identity Center zu verwenden. Sie können Benutzer und Gruppen im IAM Identity Center erstellen oder Sie können eine Verbindung mit einer Gruppe von Benutzern und Gruppen in Ihrer eigenen Identitätsquelle herstellen und synchronisieren, um sie in allen AWS-Konten und Anwendungen zu verwenden. Informationen zu

IAM Identity Center finden Sie unter Was ist IAM Identity Center? im AWS IAM Identity Center-Benutzerhandbuch.

IAM-Benutzer und -Gruppen

Ein IAM-Benutzer ist eine Identität in Ihrem AWS-Konto mit bestimmten Berechtigungen für eine einzelne Person oder eine einzelne Anwendung. Wenn möglich, empfehlen wir, temporäre Anmeldeinformationen zu verwenden, anstatt IAM-Benutzer zu erstellen, die langfristige Anmeldeinformationen wie Passwörter und Zugriffsschlüssel haben. Bei speziellen Anwendungsfällen, die langfristige Anmeldeinformationen mit IAM-Benutzern erfordern, empfehlen wir jedoch, die Zugriffsschlüssel zu rotieren. Weitere Informationen finden Sie unter Regelmäßiges Rotieren von Zugriffsschlüsseln für Anwendungsfälle, die langfristige Anmeldeinformationen erfordern im IAM-Benutzerhandbuch.

Eine IAM-Gruppe ist eine Identität, die eine Sammlung von IAM-Benutzern angibt. Sie können sich nicht als Gruppe anmelden. Mithilfe von Gruppen können Sie Berechtigungen für mehrere Benutzer gleichzeitig angeben. Gruppen vereinfachen die Verwaltung von Berechtigungen, wenn es zahlreiche Benutzer gibt. Sie könnten beispielsweise einer Gruppe mit dem Namen IAMAdmins Berechtigungen zum Verwalten von IAM-Ressourcen erteilen.

Benutzer unterscheiden sich von Rollen. Ein Benutzer ist einer einzigen Person oder Anwendung eindeutig zugeordnet. Eine Rolle kann von allen Personen angenommen werden, die sie benötigen. Benutzer besitzen dauerhafte Anmeldeinformationen. Rollen stellen temporäre Anmeldeinformationen bereit. Weitere Informationen finden Sie unter Erstellen eines IAM-Benutzers (anstatt einer Rolle) im IAM-Benutzerhandbuch.

IAM roles (IAM-Rollen)

Eine IAM-Rolle ist eine Identität in Ihrem AWS-Konto mit spezifischen Berechtigungen. Sie ist einem IAM-Benutzer vergleichbar, ist aber nicht mit einer bestimmten Person verknüpft. Sie können vorübergehend eine IAM-Rolle in der AWS Management Console übernehmen, indem Sie Rollen wechseln. Sie können eine Rolle annehmen, indem Sie eine AWS CLI oder AWS-API-Operation aufrufen oder eine benutzerdefinierte URL verwenden. Weitere Informationen zu Methoden für die Verwendung von Rollen finden Sie unter Verwenden von IAM-Rollen im IAM-Benutzerhandbuch.

IAM-Rollen mit temporären Anmeldeinformationen sind in folgenden Situationen hilfreich:

- Verbundbenutzerzugriff – Um einer Verbundidentität Berechtigungen zuzuweisen, erstellen Sie eine Rolle und definieren Berechtigungen für die Rolle. Wenn eine Verbundidentität

authentifiziert wird, wird die Identität der Rolle zugeordnet und erhält die von der Rolle definierten Berechtigungen. Informationen zu Rollen für den Verbund finden Sie unter Erstellen von Rollen für externe Identitätsanbieter im IAM-Benutzerhandbuch. Wenn Sie IAM Identity Center verwenden, konfigurieren Sie einen Berechtigungssatz. Wenn Sie steuern möchten, worauf Ihre Identitäten nach der Authentifizierung zugreifen können, korreliert IAM Identity Center den Berechtigungssatz mit einer Rolle in IAM. Informationen zu Berechtigungssätzen finden Sie unter Berechtigungssätze im AWS IAM Identity Center-Benutzerhandbuch.

- Temporäre IAM-Benutzerberechtigungen – Ein IAM-Benutzer oder eine -Rolle kann eine IAM-Rolle übernehmen, um vorübergehend andere Berechtigungen für eine bestimmte Aufgabe zu erhalten.
- Kontenübergreifender Zugriff – Sie können eine IAM-Rolle verwenden, um einem vertrauenswürdigen Prinzipal in einem anderen Konto den Zugriff auf Ressourcen in Ihrem Konto zu ermöglichen. Rollen stellen die primäre Möglichkeit dar, um kontoübergreifendem Zugriff zu gewähren. In einigen AWS-Services können Sie jedoch eine Richtlinie direkt an eine Ressource anfügen (anstatt eine Rolle als Proxy zu verwenden). Informationen zu den Unterschieden zwischen Rollen und ressourcenbasierten Richtlinien für den kontenübergreifenden Zugriff finden Sie unter So unterscheiden sich IAM-Rollen von ressourcenbasierten Richtlinien im IAM-Benutzerhandbuch.
- Serviceübergreifender Zugriff – Einige AWS-Services verwenden Features in anderen AWS-Services. Wenn Sie beispielsweise einen Aufruf in einem Service tätigen, führt dieser Service häufig Anwendungen in Amazon EC2 aus oder speichert Objekte in Amazon S3. Ein Service kann dies mit den Berechtigungen des aufrufenden Prinzipals mit einer Servicerolle oder mit einer serviceverknüpften Rolle tun.
  - Prinzipalberechtigungen – Wenn Sie einen IAM-Benutzer oder eine IAM-Rolle zum Ausführen von Aktionen in AWS verwenden, gelten Sie als Prinzipal. Richtlinien gewähren einem Prinzipal Berechtigungen. Bei einigen Services könnte es Aktionen geben, die dann eine andere Aktion in einem anderen Service auslösen. In diesem Fall müssen Sie über Berechtigungen zum Ausführen beider Aktionen verfügen. Informationen dazu, ob eine Aktion zusätzliche abhängige Aktionen in einer Richtlinie erfordert, finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR in der Service-Autorisierungs-Referenz.
  - Servicerolle – Eine Servicerolle ist eine IAM-Rolle, die ein Service übernimmt, um Aktionen in Ihrem Namen auszuführen. Ein IAM-Administrator kann eine Servicerolle innerhalb von IAM erstellen, ändern und löschen. Weitere Informationen finden Sie unter Erstellen einer Rolle zum Delegieren von Berechtigungen an einen AWS-Service im IAM-Benutzerhandbuch.
  - Serviceverknüpfte Rolle – Eine serviceverknüpfte Rolle ist ein Typ von Servicerolle, die mit einem AWS-Service verknüpft ist. Der Service kann die Rolle übernehmen, um eine Aktion in Ihrem

Namen auszuführen. Serviceverknüpfte Rollen werden in Ihrem AWS-Konto angezeigt und gehören zum Service. Ein IAM-Administrator kann die Berechtigungen für serviceverknüpfte Rollen anzeigen, aber nicht bearbeiten.

- Anwendungen in Amazon EC2 – Sie können eine IAM-Rolle verwenden, um temporäre Anmeldeinformationen für Anwendungen zu verwalten, die auf einer EC2-Instance ausgeführt werden und AWS CLI- oder AWS-API-Anforderungen durchführen. Das ist eher zu empfehlen, als Zugriffsschlüssel innerhalb der EC2-Instance zu speichern. Erstellen Sie ein Instance-Profil, das an die Instance angefügt ist, um eine AWS-Rolle einer EC2-Instance zuzuweisen und die Rolle für sämtliche Anwendungen der Instance bereitzustellen. Ein Instance-Profil enthält die Rolle und ermöglicht, dass Programme, die in der EC2-Instance ausgeführt werden, temporäre Anmeldeinformationen erhalten. Weitere Informationen finden Sie unter Verwenden einer IAM-Rolle zum Erteilen von Berechtigungen für Anwendungen, die auf Amazon EC2-Instances ausgeführt werden im IAM-Benutzerhandbuch.

Informationen dazu, wann Sie IAM-Rollen oder IAM-Benutzer verwenden sollten, finden Sie unter Erstellen einer IAM-Rolle (anstatt eines Benutzers) im IAM-Benutzerhandbuch.

Verwalten des Zugriffs mit Richtlinien

Für die Zugriffssteuerung in AWS erstellen Sie Richtlinien und weisen diese den AWS-Identitäten oder -Ressourcen zu. Eine Richtlinie ist ein Objekt in AWS, das, wenn es einer Identität oder Ressource zugeordnet wird, deren Berechtigungen definiert. AWS wertet diese Richtlinien aus, wenn ein Prinzipal (Benutzer, Root-Benutzer oder Rollensitzung) eine Anforderung stellt. Berechtigungen in den Richtlinien bestimmen, ob die Anforderung zugelassen oder abgelehnt wird. Die meisten Richtlinien werden in AWS als JSON-Dokumente gespeichert. Weitere Informationen zu Struktur und Inhalten von JSON-Richtliniendokumenten finden Sie unter Übersicht über JSON-Richtlinien im IAM-Benutzerhandbuch.

Administratoren können mithilfe von AWS-JSON-Richtlinien festlegen, wer zum Zugriff auf was berechtigt ist. Das heißt, welcher Prinzipal kann Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen.

Standardmäßig haben Benutzer, Gruppen und Rollen keine Berechtigungen. Ein IAM-Administrator muss IAM-Richtlinien erstellen, die Benutzern die Berechtigung erteilen, Aktionen für die Ressourcen auszuführen, die sie benötigen. Der Administrator kann dann die IAM-Richtlinien zu Rollen hinzufügen, und Benutzer können die Rollen annehmen.

IAM-Richtlinien definieren Berechtigungen für eine Aktion unabhängig von der Methode, die Sie zur Ausführung der Aktion verwenden. Angenommen, es gibt eine Richtlinie, die Berechtigungen für die `iam:GetRole`-Aktion erteilt. Ein Benutzer mit dieser Richtlinie kann Benutzerinformationen über die AWS Management Console, die AWS CLI oder die AWS-API abrufen.

Identitätsbasierte Richtlinien

Identitätsbasierte Richtlinien sind JSON-Berechtigungsrichtliniendokumente, die Sie einer Identität anfügen können, wie z. B. IAM-Benutzern, -Benutzergruppen oder -Rollen. Diese Richtlinien steuern, welche Aktionen die Benutzer und Rollen für welche Ressourcen und unter welchen Bedingungen ausführen können. Informationen zum Erstellen identitätsbasierter Richtlinien finden Sie unter Erstellen von IAM-Richtlinien im IAM-Benutzerhandbuch.

Identitätsbasierte Richtlinien können weiter als Inline-Richtlinien oder verwaltete Richtlinien kategorisiert werden. Inline-Richtlinien sind direkt in einen einzelnen Benutzer, eine einzelne Gruppe oder eine einzelne Rolle eingebettet. Verwaltete Richtlinien sind eigenständige Richtlinien, die Sie mehreren Benutzern, Gruppen und Rollen in Ihrem AWS-Konto anfügen können. Verwaltete Richtlinien umfassen von AWS verwaltete und von Kunden verwaltete Richtlinien. Informationen dazu, wie Sie zwischen einer verwalteten Richtlinie und einer eingebundenen Richtlinie wählen, finden Sie unter Auswahl zwischen verwalteten und eingebundenen Richtlinien im IAM-Benutzerhandbuch.

Ressourcenbasierte Richtlinien

Ressourcenbasierte Richtlinien sind JSON-Richtliniendokumente, die Sie an eine Ressource anfügen. Beispiele für ressourcenbasierte Richtlinien sind IAM-Rollen-Vertrauensrichtlinien und Amazon S3-Bucket-Richtlinien. In Services, die ressourcenbasierte Richtlinien unterstützen, können Service-Administratoren sie verwenden, um den Zugriff auf eine bestimmte Ressource zu steuern. Für die Ressource, an welche die Richtlinie angehängt ist, legt die Richtlinie fest, welche Aktionen ein bestimmter Prinzipal unter welchen Bedingungen für diese Ressource ausführen kann. Sie müssen in einer ressourcenbasierten Richtlinie einen Prinzipal angeben. Prinzipale können Konten, Benutzer, Rollen, Verbundbenutzer oder AWS-Services umfassen.

Ressourcenbasierte Richtlinien sind Richtlinien innerhalb dieses Service. Sie können verwaltete AWS-Richtlinien von IAM nicht in einer ressourcenbasierten Richtlinie verwenden.

Zugriffskontrolllisten (ACLs)

Zugriffskontrolllisten (ACLs) steuern, welche Prinzipale (Kontomitglieder, Benutzer oder Rollen) auf eine Ressource zugreifen können. ACLs sind ähnlich wie ressourcenbasierte Richtlinien, verwenden jedoch nicht das JSON-Richtliniendokumentformat.

Amazon S3, AWS WAF und Amazon VPC sind Beispiele für Services, die ACLs unterstützen. Weitere Informationen“ zu ACLs finden Sie unter Zugriffskontrollliste (ACL) – Übersicht (Access Control List) im Amazon-Simple-Storage-Service-Entwicklerhandbuch.

Weitere Richtlinientypen

AWS unterstützt zusätzliche, weniger häufig verwendete Richtlinientypen. Diese Richtlinientypen können die maximalen Berechtigungen festlegen, die Ihnen von den häufiger verwendeten Richtlinientypen erteilt werden können.

- Berechtigungsgrenzen – Eine Berechtigungsgrenze ist ein erweitertes Feature, mit der Sie die maximalen Berechtigungen festlegen können, die eine identitätsbasierte Richtlinie einer IAM-Entität (IAM-Benutzer oder -Rolle) erteilen kann. Sie können eine Berechtigungsgrenze für eine Entität festlegen. Die daraus resultierenden Berechtigungen sind der Schnittpunkt der identitätsbasierten Richtlinien einer Entität und ihrer Berechtigungsgrenzen. Ressourcenbasierte Richtlinien, die den Benutzer oder die Rolle im Feld `Principal` angeben, werden nicht durch Berechtigungsgrenzen eingeschränkt. Ein ausdrückliches Ablehnen in einer dieser Richtlinien setzt das Zulassen außer Kraft. Weitere Informationen über Berechtigungsgrenzen finden Sie unter Berechtigungsgrenzen für IAM-Entitäten im IAM-Benutzerhandbuch.
- Service-Kontrollrichtlinien (SCPs) – SCPs sind JSON-Richtlinien, die die maximalen Berechtigungen für eine Organisation oder Organisationseinheit (OE) in AWS Organizations angeben. AWS Organizations ist ein Service für die Gruppierung und zentrale Verwaltung mehrerer AWS-Konten Ihres Unternehmens. Wenn Sie innerhalb einer Organisation alle Features aktivieren, können Sie Service-Kontrollrichtlinien (SCPs) auf alle oder einzelne Ihrer Konten anwenden. SCPs schränken Berechtigungen für Entitäten in Mitgliedskonten einschließlich des jeweiligen Root-Benutzer des AWS-Kontos ein. Weitere Informationen zu Organizations und SCPs finden Sie unter Funktionsweise von SCPs im AWS Organizations-Benutzerhandbuch.
- Sitzungsrichtlinien – Sitzungsrichtlinien sind erweiterte Richtlinien, die Sie als Parameter übergeben, wenn Sie eine temporäre Sitzung für eine Rolle oder einen verbundenen Benutzer programmgesteuert erstellen. Die resultierenden Sitzungsberechtigungen sind eine Schnittmenge der auf der Identität des Benutzers oder der Rolle basierenden Richtlinien und der Sitzungsrichtlinien. Berechtigungen können auch aus einer ressourcenbasierten Richtlinie

stammen. Eine explizite Zugriffsverweigerung in einer dieser Richtlinien setzt eine Zugriffserlaubnis außer Kraft. Weitere Informationen finden Sie unter Sitzungsrichtlinien im IAM-Benutzerhandbuch.

Mehrere Richtlinientypen

Wenn mehrere auf eine Anforderung mehrere Richtlinientypen angewendet werden können, sind die entsprechenden Berechtigungen komplizierter. Informationen dazu, wie AWS die Zulässigkeit einer Anforderung ermittelt, wenn mehrere Richtlinientypen beteiligt sind, finden Sie unter Logik für die Richtlinienauswertung im IAM-Benutzerhandbuch.

Funktionsweise von Amazon EMR mit IAM

Bevor Sie mit IAM den Zugriff auf Amazon EMR verwalten können, sollten Sie sich darüber informieren, welche IAM-Features Sie mit Amazon EMR verwenden können.

IAM-Features, die Sie mit Amazon EMR verwenden können

IAM-Feature	Amazon-EMR-Support
Identitätsbasierte Richtlinien	Ja
Ressourcenbasierte Richtlinien	Ja
Richtlinienaktionen	Ja
Richtlinienressourcen	Ja
Bedingungsschlüssel für die Richtlinie	Ja
ACLs	Nein
ABAC (Tags in Richtlinien)	Ja
Temporäre Anmeldeinformationen	Ja
Hauptberechtigungen	Ja
Servicerollen	Nein
Service-verknüpfte Rollen	Ja

Einen Überblick über das Zusammenwirken von Amazon EMR und anderen AWS-Services mit den meisten IAM-Features finden Sie unter AWS-Services, die mit IAM funktionieren im IAM-Benutzerhandbuch.

Identitätsbasierte Richtlinien für Amazon EMR

Unterstützt Richtlinien auf Identitätsbasis.	Ja

Identitätsbasierte Richtlinien sind JSON-Berechtigungsrichtliniendokumente, die Sie einer Identität anfügen können, wie z. B. IAM-Benutzern, -Benutzergruppen oder -Rollen. Diese Richtlinien steuern, welche Aktionen die Benutzer und Rollen für welche Ressourcen und unter welchen Bedingungen ausführen können. Informationen zum Erstellen identitätsbasierter Richtlinien finden Sie unter Erstellen von IAM-Richtlinien im IAM-Benutzerhandbuch.

Mit identitätsbasierten IAM-Richtlinien können Sie angeben, welche Aktionen und Ressourcen zugelassen oder abgelehnt werden. Darüber hinaus können Sie die Bedingungen festlegen, unter denen Aktionen zugelassen oder abgelehnt werden. Sie können den Prinzipal nicht in einer identitätsbasierten Richtlinie angeben, da er für den Benutzer oder die Rolle gilt, dem er zugeordnet ist. Informationen zu sämtlichen Elementen, die Sie in einer JSON-Richtlinie verwenden, finden Sie in der IAM-Referenz für JSON-Richtlinienelemente im IAM-Benutzerhandbuch.

Beispiele für identitätsbasierte Richtlinien für Amazon EMR

Beispiele für identitätsbasierte Amazon-EMR-Richtlinien finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.

Ressourcenbasierte Richtlinien in Amazon EMR

Unterstützt ressourcenbasierte Richtlinien	Ja

Ressourcenbasierte Richtlinien sind JSON-Richtliniendokumente, die Sie an eine Ressource anfügen. Beispiele für ressourcenbasierte Richtlinien sind IAM-Rollen-Vertrauensrichtlinien und Amazon S3-Bucket-Richtlinien. In Services, die ressourcenbasierte Richtlinien unterstützen, können Service-Administratoren sie verwenden, um den Zugriff auf eine bestimmte Ressource zu steuern. Für die Ressource, an welche die Richtlinie angehängt ist, legt die Richtlinie fest, welche Aktionen ein

bestimmter Prinzipal unter welchen Bedingungen für diese Ressource ausführen kann. Sie müssen in einer ressourcenbasierten Richtlinie einen Prinzipal angeben. Prinzipale können Konten, Benutzer, Rollen, Verbundbenutzer oder AWS-Services umfassen.

Um kontoübergreifenden Zugriff zu ermöglichen, können Sie ein gesamtes Konto oder IAM-Entitäten in einem anderen Konto als Prinzipal in einer ressourcenbasierten Richtlinie angeben. Durch das Hinzufügen eines kontoübergreifenden Auftraggebers zu einer ressourcenbasierten Richtlinie ist nur die halbe Vertrauensbeziehung eingerichtet. Wenn sich der Prinzipal und die Ressource in unterschiedlichen AWS-Konten befinden, muss ein IAM-Administrator im vertrauenswürdigen Konto auch der Prinzipalentität (Benutzer oder Rolle) die Berechtigung zum Zugriff auf die Ressource erteilen. Sie erteilen Berechtigungen, indem Sie der juristischen Stelle eine identitätsbasierte Richtlinie anfügen. Wenn jedoch eine ressourcenbasierte Richtlinie Zugriff auf einen Prinzipal in demselben Konto gewährt, ist keine zusätzliche identitätsbasierte Richtlinie erforderlich. Weitere Informationen finden Sie unter Wie sich IAM-Rollen von ressourcenbasierten Richtlinien unterscheiden im IAM-Benutzerhandbuch.

Richtlinienaktionen für Amazon EMR

Unterstützt Richtlinienaktionen	Ja

Administratoren können mithilfe von AWS-JSON-Richtlinien festlegen, wer zum Zugriff auf was berechtigt ist. Das heißt, welcher Prinzipal kann Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen.

Das Element `Action` einer JSON-Richtlinie beschreibt die Aktionen, mit denen Sie den Zugriff in einer Richtlinie zulassen oder verweigern können. Richtlinienaktionen haben normalerweise denselben Namen wie die zugehörige AWS-API-Operation. Es gibt einige Ausnahmen, z. B. Aktionen, die nur mit Genehmigung durchgeführt werden können und für die es keinen passenden API-Vorgang gibt. Es gibt auch einige Operationen, die mehrere Aktionen in einer Richtlinie erfordern. Diese zusätzlichen Aktionen werden als abhängige Aktionen bezeichnet.

Schließen Sie Aktionen in eine Richtlinie ein, um Berechtigungen zur Durchführung der zugeordneten Operation zu erteilen.

Eine Liste von Amazon EMR Aktionen finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR in der Service-Autorisierungs-Referenz.

Richtlinienaktionen in Amazon EMR verwenden das folgende Präfix vor der Aktion:

```
EMR
```

Um mehrere Aktionen in einer einzigen Anweisung anzugeben, trennen Sie sie mit Kommata:

```
"Action": [
      "EMR:action1",
      "EMR:action2"
         ]
```

Beispiele für identitätsbasierte Amazon-EMR-Richtlinien finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.

Richtlinienressourcen für Amazon EMR

Unterstützt Richtlinienressourcen	Ja

Administratoren können mithilfe von AWS-JSON-Richtlinien festlegen, wer zum Zugriff auf was berechtigt ist. Das bedeutet die Festlegung, welcher Prinzipal Aktionen für welche Ressourcen unter welchen Bedingungen ausführen kann.

Das JSON-Richtlinienelement `Resource` gibt die Objekte an, auf welche die Aktion angewendet wird. Anweisungen müssen entweder ein `Resource`- oder ein `NotResource`-Element enthalten. Als bewährte Methode geben Sie eine Ressource mit dem zugehörigen Amazon-Ressourcennamen (ARN) an. Sie können dies für Aktionen tun, die einen bestimmten Ressourcentyp unterstützen, der als Berechtigungen auf Ressourcenebene bezeichnet wird.

Verwenden Sie für Aktionen, die keine Berechtigungen auf Ressourcenebene unterstützen, z. B. Auflistungsoperationen, einen Platzhalter (*), um anzugeben, dass die Anweisung für alle Ressourcen gilt.

```
"Resource": "*"
```

Eine Liste von Amazon EMR Ressourcentypen und deren ARNs finden Sie unter Von Amazon EMR definierte Ressourcen in der Service-Autorisierungs-Referenz. Informationen zu den Aktionen, mit

denen Sie den ARN jeder Ressource angeben können, finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR.

Beispiele für identitätsbasierte Amazon-EMR-Richtlinien finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.

Richtlinien-Bedingungsschlüssel für Amazon EMR

Unterstützt servicespezifische Richtlinienbedingungsschlüssel	Ja

Administratoren können mithilfe von AWS-JSON-Richtlinien festlegen, wer zum Zugriff auf was berechtigt ist. Das heißt, welcher Prinzipal kann Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen.

Das Element `Condition` (oder `Condition` block) ermöglicht Ihnen die Angabe der Bedingungen, unter denen eine Anweisung wirksam ist. Das Element `Condition` ist optional. Sie können bedingte Ausdrücke erstellen, die Bedingungsoperatoren verwenden, z. B. ist gleich oder kleiner als, damit die Bedingung in der Richtlinie mit Werten in der Anforderung übereinstimmt.

Wenn Sie mehrere `Condition`-Elemente in einer Anweisung oder mehrere Schlüssel in einem einzelnen `Condition`-Element angeben, wertet AWS diese mittels einer logischen `AND`-Operation aus. Wenn Sie mehrere Werte für einen einzelnen Bedingungsschlüssel angeben, wertet AWS die Bedingung mittels einer logischen `OR`-Operation aus. Alle Bedingungen müssen erfüllt werden, bevor die Berechtigungen der Anweisung gewährt werden.

Sie können auch Platzhaltervariablen verwenden, wenn Sie Bedingungen angeben. Beispielsweise können Sie einem IAM-Benutzer die Berechtigung für den Zugriff auf eine Ressource nur dann gewähren, wenn sie mit dessen IAM-Benutzernamen gekennzeichnet ist. Weitere Informationen finden Sie unter IAM-Richtlinienelemente: Variablen und Tags im IAM-Benutzerhandbuch.

AWS unterstützt globale Bedingungsschlüssel und servicespezifische Bedingungsschlüssel. Eine Liste aller globalen AWS-Bedingungsschlüssel finden Sie unter Globale AWS-Bedingungskontextschlüssel im IAM-Benutzerhandbuch.

Eine Liste der Bedingungsschlüssel von Amazon EMR und Informationen darüber, welche Aktionen und Ressourcen Sie mit einem Bedingungsschlüssel verwenden können, finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR in der Service-Autorisierungs-Referenz.

Beispiele für identitätsbasierte Amazon-EMR-Richtlinien finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.

Zugriffssteuerungslisten (ACLs) in Amazon EMR

Unterstützt ACLs	Nein

Zugriffskontrolllisten (ACLs) steuern, welche Prinzipale (Kontomitglieder, Benutzer oder Rollen) auf eine Ressource zugreifen können. ACLs sind ähnlich wie ressourcenbasierte Richtlinien, verwenden jedoch nicht das JSON-Richtliniendokumentformat.

Attributbasierte Zugriffssteuerung (ABAC) mit Amazon EMR

Unterstützt ABAC (Tags in Richtlinien)	Ja

Die attributbasierte Zugriffskontrolle (ABAC) ist eine Autorisierungsstrategie, bei der Berechtigungen basierend auf Attributen definiert werden. In AWS werden diese Attribute als Tags bezeichnet. Sie können Tags an IAM-Entitäten (Benutzer oder Rollen) und mehrere AWS-Ressourcen anfügen. Das Markieren von Entitäten und Ressourcen ist der erste Schritt von ABAC. Anschließend entwerfen Sie ABAC-Richtlinien, um Operationen zuzulassen, wenn das Tag des Prinzipals mit dem Tag der Ressource übereinstimmt, auf die sie zugreifen möchten.

ABAC ist in Umgebungen hilfreich, die schnell wachsen, und unterstützt Sie in Situationen, in denen die Richtlinienverwaltung mühsam wird.

Um den Zugriff auf der Grundlage von Tags zu steuern, geben Sie im Bedingungselement einer Richtlinie Tag-Informationen an, indem Sie die Schlüssel `aws:ResourceTag/`*`key-name`*, `aws:RequestTag/`*`key-name`*, oder `aws:TagKeys`Bedingung verwenden.

Wenn ein Service alle drei Bedingungsschlüssel für jeden Ressourcentyp unterstützt, lautet der Wert für den Service Ja. Wenn ein Service alle drei Bedingungsschlüssel für nur einige Ressourcentypen unterstützt, lautet der Wert Teilweise.

Weitere Informationen zu ABAC finden Sie unter Was ist ABAC? im IAM-Benutzerhandbuch. Um ein Tutorial mit Schritten zur Einstellung von ABAC anzuzeigen, siehe Attributbasierte Zugriffskontrolle (ABAC) verwenden im IAM-Benutzerhandbuch.

Verwenden temporärer Anmeldeinformationen mit Amazon EMR

Unterstützt temporäre Anmeldeinformationen	Ja

Einige AWS-Services funktionieren nicht, wenn Sie sich mit temporären Anmeldeinformationen anmelden. Weitere Informationen, darunter welche AWS-Services mit temporären Anmeldeinformationen funktionieren, finden Sie unter AWS-Services, die mit IAM funktionieren im IAM-Benutzerhandbuch.

Sie verwenden temporäre Anmeldeinformationen, wenn Sie sich mit einer anderen Methode als einem Benutzernamen und einem Passwort bei der AWS Management Console anmelden. Wenn Sie beispielsweise über den Single Sign-On (SSO)-Link Ihres Unternehmens auf AWS zugreifen, erstellt dieser Prozess automatisch temporäre Anmeldeinformationen. Sie erstellen auch automatisch temporäre Anmeldeinformationen, wenn Sie sich als Benutzer bei der Konsole anmelden und dann die Rollen wechseln. Weitere Informationen zum Wechseln von Rollen finden Sie unter Wechseln zu einer Rolle (Konsole) im IAM-Benutzerhandbuch.

Sie können mithilfe der AWS CLI- oder AWS-API manuell temporäre Anmeldeinformationen erstellen. Sie können dann diese temporären Anmeldeinformationen verwenden, um auf AWS zuzugreifen. AWS empfiehlt, dass Sie temporäre Anmeldeinformationen dynamisch generieren, anstatt langfristige Zugriffsschlüssel zu verwenden. Weitere Informationen finden Sie unter Temporäre Sicherheitsanmeldeinformationen in IAM.

Serviceübergreifende Prinzipalberechtigungen für Amazon EMR

Unterstützt Hauptberechtigungen	Ja

Wenn Sie einen IAM-Benutzer oder eine IAM-Rolle zum Ausführen von Aktionen in AWS verwenden, gelten Sie als Prinzipal. Richtlinien erteilen einem Prinzipal Berechtigungen. Bei einigen Services könnte es Aktionen geben, die dann eine andere Aktion in einem anderen Service auslösen. In diesem Fall müssen Sie über Berechtigungen zum Ausführen beider Aktionen verfügen. Informationen dazu, ob eine Aktion zusätzliche abhängige Aktionen in einer Richtlinie erfordert, finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR in der Service-Autorisierungs-Referenz.

Servicerollen für Amazon EMR

Unterstützt Servicerollen	Nein

Serviceverknüpfte Rollen für Amazon EMR

Unterstützt serviceverknüpfte Rollen	Ja

Details zum Erstellen oder Verwalten von serviceverknüpften Rollen finden Sie unter AWS-Services, die mit IAM funktionieren. Suchen Sie in der Tabelle nach einem Service mit einem `Yes` in der Spalte Service-linked role (Serviceverknüpfte Rolle). Wählen Sie den Link Yes (Ja) aus, um die Dokumentation für die serviceverknüpfte Rolle für diesen Service anzuzeigen.

Verwenden Sie Cluster- und Notebook-Tags mit IAM-Richtlinien für die Zugriffskontrolle

Die Berechtigungen für Amazon EMR-Aktionen, die EMR Notebooks und EMR-Clustern zugeordnet sind, können anhand der Tag-basierten Zugriffskontrolle mit identitätsbasierten IAM-Richtlinien abgestimmt werden. Sie können Bedingungsschlüssel in einem `Condition`-Element (auch als `Condition`-Block bezeichnet) verwenden, um bestimmte Aktionen nur dann zuzulassen, wenn ein Notebook, ein Cluster oder beide bestimmte Tag-Schlüssel oder Schlüssel-Wert-Kombinationen aufweisen. Sie können auch die Aktion `CreateEditor` (erstellt ein EMR Notebook) und die Aktion `RunJobFlow` (erstellt einen Cluster) einschränken, damit bei der Erstellung der Ressource eine Anforderung für ein Tag eingereicht werden muss.

In Amazon EMR gelten die Bedingungsschlüssel, die in einem `Condition`-Element verwendet werden können, nur für die Amazon EMR-API-Aktionen, für die `ClusterID` oder `NotebookID` ein erforderlicher Anforderungsparameter ist. Beispielsweise unterstützt die Aktion ModifyInstanceGroups keine Kontextschlüssel, da `ClusterID` ein optionaler Parameter ist.

Wenn Sie ein EMR-Notebook erstellen, wird ein Standard-Tag angewendet. Dabei entspricht die Schlüsselzeichenfolge `creatorUserId` der IAM-Benutzer-ID, mit der das Notebook erstellt wurde. Dies ist nützlich, um zulässige Aktionen für das Notebook ausschließlich auf den Ersteller zu beschränken.

Die folgenden Bedingungsschlüssel sind in Amazon EMR: verfügbar:

- Verwenden Sie den Bedingungskontextschlüssel `elasticmapreduce:ResourceTag/`*`TagKeyString`*, um Benutzeraktionen in Clustern oder Notebooks mit Tags mit dem von Ihnen festgelegten *`TagKeyString`* zuzulassen oder abzulehnen. Wenn eine Aktion sowohl `NotebookID` als auch `ClusterID` übergibt, gilt die Bedingung sowohl für den Cluster als auch das Notebook. Das bedeutet, dass beide Ressourcen dieselbe Tag-Schlüsselzeichenfolge oder Schlüssel-Wert-Kombination aufweisen müssen. Sie können das Element `Resource` verwenden, um die Anweisung nach Bedarf nur auf Cluster oder Notebooks zu beschränken. Weitere Informationen finden Sie unter Beispiele für identitätsbasierte Amazon-EMR-Richtlinien.
- Verwenden Sie den Bedingungskontextschlüssel `elasticmapreduce:RequestTag/`*`TagKeyString`*, um ein bestimmtes Tag mit Aktionen/API-Aufrufe anzufordern. Verwenden Sie diesen Bedingungskontextschlüssel zusammen mit der `CreateEditor`-Aktion, um festzulegen, dass bei der Erstellung von Notebooks ein Schlüssel mit *`TagKeyString`* angewendet wird.

Beispiele

Eine Liste der Amazon EMR Aktionen finden Sie unter Von Amazon EMR definierte Aktionen im IAM-Benutzerhandbuch.

Schritte für Laufzeit-Rollen für Amazon EMR

Eine Laufzeit-Rolle ist eine AWS Identity and Access Management (IAM)-Rolle, die Sie angeben können, wenn Sie einen Job oder eine Abfrage an einen Amazon-EMR-Cluster senden. Der Auftrag oder die Abfrage, die Sie an Ihren Amazon-EMR-Cluster senden, verwendet die Laufzeit-Rolle, um auf AWS-Ressourcen wie Objekte in Amazon S3 zuzugreifen. Sie können Laufzeit-Rollen mit Amazon EMR für Spark- und Hive-Jobs angeben.

Sie können auch Laufzeit-Rollen angeben, wenn Sie eine Verbindung zu Amazon EMR-Clustern in einem EMR-Cluster herstellen Amazon SageMaker und wenn Sie einen Amazon EMR Studio Workspace an einen EMR-Cluster anhängen. Weitere Informationen finden Sie unter Herstellen einer Verbindung zu einem Amazon EMR-Cluster über Studio und Einen EMR-Studio-Workspace mit einer Laufzeit-Rolle ausführen.

Zuvor führten Amazon EMR-Cluster Amazon EMR-Aufträge oder -Abfragen mit Berechtigungen aus, die auf der IAM-Richtlinie basierten, die dem Instance-Profil zugeordnet war, das Sie zum Starten des Clusters verwendet haben. Das bedeutete, dass die Richtlinien die Vereinigung aller Berechtigungen für alle Aufträge und Abfragen enthalten mussten, die auf einem Amazon EMR-Cluster ausgeführt

wurden. Mit Laufzeit-Rollen können Sie jetzt die Zugriffskontrolle für jeden Auftrag oder jede Abfrage einzeln verwalten, anstatt das Amazon EMR-Instance-Profil des Clusters gemeinsam zu nutzen.

Auf Amazon EMR-Clustern mit Laufzeit-Rollen können Sie auch eine AWS Lake Formation basierte Zugriffskontrolle auf Spark-, Hive- und Presto-Aufträge und Abfragen für Ihre Data Lakes anwenden. Weitere Informationen zur Integration mit AWS Lake Formation finden Sie unter Integrieren Sie Amazon EMR mit AWS Lake Formation.

> **Note**
>
> Wenn Sie eine Laufzeit-Rolle für einen Amazon EMR-Schritt angeben, können die Aufträge oder Abfragen, die Sie einreichen, nur auf AWS Ressourcen zugreifen, die die mit der Laufzeit-Rolle verknüpften Richtlinien zulassen. Diese Aufträge und Abfragen können nicht auf den Instance Metadata Service auf den EC2-Instances des Clusters zugreifen oder das EC2-Instance-Profil des Clusters für den Zugriff auf AWS-Ressourcen verwenden.

Voraussetzungen für den Start eines Amazon EMR-Clusters mit einer Laufzeit-Rolle

Themen

- Schritt 1: Sicherheitskonfigurationen in Amazon EMR einrichten
- Schritt 2: Ein EC2-Instance-Profil für den Amazon EMR-Cluster einrichten
- Schritt 3: Eine Vertrauensrichtlinie einrichten

Schritt 1: Sicherheitskonfigurationen in Amazon EMR einrichten

Verwenden Sie die folgende JSON-Struktur, um eine Sicherheitskonfiguration für AWS Command Line Interface (AWS CLI) zu erstellen, und setzen Sie `EnableApplicationScopedIAMRole` auf `true`. Weitere Informationen zu den Sicherheitskonfigurationen finden Sie unter Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden.

```
{
    "AuthorizationConfiguration":{
        "IAMConfiguration":{
            "EnableApplicationScopedIAMRole":true
        }
    }
}
```

Wir empfehlen, in der Sicherheitskonfiguration immer die Verschlüsselungsoptionen bei der Übertragung zu aktivieren, sodass Daten, die über das Internet übertragen werden, verschlüsselt und nicht im Klartext übertragen werden. Sie können diese Optionen überspringen, wenn Sie keine Verbindung zu Amazon EMR-Clustern mit Laufzeit-Rollen aus SageMaker Studio oder EMR Studio herstellen möchten. Informationen zur Konfiguration der Datenverschlüsselung finden Sie unter Datenverschlüsselung konfigurieren.

Alternativ können Sie mit dem eine Sicherheitskonfiguration mit benutzerdefinierten Einstellungen mit AWS Management Console erstellen.

Schritt 2: Ein EC2-Instance-Profil für den Amazon EMR-Cluster einrichten

Amazon EMR-Cluster verwenden die Amazon-EC2-Instance-Profilrolle, um die Laufzeit-Rollen zu übernehmen. Um Laufzeit-Rollen mit Amazon EMR-Schritten zu verwenden, fügen Sie der IAM-Rolle, die Sie als Instance-Profilrolle verwenden möchten, die folgenden Richtlinien hinzu. Informationen zum Hinzufügen von Richtlinien zu einer IAM-Rolle oder zum Bearbeiten einer vorhandenen Inline- oder verwalteten Richtlinie finden Sie unter Hinzufügen und Entfernen von IAM-Identitätsberechtigungen.

```
{
    "Version":"2012-10-17",
    "Statement":[
        {
            "Sid":"AllowRuntimeRoleUsage",
            "Effect":"Allow",
            "Action":[
                "sts:AssumeRole",
                "sts:TagSession"
            ],
            "Resource":[
                <runtime-role-ARN>
            ]
        }
    ]
}
```

Schritt 3: Eine Vertrauensrichtlinie einrichten

Legen Sie für jede IAM-Rolle, die Sie als Laufzeit-Rolle verwenden möchten, die folgende Vertrauensrichtlinie fest und ersetzen Sie sie `EMR_EC2_DefaultRole` durch Ihre Instance-

Profilrolle. Informationen zum Ändern der Vertrauensrichtlinie einer IAM-Rolle finden Sie unter Vertrauensrichtlinie für Rollen ändern.

```
{
    "Sid":"AllowAssumeRole",
    "Effect":"Allow",
    "Principal":{
        "AWS":"arn:aws:iam::<AWS_ACCOUNT_ID>:role/EMR_EC2_DefaultRole"
    },
    "Action":"sts:AssumeRole"
}
```

Starten Sie einen Amazon-EMR-Cluster mit rollenbasierter Zugriffskontrolle

Nachdem Sie Ihre Konfigurationen eingerichtet haben, können Sie einen Amazon EMR-Cluster mit der Sicherheitskonfiguration von Schritt 1: Sicherheitskonfigurationen in Amazon EMR einrichten starten. Um Laufzeit-Rollen mit Amazon-EMR-Schritten zu verwenden, verwenden Sie Release Label `emr-6.7.0` oder höher und wählen Sie Hive, Spark oder beide als Cluster-Anwendung aus. Um von SageMaker Studio aus eine Verbindung herzustellen, verwenden Sie Release `emr-6.9.0` oder höher und wählen Sie Livy, Spark, Hive oder Presto als Ihre Cluster-Anwendung aus. Anweisungen zum Start Ihres Clusters finden Sie unter Angabe einer Sicherheitskonfiguration für einen Cluster.

Spark-Jobs mithilfe der Amazon-EMR-Schritte übermitteln

Im Folgenden finden Sie ein Beispiel für die Ausführung des in Apache Spark enthaltenen HdfsTest-Beispiels. Dieser API-Aufruf ist nur erfolgreich, wenn die bereitgestellte Amazon EMR-Laufzeitrolle auf die `S3_LOCATION` zugreifen kann.

```
RUNTIME_ROLE_ARN=<runtime-role-arn>
S3_LOCATION=<s3-path>
REGION=<aws-region>
CLUSTER_ID=<cluster-id>

aws emr add-steps --cluster-id $CLUSTER_ID \
--steps '[{ "Name": "Spark Example", "ActionOnFailure": "CONTINUE","HadoopJarStep":
 { "Jar":"command-runner.jar","Args" : ["spark-example","HdfsTest",
 "$S3_LOCATION"] } }]' \
--execution-role-arn $RUNTIME_ROLE_ARN \
--region $REGION
```

> **Note**
>
> Wir empfehlen, den SSH-Zugriff auf den Amazon-EMR-Cluster zu deaktivieren und nur der Amazon-EMR-`AddJobFlowSteps`-API den Zugriff auf den Cluster zu gewähren.

Hive-Jobs mithilfe der Amazon-EMR-Schritte übermitteln

Im folgenden Beispiel wird Apache Hive mit Amazon-EMR-Schritten verwendet, um einen Job zur Ausführung der `QUERY_FILE.hql` Datei einzureichen. Diese Abfrage ist nur erfolgreich, wenn die angegebene Laufzeit-Rolle auf den Amazon-S3-Pfad der Abfragedatei zugreifen kann.

```
RUNTIME_ROLE_ARN=<runtime-role-arn>
REGION=<aws-region>
CLUSTER_ID=<cluster-id>

aws emr add-steps --cluster-id $CLUSTER_ID \
--steps '[{ "Name": "Run hive query using command-runner.jar - simple
 select","ActionOnFailure":"CONTINUE","HadoopJarStep": { "Jar": "command-
runner.jar","Args" :["hive -
f","s3://DOC_EXAMPLE_BUCKET/QUERY_FILE.hql"] } }]' \
--execution-role-arn $RUNTIME_ROLE_ARN \
--region $REGION
```

Verbinden mit Amazon-EMR-Clustern mit Laufzeitrollen von einem SageMaker-Studio-Notebook aus

Sie können Amazon EMR-Laufzeit-Rollen auf Abfragen anwenden, die Sie in Amazon-EMR-Clustern von SageMaker Studio aus ausführen. Führen Sie dazu die folgenden Schritte aus.

1. Folgen Sie den Anweisungen unter Amazon SageMaker Studio starten, um ein SageMaker Studio zu erstellen.
2. Starten Sie in der Benutzeroberfläche von SageMaker Studio ein Notebook mit unterstützten Kerneln. Starten Sie beispielsweise ein SparkMagic-Image mit einem PySpark-Kernel.
3. Wählen Sie in SageMaker Studio einen Amazon EMR-Cluster und dann Verbinden aus.
4. Wählen Sie eine Laufzeit-Rolle und dann Verbinden aus.

Dadurch wird eine SageMaker-Notebookzelle mit magischen Befehlen erstellt, um eine Verbindung zu Ihrem Amazon-EMR-Cluster mit der ausgewählten Amazon-EMR-Laufzeitrolle herzustellen.

In der Notebook-Zelle können Sie Abfragen mit Laufzeit-Rollen- und Lake-Formation-basierter Zugriffskontrolle eingeben und ausführen. Ein detaillierteres Beispiel finden Sie unter Anwenden detaillierter Datenzugriffskontrollen mit AWS Lake Formation Amazon EMR von Amazon SageMaker Studio.

Steuern Sie den Zugriff auf die Amazon EMR-Laufzeit-Rolle

Sie können den Zugriff auf die Laufzeit-Rolle mit dem Bedingungsschlüssel `elasticmapreduce:ExecutionRoleArn` steuern. Die folgende Richtlinie ermöglicht es einem IAM-Prinzipal, eine IAM-Rolle mit dem Namen `Caller` oder eine beliebige IAM-Rolle, die mit der Zeichenfolge `CallerTeamRole` beginnt, als Laufzeitrolle zu verwenden.

> **Important**
>
> Sie müssen eine auf dem `elasticmapreduce:ExecutionRoleArn` Kontextschlüssel basierende Bedingung erstellen, wenn Sie einem Aufrufer Zugriff auf die `AddJobFlowSteps` oder `GetClusterSessionCredentials`-APIs gewähren, wie das folgende Beispiel zeigt.

```
{
    "Sid":"AddStepsWithSpecificExecRoleArn",
    "Effect":"Allow",
    "Action":[
        "elasticmapreduce:AddJobFlowSteps"
    ],
    "Resource":"*",
    "Condition":{
        "StringEquals":{
            "elasticmapreduce:ExecutionRoleArn":[
                "arn:aws:iam::<AWS_ACCOUNT_ID>:role/Caller"
            ]
        },
        "StringLike":{
            "elasticmapreduce:ExecutionRoleArn":[
                "arn:aws:iam::<AWS_ACCOUNT_ID>:role/CallerTeamRole*"
            ]
        }
    }
}
```

Schaffen Sie Vertrauen zwischen Laufzeit-Rollen und Amazon EMR-Clustern

Amazon EMR generiert eine eindeutige Kennung `ExternalId` für jede Sicherheitskonfiguration mit aktivierter Laufzeit-Rollenautorisierung. Diese Autorisierung ermöglicht es jedem Benutzer, eine Reihe von Laufzeit-Rollen zu besitzen, die er auf Clustern verwenden kann, die ihm gehören. In einem Unternehmen kann beispielsweise jede Abteilung ihre externe ID verwenden, um die Vertrauensrichtlinie für ihre eigenen Laufzeit-Rollen zu aktualisieren.

Sie können die externe ID mit der Amazon-EMR-`DescribeSecurityConfiguration`-API finden, wie im folgenden Beispiel gezeigt.

```
aws emr describe-security-configuration --name 'iamconfig-with-lf'{"Name": "iamconfig-
with-lf",
    "SecurityConfiguration":
        "{\"AuthorizationConfiguration\":{\"IAMConfiguration\":
{\"EnableApplicationScopedIAMRole\
        ":true,\"ApplicationScopedIAMRoleConfiguration\":{\"PropagateSourceIdentity
\":true,\"Exter
        nalId\":\"FXH5TSACFDWUCDSR3YQE2O7ETPUSM4OBCGLYWODSCUZDNZ4Y\"}},\"Lake
        FormationConfiguration\":{\"AuthorizedSessionTagValue\":\"Amazon EMR\"}}}",
    "CreationDateTime": "2022-06-03T12:52:35.308000-07:00"
}
```

Informationen zur Verwendung einer externen ID finden Sie unter So verwenden Sie eine externe ID, wenn Sie einem Dritten Zugriff auf Ihre AWS-Ressourcen gewähren.

Audit

Um die Aktionen zu überwachen und zu kontrollieren, die Endbenutzer mit IAM-Rollen ergreifen, können Sie das Quellidentitätsfeature aktivieren. Weitere Informationen zur Quellenidentität finden Sie unter Überwachen und Steuern von Aktionen mit übernommenen Rollen.

Um die Quellidentität nachzuverfolgen, stellen Sie `ApplicationScopedIAMRoleConfiguration/PropagateSourceIdentity` in Ihrer Sicherheitskonfiguration wie folgt auf `true` ein.

```
{
    "AuthorizationConfiguration":{
        "IAMConfiguration":{
            "EnableApplicationScopedIAMRole":true,
            "ApplicationScopedIAMRoleConfiguration":{
```

```
                "PropagateSourceIdentity":true
            }
        }
    }
}
```

Wenn Sie `PropagateSourceIdentity` auf `true` einstellen, wendet Amazon EMR die Quellidentität aus den Anrufanmeldedaten auf einen Job oder eine Abfragesitzung an, die Sie mit der Laufzeit-Rolle erstellen. Wenn in den Anrufanmeldedaten keine Quellidentität enthalten ist, legt Amazon EMR die Quellidentität nicht fest.

Um diese Eigenschaft zu verwenden, geben Sie wie folgt `sts:SetSourceIdentity`-Berechtigungen für Ihr Instance-Profil ein.

```
{ // PropagateSourceIdentity statement
    "Sid":"PropagateSourceIdentity",
    "Effect":"Allow",
    "Action":"sts:SetSourceIdentity",
    "Resource":[
        <runtime-role-ARN>
    ],
    "Condition":{
        "StringEquals":{
            "sts:SourceIdentity":<source-identity>
        }
    }
}
```

Sie müssen die `AllowSetSourceIdentity`-Anweisung auch zur Vertrauensrichtlinie Ihrer Laufzeit-Rollen hinzufügen.

```
{ // AllowSetSourceIdentity statement
    "Sid":"AllowSetSourceIdentity",
    "Effect":"Allow",
    "Principal":{
        "AWS":"arn:aws:iam::<AWS_ACCOUNT_ID>:role/EMR_EC2_DefaultRole"
    },
    "Action":[
        "sts:SetSourceIdentity",
        "sts:AssumeRole"
    ],
    "Condition":{
```

```
        "StringEquals":{
            "sts:SourceIdentity":<source-identity>
        }
    }
}
```

Weitere Überlegungen

> **Note**
>
> Mit Amazon EMR-Version `emr-6.9.0` kann es zu zeitweiligen Ausfällen kommen, wenn Sie von SageMaker Studio aus eine Verbindung zu Amazon-EMR-Clustern herstellen. Um dieses Problem zu lösen, können Sie den Patch mit einer Bootstrap-Aktion installieren, wenn Sie den Cluster starten. Einzelheiten zum Patch finden Sie unter Bekannte Probleme in Amazon EMR Version 6.9.0.

Beachten Sie außerdem Folgendes, wenn Sie Laufzeit-Rollen für Amazon EMR konfigurieren.

- Amazon EMR unterstützt Laufzeit-Rollen in allen kommerziellen AWS-Regionen Anwendungen.
- Amazon EMR-Schritte unterstützen Apache Spark- und Apache Hive-Jobs mit Laufzeit-Rollen, wenn Sie Release `emr-6.7.0` oder höher verwenden.
- SageMaker Studio unterstützt Spark-, Hive- und Presto-Abfragen mit Laufzeit-Rollen, wenn Sie Release `emr-6.9.0` oder höher verwenden.
- Die folgenden Notebook-Kernel in SageMaker unterstützen Laufzeit-Rollen:
  - DataScience – Python-3-Kernel
  - DataScience 2.0 – Python-3-Kernel
  - DataScience 3.0 – Python-3-Kernel
  - SparkAnalytics 1.0 – SparkMagic- und PySpark-Kernel
  - SparkAnalytics 2.0 – SparkMagic- und PySpark-Kernel
  - SparkMagic – PySpark-Kernel
- Amazon EMR unterstützt Schritte, die `RunJobFlow` nur zum Zeitpunkt der Clustererstellung verwendet werden. Diese API unterstützt keine Laufzeit-Rollen.
- Amazon EMR unterstützt keine Laufzeit-Rollen auf Clustern, die Sie so konfigurieren, dass sie hochverfügbar sind.

- Laufzeit-Rollen bieten keine Unterstützung für die Steuerung des Zugriffs auf Cluster-Ressourcen wie HDFS und HMS.

Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen

Amazon EMR und Anwendungen wie Hadoop und Spark benötigen Berechtigungen für den Zugriff auf andere AWS-Ressourcen und die Ausführung von Aktionen während der Ausführung. Jeder Cluster in Amazon EMR muss eine Servicerolle und eine Rolle für das Amazon-EC2-Instance-Profil haben. Weitere Informationen finden Sie unter IAM-Rollen und Verwenden von Instance-Profilen im IAM-Benutzerhandbuch. Die diesen Rollen zugeordneten IAM-Richtlinien stellen dem Cluster die Berechtigung bereit, im Namen eines Benutzers mit anderen AWS-Services zu interagieren.

Eine zusätzliche Rolle, die Auto Scaling-Rolle, ist erforderlich, wenn Ihr Cluster ein Auto Scaling in Amazon EMR verwendet. Die AWS-Servicerolle für EMR-Notebooks ist erforderlich, wenn Sie EMR Notebooks verwenden.

Amazon EMR bietet Standardrollen und standardmäßig verwaltete Richtlinien für alle Rollen, die Berechtigungen bestimmen. Verwaltete Richtlinien werden von AWS erstellt und verwaltet, sodass sie automatisch aktualisiert werden, wenn sich Serviceanforderungen ändern. Siehe unter Von AWS verwaltete Richtlinien im IAM-Benutzerhandbuch.

Wenn Sie zum ersten Mal einen Cluster oder ein Notebook in einem Konto erstellen, existieren für Amazon EMR noch keine Rollen. Nach ihrer Erstellung können Sie die Rollen, die diesen angefügten Richtlinien und die durch die Richtlinien erteilten oder verweigerten Berechtigungen in der IAM-Konsole (https://console.aws.amazon.com/iam/) anzeigen. Sie können Standardrollen für Amazon EMR zum Erstellen und Verwenden angeben, Sie können Ihre eigenen Rollen erstellen und sie einzeln angeben, wenn Sie einen Cluster erstellen, um Berechtigungen anpassen. Und Sie können Standardrollen angeben, die verwendet werden sollen, wenn Sie einen Cluster mithilfe der AWS CLI erstellen. Weitere Informationen finden Sie unter IAM-Rollen anpassen.

Ändern von identitätsbasierten Richtlinien für Berechtigungen zum Übergeben von Servicerollen für Amazon EMR

Die verwalteten Standardrichtlinien von Amazon EMR mit vollen Berechtigungen beinhalten `iam:PassRole`-Sicherheitskonfigurationen, darunter die folgenden:

- `iam:PassRole`-Berechtigungen nur für bestimmte Amazon-EMR-Standardrollen.

- `iam:PassedToService`-Bedingungen, die es Ihnen ermöglichen, die Richtlinie nur mit bestimmten AWS-Services zu verwenden, z. B. `elasticmapreduce.amazonaws.com` und `ec2.amazonaws.com`.

Sie können die JSON-Version der Richtlinien AmazonEMRFullAccessPolicy_v2 und AmazonEMRServicePolicy_v2 in der IAM-Konsole anzeigen. Wir empfehlen, dass Sie neue Cluster mit den verwalteten v2-Richtlinien erstellen.

Übersicht über Servicerollen

In der folgenden Tabelle finden Sie als Referenz die IAM-Servicerollen aufgelistet, die Amazon EMR zugeordnet sind.

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
Servicerolle für Amazon EMR (EMR-Rolle)	`EMR_DefaultRole_V2`	Ermöglicht Amazon EMR das Aufrufen anderer AWS-Services in Ihrem Namen, wenn Ressourcen bereitgestellt und Aktionen auf Serviceebene durchgeführt werden. Diese Rolle ist für alle Cluster erforderlich.	`AmazonEMRServicePolicy_v2` **Important** Zum Anfordern von Spot Instances ist eine serviceverknüpfte Rolle erforderlich. Wenn diese Rolle nicht vorhanden ist, benötigt die Amazon-EMR-Servicerolle die Berechtigung, sie zu

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
			erstellen, andernfalls tritt ein Berechtigungsfehler auf. Wenn Sie Spot Instances anfordern möchten, müssen Sie diese Richtlinie so aktualisieren, dass sie eine Erklärung enthält, die die Erstellung dieser serviceverknüpften Rolle ermöglicht. Weitere Informationen finden Sie unter Servicerolle für Amazon EMR (EMR-Rolle) und Serviceverknüpfte Rollen für Spot Instance-

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
			Anfragen im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil)	`EMR_EC2_DefaultRole`	Anwendungsprozesse, die auf dem Hadoop-Ökosystem auf Cluster-Instances ausgeführt werden, verwenden diese Rolle, wenn sie andere AWS-Services aufrufen. Für den Zugriff auf Daten in Amazon S3 mithilfe von EMRFS können Sie unterschiedliche Rollen angeben, die abhängig vom Speicherort der Daten in Amazon S3 angenommen werden sollen. Beispielsweise können mehrere Teams auf ein einzelnes „Datenspeicherkonto“ von Amazon S3 zugreifen. Weitere Informationen finden Sie unter Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3. Diese Rolle ist für alle Cluster erforderlich.	`AmazonElasticMapReduceforEC2Role`. Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
Servicerolle für Auto Scaling in Amazon EMR (Auto Scaling-Rolle)	`EMR_AutoScaling_DefaultRole`	Ermöglicht zusätzliche Aktionen für dynamisch skalierte Umgebungen. Nur erforderlich für Cluster mit Auto Scaling in Amazon EMR. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .	`AmazonElasticMapReduceforAutoScalingRole` . Weitere Informationen finden Sie unter Servicerolle für Auto Scaling in Amazon EMR (Auto Scaling-Rolle).

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
Servicerolle für EMR Notebooks	`EMR_Notebooks_DefaultRole`	Gewährt Berechtigungen, die ein EMR Notebook für den Zugriff auf andere AWS-Ressourcen benötigt und um Aktionen auszuführen. Nur erforderlich, wenn EMR-Notebooks verwendet werden.	`AmazonElasticMapReduceEditorsRole` . Weitere Informationen finden Sie unter Servicerolle für EMR Notebooks. `S3FullAccessPolicy` wird auch standardmäßig angehängt. Im Folgenden finden Sie den Inhalt dieser Richtlinie.. `{ "Version": "2012-10-17", "Statement": [ { "Effect": "Allow", "Action": "s3:*", "Resource": "*" } ] }`

Funktion	Standardrolle	Beschreibung	Verwaltete Standardrichtlinie
Serviceverknüpfte Rolle	`AWSServiceRoleForEMRCleanup`	Amazon EMR erstellt automatisch eine serviceverknüpfte Rolle. Wenn der Service für Amazon EMR keine Amazon EC2 Ressourcen mehr bereinigen kann, kann Amazon EMR diese Rolle zum Bereinigen verwenden. Wenn ein Cluster Spot-Instances verwendet, muss die Berechtigungsrichtlinie, die der Servicerolle für Amazon EMR (EMR-Rolle) angefügt ist, die Erstellung einer serviceverknüpften Rolle zulassen. Weitere Informationen finden Sie unter Serviceverknüpfte Rollenberechtigungen für Amazon EMR.	`AmazonEMRCleanupPolicy`

Themen

- Von Amazon EMR verwendete IAM-Servicerollen
- IAM-Rollen anpassen
- Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3

- Ressourcenbasierte Richtlinien für den Zugriff von Amazon EMR auf AWS Glue Data Catalog verwenden
- IAM-Rollen mit Anwendungen verwenden, die AWS-Services direkt aufrufen
- Benutzern und Gruppen gestatten, Rollen zu erstellen und zu ändern

Von Amazon EMR verwendete IAM-Servicerollen

Amazon EMR verwendet IAM-Servicerollen, um in Ihrem Namen Aktionen bei der Bereitstellung von Cluster-Ressourcen, der Ausführung von Anwendungen, der dynamischen Skalierung von Ressourcen und der Erstellung und Ausführung von EMR Notebooks durchzuführen. Amazon EMR verwendet in Interaktionen mit anderen AWS-Services die folgenden Rollen. Jede Rolle verfügt über eine eindeutige Funktion innerhalb von Amazon EMR. Die Themen in diesem Abschnitt beschreiben die Rollenfunktion und stellen die Standardrollen und die Berechtigungsrichtlinie für jede Rolle bereit.

Ist ein Anwendungscode auf Ihrem Cluster vorhanden, der die AWS-Services direkt aufruft, müssen Sie möglicherweise das SDK verwenden, um Rollen anzugeben. Weitere Informationen finden Sie unter IAM-Rollen mit Anwendungen verwenden, die AWS-Services direkt aufrufen.

Themen

- Servicerolle für Amazon EMR (EMR-Rolle)
- Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil)
- Servicerolle für Auto Scaling in Amazon EMR (Auto Scaling-Rolle)
- Servicerolle für EMR Notebooks
- Serviceverknüpften Rollen für Amazon EMR verwenden

Servicerolle für Amazon EMR (EMR-Rolle)

Die Amazon-EMR-Rolle definiert die zulässigen Aktionen für Amazon EMR bei der Bereitstellung von Ressourcen und der Ausführung von Service-Level-Aufgaben, die nicht im Kontext einer EC2-Instance innerhalb eines Clusters ausgeführt werden. Die Servicerolle wird beispielsweise verwendet, um EC2-Instances bereitzustellen, wenn ein Cluster gestartet wird.

- Der Standardrollenname ist `EMR_DefaultRole_V2`.
- Die Amazon EMR angefügte standardmäßige verwaltete Richtlinie `EMR_DefaultRole_V2` ist `AmazonEMRServicePolicy_v2`. Diese v2-Richtlinie ersetzt die veraltete verwaltete Standardrichtlinie `AmazonElasticMapReduceRole`.

`AmazonEMRServicePolicy_v2` hängt vom begrenzten Zugriff auf Ressourcen ab, die Amazon EMR bereitstellt oder nutzt. Wenn Sie diese Richtlinie verwenden, müssen Sie bei der Bereitstellung des Clusters das Benutzer-Tag `for-use-with-amazon-emr-managed-policies = true` übergeben. Amazon EMR verbreitet diese Tags automatisch. Darüber hinaus müssen Sie möglicherweise manuell ein Benutzer-Tag zu bestimmten Ressourcentypen hinzufügen, z. B. EC2-Sicherheitsgruppen, die nicht von Amazon EMR erstellt wurden. Siehe Taggen von Ressourcen zur Verwendung verwalteter Richtlinien.

> **Important**
>
> Amazon EMR verwendet diese Amazon EMR-Servicerolle und die `AWSServiceRoleForEMRCleanup` Rolle, um Clusterressourcen in Ihrem Konto zu bereinigen, die Sie nicht mehr verwenden, z. B. Amazon-EC2-Instances. Sie müssen Aktionen für die Rollenrichtlinien angeben, um die Ressourcen zu löschen oder zu beenden. Andernfalls kann Amazon EMR diese Bereinigungsaktionen nicht durchführen, und es können Kosten für ungenutzte Ressourcen anfallen, die im Cluster verbleiben.

Im Folgenden werden die Inhalte aktuellen Richtlinie `AmazonEMRServicePolicy_v2` angezeigt. Sie können den aktuellen Inhalt der `AmazonEMRServicePolicy_v2` verwalteten Richtlinie auch auf der IAM-Konsole sehen.

```
{
 "Version": "2012-10-17",
 "Statement": [
  {
   "Sid": "CreateInTaggedNetwork",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateNetworkInterface",
    "ec2:RunInstances",
    "ec2:CreateFleet",
    "ec2:CreateLaunchTemplate",
    "ec2:CreateLaunchTemplateVersion"
   ],
   "Resource": [
    "arn:aws:ec2:*:*:subnet/*",
    "arn:aws:ec2:*:*:security-group/*"
   ],
   "Condition": {
```

```
    "StringEquals": {
     "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "CreateWithEMRTaggedLaunchTemplate",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateFleet",
    "ec2:RunInstances",
    "ec2:CreateLaunchTemplateVersion"
   ],
   "Resource": "arn:aws:ec2:*:*:launch-template/*",
   "Condition": {
    "StringEquals": {
     "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "CreateEMRTaggedLaunchTemplate",
   "Effect": "Allow",
   "Action": "ec2:CreateLaunchTemplate",
   "Resource": "arn:aws:ec2:*:*:launch-template/*",
   "Condition": {
    "StringEquals": {
     "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "CreateEMRTaggedInstancesAndVolumes",
   "Effect": "Allow",
   "Action": [
    "ec2:RunInstances",
    "ec2:CreateFleet"
   ],
   "Resource": [
    "arn:aws:ec2:*:*:instance/*",
    "arn:aws:ec2:*:*:volume/*"
   ],
   "Condition": {
    "StringEquals": {
```

```
      "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
     }
    }
   },
   {
    "Sid": "ResourcesToLaunchEC2",
    "Effect": "Allow",
    "Action": [
     "ec2:RunInstances",
     "ec2:CreateFleet",
     "ec2:CreateLaunchTemplate",
     "ec2:CreateLaunchTemplateVersion"
    ],
    "Resource": [
     "arn:aws:ec2:*:*:network-interface/*",
     "arn:aws:ec2:*::image/ami-*",
     "arn:aws:ec2:*:*:key-pair/*",
     "arn:aws:ec2:*:*:capacity-reservation/*",
     "arn:aws:ec2:*:*:placement-group/pg-*",
     "arn:aws:ec2:*:*:fleet/*",
     "arn:aws:ec2:*:*:dedicated-host/*",
     "arn:aws:resource-groups:*:*:group/*"
    ]
   },
   {
    "Sid": "ManageEMRTaggedResources",
    "Effect": "Allow",
    "Action": [
     "ec2:CreateLaunchTemplateVersion",
     "ec2:DeleteLaunchTemplate",
     "ec2:DeleteNetworkInterface",
     "ec2:ModifyInstanceAttribute",
     "ec2:TerminateInstances"
    ],
    "Resource": "*",
    "Condition": {
     "StringEquals": {
      "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
     }
    }
   },
   {
    "Sid": "ManageTagsOnEMRTaggedResources",
    "Effect": "Allow",
```

```
    "Action": [
     "ec2:CreateTags",
     "ec2:DeleteTags"
    ],
    "Resource": [
     "arn:aws:ec2:*:*:instance/*",
     "arn:aws:ec2:*:*:volume/*",
     "arn:aws:ec2:*:*:network-interface/*",
     "arn:aws:ec2:*:*:launch-template/*"
    ],
    "Condition": {
     "StringEquals": {
      "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
     }
    }
   },
   {
    "Sid": "CreateNetworkInterfaceNeededForPrivateSubnet",
    "Effect": "Allow",
    "Action": [
     "ec2:CreateNetworkInterface"
    ],
    "Resource": [
     "arn:aws:ec2:*:*:network-interface/*"
    ],
    "Condition": {
     "StringEquals": {
      "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
     }
    }
   },
   {
    "Sid": "TagOnCreateTaggedEMRResources",
    "Effect": "Allow",
    "Action": [
     "ec2:CreateTags"
    ],
    "Resource": [
     "arn:aws:ec2:*:*:network-interface/*",
     "arn:aws:ec2:*:*:instance/*",
     "arn:aws:ec2:*:*:volume/*",
     "arn:aws:ec2:*:*:launch-template/*"
    ],
    "Condition": {
```

```
    "StringEquals": {
     "ec2:CreateAction": [
      "RunInstances",
      "CreateFleet",
      "CreateLaunchTemplate",
      "CreateNetworkInterface"
     ]
    }
   }
  },
  {
   "Sid": "TagPlacementGroups",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateTags",
    "ec2:DeleteTags"
   ],
   "Resource": [
    "arn:aws:ec2:*:*:placement-group/pg-*"
   ]
  },
  {
   "Sid": "ListActionsForEC2Resources",
   "Effect": "Allow",
   "Action": [
    "ec2:DescribeAccountAttributes",
    "ec2:DescribeCapacityReservations",
    "ec2:DescribeDhcpOptions",
    "ec2:DescribeImages",
    "ec2:DescribeInstances",
    "ec2:DescribeLaunchTemplates",
    "ec2:DescribeNetworkAcls",
    "ec2:DescribeNetworkInterfaces",
    "ec2:DescribePlacementGroups",
    "ec2:DescribeRouteTables",
    "ec2:DescribeSecurityGroups",
    "ec2:DescribeSubnets",
    "ec2:DescribeVolumes",
    "ec2:DescribeVolumeStatus",
    "ec2:DescribeVpcAttribute",
    "ec2:DescribeVpcEndpoints",
    "ec2:DescribeVpcs"
   ],
   "Resource": "*"
```

```
  },
  {
   "Sid": "CreateDefaultSecurityGroupWithEMRTags",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateSecurityGroup"
   ],
   "Resource": [
    "arn:aws:ec2:*:*:security-group/*"
   ],
   "Condition": {
    "StringEquals": {
     "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "CreateDefaultSecurityGroupInVPCWithEMRTags",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateSecurityGroup"
   ],
   "Resource": [
    "arn:aws:ec2:*:*:vpc/*"
   ],
   "Condition": {
    "StringEquals": {
     "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "TagOnCreateDefaultSecurityGroupWithEMRTags",
   "Effect": "Allow",
   "Action": [
    "ec2:CreateTags"
   ],
   "Resource": "arn:aws:ec2:*:*:security-group/*",
   "Condition": {
    "StringEquals": {
     "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true",
     "ec2:CreateAction": "CreateSecurityGroup"
    }
   }
```

```
  },
  {
   "Sid": "ManageSecurityGroups",
   "Effect": "Allow",
   "Action": [
    "ec2:AuthorizeSecurityGroupEgress",
    "ec2:AuthorizeSecurityGroupIngress",
    "ec2:RevokeSecurityGroupEgress",
    "ec2:RevokeSecurityGroupIngress"
   ],
   "Resource": "*",
   "Condition": {
    "StringEquals": {
     "aws:ResourceTag/for-use-with-amazon-emr-managed-policies": "true"
    }
   }
  },
  {
   "Sid": "CreateEMRPlacementGroups",
   "Effect": "Allow",
   "Action": [
    "ec2:CreatePlacementGroup"
   ],
   "Resource": "arn:aws:ec2:*:*:placement-group/pg-*"
  },
  {
   "Sid": "DeletePlacementGroups",
   "Effect": "Allow",
   "Action": [
    "ec2:DeletePlacementGroup"
   ],
   "Resource": "*"
  },
  {
   "Sid": "AutoScaling",
   "Effect": "Allow",
   "Action": [
    "application-autoscaling:DeleteScalingPolicy",
    "application-autoscaling:DeregisterScalableTarget",
    "application-autoscaling:DescribeScalableTargets",
    "application-autoscaling:DescribeScalingPolicies",
    "application-autoscaling:PutScalingPolicy",
    "application-autoscaling:RegisterScalableTarget"
   ],
```

```
    "Resource": "*"
   },
   {
    "Sid": "ResourceGroupsForCapacityReservations",
    "Effect": "Allow",
    "Action": [
     "resource-groups:ListGroupResources"
    ],
    "Resource": "*"
   },
   {
    "Sid": "AutoScalingCloudWatch",
    "Effect": "Allow",
    "Action": [
     "cloudwatch:PutMetricAlarm",
     "cloudwatch:DeleteAlarms",
     "cloudwatch:DescribeAlarms"
    ],
    "Resource": "arn:aws:cloudwatch:*:*:alarm:*_EMR_Auto_Scaling"
   },
   {
    "Sid": "PassRoleForAutoScaling",
    "Effect": "Allow",
    "Action": "iam:PassRole",
    "Resource": "arn:aws:iam::*:role/EMR_AutoScaling_DefaultRole",
    "Condition": {
     "StringLike": {
      "iam:PassedToService": "application-autoscaling.amazonaws.com*"
     }
    }
   },
   {
    "Sid": "PassRoleForEC2",
    "Effect": "Allow",
    "Action": "iam:PassRole",
    "Resource": "arn:aws:iam::*:role/EMR_EC2_DefaultRole",
    "Condition": {
     "StringLike": {
      "iam:PassedToService": "ec2.amazonaws.com*"
     }
    }
   }
  ]
```

```
}
```

Ihre Servicerolle sollte die folgende Vertrauensrichtlinie verwenden.

> **Important**
>
> Die folgende Vertrauensrichtlinie umfasst die globalen Bedingungsschlüssel `aws:SourceArn` und `aws:SourceAccount`, die die Berechtigungen einschränken, die Sie Amazon EMR auf bestimmte Ressourcen in Ihrem Konto erteilen. Auf diese Weise können Sie sich vor dem Problem des verwirrten Stellvertreters schützen.

```
{
    "Version": "2008-10-17",
    "Statement": [
        {
            "Sid": "",
            "Effect": "Allow",
            "Principal": {
                "Service": "elasticmapreduce.amazonaws.com"
            },
            "Action": "sts:AssumeRole",
            "Condition": {
                "StringEquals": {
                    "aws:SourceAccount": "<account-id>"
                },
                "ArnLike": {
                    "aws:SourceArn": "arn:aws:elasticmapreduce:<region>:<account-id>:*"
                }
            }
        }
    ]
}
```

Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil)

Die Servicerolle für EC2-Instance-Cluster (auch als EC2-Instance-Profil für Amazon EMR bezeichnet) ist eine spezielle Art von Servicerolle, die jeder EC2-Instance in einem Amazon-EMR-Cluster zugewiesen wird, wenn die Instance startet. Anwendungsprozesse, die auf der Hadoop-Ökosystem ausgeführt werden, übernehmen diese Rolle für Berechtigungen für die Interaktion mit anderen AWS-Services.

Weitere Informationen zu Servicerollen für EC2-Instances finden Sie unter Verwenden einer IAM-Rolle zum Erteilen von Berechtigungen für Anwendungen, die auf Amazon-EC2-Instances ausgeführt werden im IAM-Benutzerhandbuch.

> **Important**
>
> Die Standard-Servicerolle für Cluster-EC2-Instances und die zugehörige verwaltete AWS-Standardrichtlinie `AmazonElasticMapReduceforEC2Role` sind inzwischen veraltet und es stehen keine neuen AWS-verwalteten Richtlinien zur Verfügung. Sie müssen ein Instance-Profil erstellen und angeben, um die veraltete Rolle und die Standardrichtlinie zu ersetzen.

Standardrolle und verwaltete Richtlinie

- Der Standardrollenname ist `EMR_EC2_DefaultRole`.
- Die `EMR_EC2_DefaultRole` standardmäßige verwaltete Richtlinie,`AmazonElasticMapReduceforEC2Role`, nähert sich dem Ende des Supports. Anstatt eine verwaltete Standardrichtlinie für das EC2-Instance-Profil zu verwenden, wenden Sie ressourcenbasierte Richtlinien auf S3-Buckets und andere Ressourcen an, die Amazon EMR benötigt, oder verwenden Sie Ihre eigene, vom Kunden verwaltete Richtlinie mit einer IAM-Rolle als Instance-Profil. Weitere Informationen finden Sie unter Erstellen einer Servicerolle für EC2-Cluster-Instances mit Berechtigungen mit geringsten Rechten.

Im Folgenden werden die Inhalte von Version 3 von `AmazonElasticMapReduceforEC2Role` gezeigt.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Resource": "*",
            "Action": [
                "cloudwatch:*",
                "dynamodb:*",
                "ec2:Describe*",
                "elasticmapreduce:Describe*",
                "elasticmapreduce:ListBootstrapActions",
                "elasticmapreduce:ListClusters",
```

```
                "elasticmapreduce:ListInstanceGroups",
                "elasticmapreduce:ListInstances",
                "elasticmapreduce:ListSteps",
                "kinesis:CreateStream",
                "kinesis:DeleteStream",
                "kinesis:DescribeStream",
                "kinesis:GetRecords",
                "kinesis:GetShardIterator",
                "kinesis:MergeShards",
                "kinesis:PutRecord",
                "kinesis:SplitShard",
                "rds:Describe*",
                "s3:*",
                "sdb:*",
                "sns:*",
                "sqs:*",
                "glue:CreateDatabase",
                "glue:UpdateDatabase",
                "glue:DeleteDatabase",
                "glue:GetDatabase",
                "glue:GetDatabases",
                "glue:CreateTable",
                "glue:UpdateTable",
                "glue:DeleteTable",
                "glue:GetTable",
                "glue:GetTables",
                "glue:GetTableVersions",
                "glue:CreatePartition",
                "glue:BatchCreatePartition",
                "glue:UpdatePartition",
                "glue:DeletePartition",
                "glue:BatchDeletePartition",
                "glue:GetPartition",
                "glue:GetPartitions",
                "glue:BatchGetPartition",
                "glue:CreateUserDefinedFunction",
                "glue:UpdateUserDefinedFunction",
                "glue:DeleteUserDefinedFunction",
                "glue:GetUserDefinedFunction",
                "glue:GetUserDefinedFunctions"
            ]
        }
    ]
```

```
}
```

Ihre Servicerolle sollte die folgende Vertrauensrichtlinie verwenden.

```
{
    "Version": "2008-10-17",
    "Statement": [
        {
            "Sid": "",
            "Effect": "Allow",
            "Principal": {
                "Service": "ec2.amazonaws.com"
            },
            "Action": "sts:AssumeRole"
        }
    ]
}
```

Erstellen einer Servicerolle für EC2-Cluster-Instances mit Berechtigungen mit geringsten Rechten

Als bewährte Methode empfehlen wir dringend, dass Sie eine Servicerolle für Cluster-EC2-Instances und eine Berechtigungsrichtlinie erstellen, die über die Mindestberechtigungen für andere AWS-Services verfügt, die für Ihre Anwendung erforderlich sind.

Die standardmäßige verwaltete Richtlinie, `AmazonElasticMapReduceforEC2Role`, bietet Berechtigungen, mit denen Sie problemlos einen ersten Cluster starten können. `AmazonElasticMapReduceforEC2Role` ist jedoch auf dem Weg, veraltet zu werden, und Amazon EMR wird keine Ersatz-AWS-verwaltete Standardrichtlinie für die veraltete Rolle bereitstellen. Um einen ersten Cluster zu starten, müssen Sie eine vom Kunden verwaltete, ressourcenbasierte oder ID-basierte Richtlinie bereitstellen.

Die Richtlinienanweisungen unten zeigen Beispiele für die für verschiedene Features von Amazon EMR erforderlichen Berechtigungen. Wir empfehlen, diese Berechtigungen zu verwenden, um eine Berechtigungsrichtlinie zu erstellen, die den Zugriff auf nur diese Funktionen und Ressourcen beschränkt, die Ihr Cluster erfordert. Alle Beispielrichtlinienanweisungen verwenden die Region *`us-west-2`* und die fiktive AWS-Konto-ID *`123456789012`*. Ersetzen Sie diese je nach Bedarf für Ihren Cluster.

Weitere Informationen zum Erstellen und Angeben benutzerdefinierter Rollen finden Sie unter IAM-Rollen anpassen.

> **Note**
>
> Wenn Sie eine benutzerdefinierte EMR-Rolle für EC2 erstellen, folgen Sie dem grundlegenden Workflow, der automatisch ein Instance-Profil mit demselben Namen erstellt. Amazon EC2 ermöglicht es Ihnen, Instance-Profile und Rollen mit unterschiedlichen Namen zu erstellen, aber Amazon EMR unterstützt diese Konfiguration nicht und führt zu einem Fehler „Ungültiges Instance-Profil“, wenn Sie den Cluster erstellen.

Lesen und Schreiben von Daten in Amazon S3 mithilfe von EMRFS

Wenn eine Anwendung, die auf einem Amazon-EMR-Cluster ausgeführt wird, auf Daten mithilfe des `s3://mydata`-Formats verweist, wird Amazon EMR von EC2-Instance-Profilen verwendet, um die Anforderung zu stellen. Cluster lesen und schreiben in der Regel Daten auf diese Weise in Amazon S3 und EMRFS verwendet die Amazon-EMR-Berechtigungen, die standardmäßig an die Servicerolle für EC2 Instances angefügt sind. Weitere Informationen finden Sie unter Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3.

Da IAM-Rollen für EMRFS auf die Berechtigungen zurückgreifen, die der Servicerolle für Cluster-EC2-Instances zugeordnet sind, empfehlen wir als bewährte Methode, IAM-Rollen für EMRFS zu verwenden und die EMRFS- und Amazon-S3-Berechtigungen, die der Servicerolle zugeordnet sind, für Cluster-EC2-Instances einzuschränken.

Die Beispielanweisung unten zeigt die Berechtigungen, die erforderlich sind, damit EMRFS Anforderungen an Amazon S3 senden kann.

- *`my-data-bucket-in-s3-for-emrfs-reads-and-writes`* spezifiziert den Bucket in Amazon S3, mit den der Cluster Daten liest und schreibt, sowie alle Unterordner mit */**. Fügen Sie nur die Buckets und Ordner hinzu, die Ihre Anwendung benötigt.
- Die Richtlinienerklärung, die dynamodb-Aktionen zulässt, ist nur erforderlich, wenn die konsistente EMRFS-Ansicht aktiviert ist. *`EmrFSMetadata`* gibt den Standardordner für die konsistente EMRFS-Ansicht an.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
```

```
            "Action": [
                "s3:AbortMultipartUpload",
                "s3:CreateBucket",
                "s3:DeleteObject",
                "s3:GetBucketVersioning",
                "s3:GetObject",
                "s3:GetObjectTagging",
                "s3:GetObjectVersion",
                "s3:ListBucket",
                "s3:ListBucketMultipartUploads",
                "s3:ListBucketVersions",
                "s3:ListMultipartUploadParts",
                "s3:PutBucketVersioning",
                "s3:PutObject",
                "s3:PutObjectTagging"
            ],
            "Resource": [
                "arn:aws:s3:::my-data-bucket-in-s3-for-emrfs-reads-and-writes",
                "arn:aws:s3:::my-data-bucket-in-s3-for-emrfs-reads-and-writes/*"
            ]
        },
        {
            "Effect": "Allow",
            "Action": [
                "dynamodb:CreateTable",
                "dynamodb:BatchGetItem",
                "dynamodb:BatchWriteItem",
                "dynamodb:PutItem",
                "dynamodb:DescribeTable",
                "dynamodb:DeleteItem",
                "dynamodb:GetItem",
                "dynamodb:Scan",
                "dynamodb:Query",
                "dynamodb:UpdateItem",
                "dynamodb:DeleteTable",
                "dynamodb:UpdateTable"
            ],
            "Resource": "arn:aws:dynamodb:us-west-2:123456789012:table/EmrFSMetadata"
        },
        {
            "Effect": "Allow",
            "Action": [
                "cloudwatch:PutMetricData",
                "dynamodb:ListTables",
```

```
                "s3:ListBucket"
            ],
            "Resource": "*"
        },
        {
            "Effect": "Allow",
            "Action": [
                "sqs:GetQueueUrl",
                "sqs:ReceiveMessage",
                "sqs:DeleteQueue",
                "sqs:SendMessage",
                "sqs:CreateQueue"
            ],
            "Resource": "arn:aws:sqs:us-west-2:123456789012:EMRFS-Inconsistency-*"
        }
    ]
}
```

Archivieren von Protokolldateien in Amazon S3

Die folgende Richtlinienanweisung ermöglicht dem Amazon-EMR-Cluster die Archivierung von Protokolldateien in dem angegebenen Amazon-S3-Speicherort. Im folgenden Beispiel wurde *s3://MyLoggingBucket/MyEMRClusterLogs* beim Erstellen des Clusters mithilfe des S3-Speicherorts des Protokollordners in der Konsole, mithilfe der `--log-uri`-Option von AWS CLI oder mithilfe des `LogUri`-Parameters im Befehl `RunJobFlow` angegeben. Weitere Informationen finden Sie unter Archivieren von Protokolldateien in Amazon S3.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": "s3:PutObject",
            "Resource": "arn:aws:s3:::MyLoggingBucket/MyEMRClusterLogs/*"
        }
    ]
}
```

Verwenden des Debugging-Tools

Die folgende Richtlinienanweisung ermöglicht Aktionen, die erforderlich sind, wenn Sie das Amazon-EMR-Debugging-Tool aktivieren. Das Archivieren von Protokolldateien in Amazon S3 und die zugehörigen, im obigen Beispiel gezeigten Berechtigungen sind für das Debugging erforderlich. Weitere Informationen finden Sie unter Das Debugging-Tool aktivieren.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "sqs:GetQueueUrl",
                "sqs:SendMessage"
            ],
            "Resource": "arn:aws:sqs:us-west-2:123456789012:AWS-ElasticMapReduce-*"
        }
    ]
}
```

Verwenden von AWS Glue Data Catalog

Die folgende Richtlinienanweisung ermöglicht Aktionen, die erforderlich sind, wenn Sie die AWS Glue Data Catalog als Metastore für Anwendungen verwenden. Weitere Informationen finden Sie unter Verwenden von AWS Glue Data Catalog als Metastore für Spark SQL, Verwenden von AWS Glue Data Catalog als Metastore für Hive und Verwenden von Presto mit AWS Glue Data Catalog im Amazon-EMR-Versionshandbuch.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:CreateDatabase",
                "glue:UpdateDatabase",
                "glue:DeleteDatabase",
                "glue:GetDatabase",
                "glue:GetDatabases",
                "glue:CreateTable",
                "glue:UpdateTable",
```

```
                "glue:DeleteTable",
                "glue:GetTable",
                "glue:GetTables",
                "glue:GetTableVersions",
                "glue:CreatePartition",
                "glue:BatchCreatePartition",
                "glue:UpdatePartition",
                "glue:DeletePartition",
                "glue:BatchDeletePartition",
                "glue:GetPartition",
                "glue:GetPartitions",
                "glue:BatchGetPartition",
                "glue:CreateUserDefinedFunction",
                "glue:UpdateUserDefinedFunction",
                "glue:DeleteUserDefinedFunction",
                "glue:GetUserDefinedFunction",
                "glue:GetUserDefinedFunctions"
            ],
            "Resource": "*",
        }
    ]
}
```

Servicerolle für Auto Scaling in Amazon EMR (Auto Scaling-Rolle)

Die Auto-Scaling-Rolle für Amazon EMR führt eine ähnliche Funktion aus wie die Servicerolle, ermöglicht aber zusätzliche Aktionen für dynamisch skalierte Umgebungen.

- Der Standardrollenname ist `EMR_AutoScaling_DefaultRole`.
- Die an `EMR_AutoScaling_DefaultRole` angefügte standardmäßige verwaltete Richtlinie ist `AmazonElasticMapReduceforAutoScalingRole`.

Der Inhalt von Version 1 `AmazonElasticMapReduceforAutoScalingRole` wird unten angezeigt.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "cloudwatch:DescribeAlarms",
                "elasticmapreduce:ListInstanceGroups",
                "elasticmapreduce:ModifyInstanceGroups"
```

```
            ],
            "Effect": "Allow",
            "Resource": "*"
        }
    ]
}
```

Ihre Servicerolle sollte die folgende Vertrauensrichtlinie verwenden.

> **Important**
>
> Die folgende Vertrauensrichtlinie umfasst die globalen Bedingungsschlüssel `aws:SourceArn` und `aws:SourceAccount`, die die Berechtigungen einschränken, die Sie Amazon EMR auf bestimmte Ressourcen in Ihrem Konto erteilen. Auf diese Weise können Sie sich vor dem Problem des verwirrten Stellvertreters schützen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Principal": {
                "Service":  [
                    "elasticmapreduce.amazonaws.com",
                    "application-autoscaling.amazonaws.com"
                ]
            },
            "Action": "sts:AssumeRole",
            "Condition": {
                "StringEquals": {
                    "aws:SourceAccount": "<account-id>"
                },
                "ArnLike": {
                    "aws:SourceArn": "arn:aws:elasticmapreduce:<region>:<account-id>:*"
                }
            }
        }
    ]
}
```

Servicerolle für EMR Notebooks

Jedes EMR Notebook benötigt Berechtigungen, um auf andere AWS-Ressourcen zuzugreifen und Aktionen auszuführen. Die der Servicerolle zugeordneten IAM-Richtlinien bieten Berechtigungen für den Cluster, damit er mit anderen AWS-Services zusammenarbeiten kann. Wenn Sie ein Notebook mithilfe der AWS Management Console erstellen, geben Sie eine AWS-Servicerolle an. Sie können die Standardrolle, `EMR_Notebooks_DefaultRole`, verwenden oder eine Rolle angeben, die Sie erstellen. Wenn ein Notebook nicht vorher erstellt wurde, haben Sie die Möglichkeit, die Standardrolle zu erstellen.

- Der Standardrollenname ist `EMR_Notebooks_DefaultRole`.
- Die standardmäßig angehängten verwalteten Richtlinien zu `EMR_Notebooks_DefaultRole` sind `AmazonElasticMapReduceEditorsRole` und `S3FullAccessPolicy`.

Ihre Servicerolle sollte die folgende Vertrauensrichtlinie verwenden.

> **Important**
>
> Die folgende Vertrauensrichtlinie umfasst die globalen Bedingungsschlüssel `aws:SourceArn` und `aws:SourceAccount`, die die Berechtigungen einschränken, die Sie Amazon EMR auf bestimmte Ressourcen in Ihrem Konto erteilen. Auf diese Weise können Sie sich vor dem Problem des verwirrten Stellvertreters schützen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Principal": {
                "Service": "elasticmapreduce.amazonaws.com"
            },
            "Action": "sts:AssumeRole",
            "Condition": {
                "StringEquals": {
                    "aws:SourceAccount": "<account-id>"
                },
                "ArnLike": {
                    "aws:SourceArn": "arn:aws:elasticmapreduce:<region>:<account-id>:*"
```

```
                }
            }
        }
    ]
}
```

Der Inhalt von Version 1 von `AmazonElasticMapReduceEditorsRole` lautet wie folgt.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "ec2:AuthorizeSecurityGroupEgress",
                "ec2:AuthorizeSecurityGroupIngress",
                "ec2:CreateSecurityGroup",
                "ec2:DescribeSecurityGroups",
                "ec2:RevokeSecurityGroupEgress",
                "ec2:CreateNetworkInterface",
                "ec2:CreateNetworkInterfacePermission",
                "ec2:DeleteNetworkInterface",
                "ec2:DeleteNetworkInterfacePermission",
                "ec2:DescribeNetworkInterfaces",
                "ec2:ModifyNetworkInterfaceAttribute",
                "ec2:DescribeTags",
                "ec2:DescribeInstances",
                "ec2:DescribeSubnets",
                "ec2:DescribeVpcs",
                "elasticmapreduce:ListInstances",
                "elasticmapreduce:DescribeCluster",
                "elasticmapreduce:ListSteps"
            ],
            "Resource": "*"
        },
        {
            "Effect": "Allow",
            "Action": "ec2:CreateTags",
            "Resource": "arn:aws:ec2:*:*:network-interface/*",
            "Condition": {
                "ForAllValues:StringEquals": {
                    "aws:TagKeys": [
                        "aws:elasticmapreduce:editor-id",
```

```
                        "aws:elasticmapreduce:job-flow-id"
                    ]
                }
            }
        }
    ]
}
```

Im Folgenden sehen Sie den Inhalt von `S3FullAccessPolicy`. `S3FullAccessPolicy` Dadurch kann Ihre Servicerolle für EMR Notebooks alle Amazon S3-Aktionen an Objekten in Ihrem AWS-Konto ausführen. Wenn Sie eine benutzerdefinierte Servicerolle für EMR Notebooks erstellen, müssen Sie Ihrer Servicerolle Amazon-S3-Berechtigungen erteilen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": "s3:*",
            "Resource": "*"
        }
    ]
}
```

Sie können den Lese- und Schreibzugriff für Ihre Servicerolle auf den Amazon-S3-Standort beschränken, an dem Sie Ihre Notebookdateien speichern möchten. Verwenden Sie die folgenden Mindestberechtigungen an Amazon S3.

```
"s3:PutObject",
"s3:GetObject",
"s3:GetEncryptionConfiguration",
"s3:ListBucket",
"s3:DeleteObject"
```

Wenn Ihr Amazon-S3-Bucket verschlüsselt ist, müssen Sie die folgenden Berechtigungen für AWS Key Management Service angeben.

```
"kms:Decrypt",
"kms:GenerateDataKey",
"kms:ReEncryptFrom",
"kms:ReEncryptTo",
```

```
"kms:DescribeKey"
```

Wenn Sie Git-Repositorys mit Ihrem Notebook verknüpfen und ein Geheimnis für das Repository erstellen müssen, müssen Sie die Berechtigung `secretsmanager:GetSecretValue` in der IAM-Richtlinie hinzufügen, die der Servicerolle für Amazon EMR Notebooks zugewiesen ist. Eine Beispielrichtlinie wird nachfolgend gezeigt:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "VisualEditor0",
            "Effect": "Allow",
            "Action": "secretsmanager:GetSecretValue",
            "Resource": "*"
        }
    ]
}
```

Berechtigungen für die Servicerolle von EMR Notebooks

In dieser Tabelle sind die Aktionen aufgeführt, die EMR Notebooks mithilfe der Servicerolle durchführt, zusammen mit den Berechtigungen, die für jede Aktion erforderlich sind.

Action	Berechtigungen

Richten Sie einen sicheren Netzwerkkanal zwischen einem Notebook und einem Amazon-EMR-Cluster ein und führen Sie die erforderlichen Bereinigungsaktionen durch.	`"ec2:CreateNetworkInterface",`
	`"ec2:CreateNetworkInterfacePermission",`
	`"ec2:DeleteNetworkInterface",`
	`"ec2:DeleteNetworkInterfacePermission",`
	`"ec2:DescribeNetworkInterfaces",`
	`"ec2:ModifyNetworkInterfaceAttribute",`
	`"ec2:AuthorizeSecurityGroupEgress",`
	`"ec2:AuthorizeSecurityGroupIngress",`
	`"ec2:CreateSecurityGroup",`
	`"ec2:DescribeSecurityGroups",`
	`"ec2:RevokeSecurityGroupEgress",`
	`"ec2:DescribeTags",`
	`"ec2:DescribeInstances",`
	`"ec2:DescribeSubnets",`
	`"ec2:DescribeVpcs",`

Action	Berechtigungen

	`"elasticmapreduce:ListInstances",`
	`"elasticmapreduce:DescribeCluster",`
	`"elasticmapreduce:ListSteps"`

Verwenden Sie die in gespeicherten Git-Anmeldeinformationen AWS Secrets Manager, um Git-Repositorys mit einem Notizbuch zu verknüpfen.	`"secretsmanager:GetSecretValue"`
Wenden Sie AWS-Tags auf die Netzwerkschnittstelle und die Standardsicherheitsgruppen an, die EMR Studio bei der Einrichtung des sicheren Netzwerkkanals erstellt. Weitere Informationen finden Sie unter Markieren von AWS-Ressourcen.	`"ec2:CreateTags"`

Greifen Sie auf Notebook-Dateien und Metadaten zu oder laden Sie sie in Amazon S3 hoch.	`"s3:PutObject",`
	`"s3:GetObject",`
	`"s3:GetEncryptionConfiguration",`
	`"s3:ListBucket",`
	`"s3:DeleteObject"`
	
	Wenn Sie einen verschlüsselten Amazon-S3-Bucket verwenden, sind die folgenden Berechtigungen erforderlich.
	
	`"kms:Decrypt",`
	`"kms:GenerateDataKey",`
	`"kms:ReEncryptFrom",`
	`"kms:ReEncryptTo",`
	`"kms:DescribeKey"`

Aktualisierungen der AWS verwalteten Richtlinien von EMR Notebooks

Details zu Aktualisierungen von AWS verwalteten Richtlinien für EMR Notebooks seit dem 1. März 2021 anzeigen.

Änderung	Beschreibung	Datum
`AmazonElasticMapReduceEditorsRole - Added permissions`	EMR Notebooks fügt `ec2:describeVPCs -` und `elastmicmapreduce: ListSteps` -Berechtigungen für `AmazonElasticMapReduceEditorsRole` hinzu.	8. Februar 2023
EMR Notebooks hat damit begonnen, Änderungen zu verfolgen	EMR Notebooks hat mit der Verfolgung von Änderungen für seine AWS-verwalteten Richtlinien begonnen.	8. Februar 2023

Serviceverknüpften Rollen für Amazon EMR verwenden

Amazon EMR verwendet AWS Identity and Access Management (IAM)-serviceverknüpfte Rollen. Eine serviceverknüpfte Rolle ist eine einzigartige Art von IAM-Rolle, die direkt mit Amazon EMR verknüpft ist. Die serviceverknüpfte Rolle wird durch Amazon EMR vordefiniert und schließt die Berechtigungen ein, die von Amazon EMR zum Aufrufen von Amazon EC2 in Ihrem Namen benötigt werden, um Cluster-Ressourcen zu bereinigen, die nicht mehr verwendet werden. Die serviceverknüpfte Rolle funktioniert in Verbindung mit der Amazon-EMR-Servicerolle und dem Amazon-EC2-Instance-Profil für Amazon EMR. Weitere Informationen über die Service-Rolle und das Instance-Profil finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.

Amazon EMR definiert die Berechtigungen dieser serviceverknüpften Rolle. Sofern keine andere Konfiguration festgelegt wurde, kann nur Amazon EMR die Rolle übernehmen. Die definierten Berechtigungen umfassen die Vertrauens- und Berechtigungsrichtlinie. Diese Berechtigungsrichtlinie kann keinen anderen IAM-Entitäten zugewiesen werden. Sie können die Rolle nur löschen, nachdem Sie alle EMR-Cluster im Konto beendet haben.

Informationen zu anderen Services, die serviceverknüpfte Rollen unterstützen, finden Sie unter AWS-Services, die mit IAM funktionieren. Suchen Sie nach den Services, für die Yes (Ja) in der Spalte Service-Linked Role (Serviceverknüpfte Rolle) angegeben ist. Wählen Sie über einen Link Ja aus, um die Dokumentation zu einer servicegebundenen Rolle für diesen Service anzuzeigen.

Serviceverknüpfte Rollenberechtigungen für Amazon EMR

Amazon EMR verwendet die Rolle AWSServiceRoleForEMRCleanup eine servicebasierte Rolle, die es Amazon EMR ermöglicht, Amazon-EC2-Ressourcen in Ihrem Namen zu beenden und zu löschen, falls die Amazon-EMR-Servicerolle diese Fähigkeit verloren hat. Amazon EMR erstellt die Rolle automatisch während der Cluster-Erstellung, sofern sie nicht bereits vorhanden ist.

Die serviceverknüpfte Rolle AWSServiceRoleForEMRCleanup vertraut darauf, dass die folgenden Services diese Rolle annehmen:

- `elasticmapreduce.amazonaws.com`

Die Rollenberechtigungsrichtlinie gestattet Amazon EMR, die folgenden Aktionen für die angegebenen Ressourcen durchzuführen:

- Aktion: `DescribeInstances` für `ec2`
- Aktion: `DescribeSpotInstanceRequests` für `ec2`
- Aktion: `ModifyInstanceAttribute` für `ec2`
- Aktion: `TerminateInstances` für `ec2`
- Aktion: `CancelSpotInstanceRequests` für `ec2`
- Aktion: `DeleteNetworkInterface` für `ec2`
- Aktion: `DescribeInstanceAttribute` für `ec2`
- Aktion: `DescribeVolumeStatus` für `ec2`
- Aktion: `DescribeVolumes` für `ec2`
- Aktion: `DetachVolume` für `ec2`
- Aktion: `DeleteVolume` für `ec2`

Sie müssen Berechtigungen konfigurieren, damit eine juristische Stelle von IAM (z. B. Benutzer, Gruppe oder Rolle) eine servicegebundene Rolle erstellen, bearbeiten oder löschen kann.

So erlauben Sie einer IAM-Entität das Erstellen der serviceverknüpften Rolle namens AWSServiceRoleForEMRCleanup service-linked

Fügen Sie die folgende Anweisung der Berechtigungsrichtlinie für die IAM-Entität hinzu, die die serviceverknüpfte Rolle erstellen soll:

```
{
    "Effect": "Allow",
    "Action": [
        "iam:CreateServiceLinkedRole",
        "iam:PutRolePolicy"
    ],
    "Resource": "arn:aws:iam::*:role/aws-service-role/elasticmapreduce.amazonaws.com*/
AWSServiceRoleForEMRCleanup*",
    "Condition": {
        "StringLike": {
            "iam:AWSServiceName": [
                "elasticmapreduce.amazonaws.com",
                "elasticmapreduce.amazonaws.com.cn"
            ]
        }
    }
}
```

So erlauben Sie einer IAM-Entität das Bearbeiten der Beschreibung für die serviceverknüpfte Rolle AWSServiceRoleForEMRCleanup

Fügen Sie die folgende Anweisung der Berechtigungsrichtlinie für die IAM-Entität hinzu, die die Beschreibung einer serviceverknüpften Rolle bearbeiten soll:

```
{
    "Effect": "Allow",
    "Action": [
        "iam:UpdateRoleDescription"
    ],
    "Resource": "arn:aws:iam::*:role/aws-service-role/elasticmapreduce.amazonaws.com*/
AWSServiceRoleForEMRCleanup*",
    "Condition": {
        "StringLike": {
            "iam:AWSServiceName": [
                "elasticmapreduce.amazonaws.com",
                "elasticmapreduce.amazonaws.com.cn"
            ]
```

```
        }
    }
}
```

So erlauben Sie einer IAM-Entität das Löschen der serviceverknüpften Rolle namens AWSServiceRoleForEMRCleanup service-linked

Fügen Sie die folgende Anweisung der Berechtigungsrichtlinie für die IAM-Entität hinzu, die eine serviceverknüpfte Rolle löschen soll:

```
{
    "Effect": "Allow",
    "Action": [
        "iam:DeleteServiceLinkedRole",
        "iam:GetServiceLinkedRoleDeletionStatus"
    ],
    "Resource": "arn:aws:iam::*:role/aws-service-role/elasticmapreduce.amazonaws.com*/
AWSServiceRoleForEMRCleanup*",
    "Condition": {
        "StringLike": {
            "iam:AWSServiceName": [
                "elasticmapreduce.amazonaws.com",
                "elasticmapreduce.amazonaws.com.cn"
            ]
        }
    }
}
```

Erstellen einer serviceverknüpften Rolle für Amazon EMR

Sie brauchen die Rolle AWSServiceRoleForEMRCleanup nicht manuell zu erstellen. Wenn Sie einen Cluster zum ersten Mal starten oder wenn keine serviceverknüpfte Rolle vorhanden ist, erstellt Amazon EMR die serviceverknüpfte Rolle für Sie. Sie müssen über -Berechtigungen zum Erstellen der serviceverknüpften Rolle verfügen. Sie finden eine Beispiel-Anweisung, die diese Funktion zur Berechtigungsrichtlinie einer IAM-Entität (z. B. Benutzer, Gruppe oder Rolle) hinzufügt, unter Serviceverknüpfte Rollenberechtigungen für Amazon EMR.

> **Important**
>
> Wenn Sie den Amazon-EMR-Service vor dem 24. Oktober 2017 verwendet haben, als dieser serviceverknüpfte Rollen unterstützt, hat Amazon EMR die

AWSServiceRoleForAmazonEKSNodegroup-Rolle in Ihrem Konto erstellt. Weitere Informationen finden Sie unter In meinem IAM-Konto wird eine neue Rolle angezeigt.

Bearbeiten einer serviceverknüpften Rolle für Amazon EMR

Amazon EMR erlaubt es Ihnen nicht, die serviceverknüpfte Rolle AWSServiceRoleForEMRCleanup zu bearbeiten. Da möglicherweise verschiedene Entitäten auf die Rolle verweisen, kann der Rollenname nach dem Erstellen einer serviceverknüpften Rolle nicht mehr geändert werden. Sie können jedoch die Beschreibung der Rolle mit IAM bearbeiten.

Bearbeiten der Beschreibung einer serviceverknüpften Rolle (IAM-Konsole)

Sie können die IAM-Konsole für das Bearbeiten der Beschreibung einer serviceverknüpften Rolle verwenden.

So bearbeiten Sie die Beschreibung einer serviceverknüpften Rolle (Konsole)

1. Wählen Sie im Navigationsbereich der IAM Console Roles (Rollen) aus.
2. Wählen Sie den Namen der zu ändernden Rolle.
3. Wählen Sie neben Rollenbeschreibung rechts Bearbeiten aus.
4. Geben Sie eine neue Beschreibung im Dialogfeld ein und wählen Sie Save changes (Änderungen speichern).

Bearbeiten der Beschreibung einer serviceverknüpften Rolle (IAM-CLI)

Sie können die IAM-Befehle der AWS Command Line Interface für das Bearbeiten der Beschreibung einer serviceverknüpften Rolle verwenden.

So ändern Sie die Beschreibung einer serviceverknüpften Rolle (CLI)

1. (Optional) Um die aktuelle Beschreibung einer Rolle anzuzeigen, verwenden Sie die folgenden Befehle:

   ```
   $ aws iam get-role --role-name role-name
   ```

   Verwenden Sie den Rollennamen, nicht den ARN, um sich auf Rollen mit den CLI-Befehlen zu beziehen. Wenn eine Rolle zum Beispiel folgenden ARN hat: `arn:aws:iam::123456789012:role/myrole`, verweisen Sie auf die Rolle als **`myrole`**.

2. Um die Beschreibung einer serviceverknüpften Rolle zu aktualisieren, verwenden Sie einen der folgenden Befehle:

```
$ aws iam update-role-description --role-name role-name --description description
```

Bearbeiten der Beschreibung einer serviceverknüpften Rolle (IAM-API)

Sie können die IAM-API für das Bearbeiten der Beschreibung einer serviceverknüpften Rolle verwenden.

So ändern Sie die Beschreibung einer serviceverknüpften Rolle (API)

1. (Optional) Um die aktuelle Beschreibung einer Rolle anzuzeigen, verwenden Sie den folgenden Befehl:

   IAM-API: GetRole
2. Um die Beschreibung einer Rolle zu aktualisieren, verwenden Sie den folgenden Befehl:

   IAM-API: UpdateRoleDescription

Löschen einer serviceverknüpften Rolle für Amazon EMR

Wenn Sie ein Feature oder einen Service, die bzw. der eine serviceverknüpften Rolle erfordert, nicht mehr benötigen, sollten Sie diese Rolle löschen. Auf diese Weise haben Sie keine ungenutzte Entität, die nicht aktiv überwacht oder verwaltet wird. Sie müssen jedoch Ihre serviceverknüpfte Rolle zunächst bereinigen, bevor Sie sie löschen können.

Bereinigen einer serviceverknüpften Rolle

Bevor Sie mit IAM eine serviceverknüpfte Rolle löschen können, müssen Sie sich zunächst vergewissern, dass die Rolle über keine aktiven Sitzungen verfügt, und alle Ressourcen entfernen, die von der Rolle verwendet werden.

So überprüfen Sie in der IAM-Konsole, ob die serviceverknüpfte Rolle über eine aktive Sitzung verfügt

1. Öffnen Sie die IAM-Konsole unter https://console.aws.amazon.com/iam/.
2. Wählen Sie im Navigationsbereich Roles (Rollen) aus. Wählen Sie dann den Namen (nicht das Kontrollkästchen) der Rolle AWSServiceRoleForEMRCleanup aus.

3. Wählen Sie auf der Seite Summary (Übersicht) für die ausgewählte Rolle die Option Access Advisor (Advisor aufrufen) aus.
4. Überprüfen Sie auf der Registerkarte Access Advisor (Advisor aufrufen) die jüngsten Aktivitäten für die serviceverknüpfte Rolle.

> **Note**
>
> Wenn Sie sich nicht sicher sind, ob Amazon EMR die Rolle AWSServiceRoleForEMRCleanup verwendet, können Sie versuchen, die Rolle zu löschen. Wenn der Service die Rolle verwendet, schlägt die Löschung fehl und Sie können die -Regionen anzeigen, in denen die Rolle verwendet wird. Wenn die Rolle verwendet wird, müssen Sie warten, bis die Sitzung beendet wird, bevor Sie die Rolle löschen können. Die Sitzung für eine serviceverknüpfte Rolle können Sie nicht widerrufen.

Zum Löschen von Amazon-EMR-Ressourcen, die von der serviceverknüpften Rolle AWSServiceRoleForEMRCleanup verwendet werden

- Beenden Sie alle Cluster in Ihrem Konto. Weitere Informationen finden Sie unter Einen Cluster beenden.

Löschen einer serviceverknüpften Rolle (IAM-Konsole)

Sie können die IAM-Konsole für das Löschen einer serviceverknüpften Rolle verwenden.

So löschen Sie eine serviceverknüpfte Rolle (Konsole)

1. Öffnen Sie die IAM-Konsole unter https://console.aws.amazon.com/iam/.
2. Wählen Sie im Navigationsbereich Roles (Rollen) aus. Wählen Sie das Kontrollkästchen (nicht den Namen oder die Zeile) neben AWSServiceRoleForEMRCleanup aus.
3. Wählen Sie für Role actions oben auf der Seite Delete role aus.
4. Überprüfen Sie im Bestätigungsdialogfeld die letzten Service-Zugriffsdaten, die zeigen, wann jede der ausgewählten Rollen zuletzt auf den AWS-Service zugegriffen hat. Auf diese Weise können Sie leichter bestätigen, ob die Rolle derzeit aktiv ist. Wählen Sie Yes, Delete, um fortzufahren.

5. Sehen Sie sich die Benachrichtigungen in der IAM-Konsole an, um den Fortschritt der Löschung der serviceverknüpften Rolle zu überwachen. Da die Löschung der serviceverknüpften IAM-Rolle asynchron erfolgt, kann die Löschung nach dem Übermitteln der Rolle für die Löschung erfolgreich sein oder fehlschlagen. Wenn der Vorgang fehlschlägt, können Sie in den Benachrichtigungen View details oder View Resources auswählen, um zu erfahren, warum die Löschung fehlgeschlagen ist. Wenn das Löschen fehlschlägt, weil der Service Ressourcen enthält, die von der Rolle verwendet werden, enthält die Angabe des Fehlergrundes eine Liste der Ressourcen.

Löschen einer serviceverknüpften Rolle (IAM-CLI)

Sie können die IAM-Befehle in der AWS Command Line Interface zum Löschen einer serviceverknüpften Rolle verwenden. Da eine serviceverknüpfte Rolle nicht gelöscht werden kann, wenn sie verwendet wird oder ihr Ressourcen zugeordnet sind, müssen Sie eine Löschungsanforderung übermitteln. Wenn diese Bedingungen nicht erfüllt sind, kann diese Anforderung verweigert werden.

So löschen Sie eine serviceverknüpfte Rolle (CLI)

1. Sie benötigen die `deletion-task-id` aus der Antwort, um den Status der Löschaufgabe zu überprüfen. Geben Sie den folgenden Befehl ein, um eine Löschanforderung für eine serviceverknüpfte Rolle zu übermitteln:

   ```
   $ aws iam delete-service-linked-role --role-name AWSServiceRoleForEMRCleanup
   ```

2. Geben Sie den folgenden Befehl ein, um den Status der Löschaufgabe zu überprüfen:

   ```
   $ aws iam get-service-linked-role-deletion-status --deletion-task-id deletion-task-id
   ```

   Der Status der Löschaufgabe kann `NOT_STARTED`, `IN_PROGRESS`, `SUCCEEDED` oder `FAILED` lauten. Wenn die Löschung fehlschlägt, gibt der Aufruf den Grund zurück, sodass Sie das Problem beheben können.

Löschen einer serviceverknüpften Rolle (IAM-API)

Sie können die IAM-API zum Löschen einer serviceverknüpften Rolle verwenden. Da eine serviceverknüpfte Rolle nicht gelöscht werden kann, wenn sie verwendet wird oder ihr Ressourcen

zugeordnet sind, müssen Sie eine Löschungsanforderung übermitteln. Wenn diese Bedingungen nicht erfüllt sind, kann diese Anforderung verweigert werden.

So löschen Sie eine serviceverknüpfte Rolle (API)

1. Um eine Löschanforderung für eine serviceverknüpfte Rolle zu übermitteln, rufen Sie DeleteServiceLinkedRole auf. Geben Sie in der Anforderung den Rollennamen AWSServiceRoleForEMRCleanup an.

   Sie benötigen die `DeletionTaskId` aus der Antwort, um den Status der Löschaufgabe zu überprüfen.
2. Rufen Sie GetServiceLinkedRoleDeletionStatus auf, um den Status der Löschung zu überprüfen. Geben Sie in der Anforderung die `DeletionTaskId` an.

   Der Status der Löschaufgabe kann `NOT_STARTED`, `IN_PROGRESS`, `SUCCEEDED` oder `FAILED` lauten. Wenn die Löschung fehlschlägt, gibt der Aufruf den Grund zurück, sodass Sie das Problem beheben können.

Unterstützte Regionen für Amazon-EMR-Service-verknüpfte Rollen

Amazon EMR unterstützt die Verwendung von serviceverknüpften Rollen in den folgenden - Regionen.

Name der Region	Regions-ID	Amazon EMR Support
USA Ost (Nord-Virginia)	us-east-1	Ja
USA Ost (Ohio)	us-east-2	Ja
USA West (Nordkalifornien)	us-west-1	Ja
USA West (Oregon)	us-west-2	Ja
Asien-Pazifik (Mumbai)	ap-south-1	Ja
Asien-Pazifik (Osaka)	ap-northeast-3	Ja
Asien-Pazifik (Seoul)	ap-northeast-2	Ja
Asien-Pazifik (Singapore)	ap-southeast-1	Ja

Name der Region	Regions-ID	Amazon EMR Support
Asien-Pazifik (Sydney)	ap-southeast-2	Ja
Asien-Pazifik (Tokyo)	ap-northeast-1	Ja
Kanada (Zentral)	ca-central-1	Ja
Europa (Frankfurt)	eu-central-1	Ja
Europa (Ireland)	eu-west-1	Ja
Europa (London)	eu-west-2	Ja
Europa (Paris)	eu-west-3	Ja
Südamerika (São Paulo)	sa-east-1	Ja

IAM-Rollen anpassen

Sie können die IAM-Servicerollen und -Berechtigungen anpassen, um Rechte entsprechend Ihren Sicherheitsanforderungen zu beschränken. Zum Anpassen von Berechtigungen empfehlen wir, dass Sie neue Rollen und Richtlinien erstellen. Beginnen Sie mit den Berechtigungen in den verwalteten Richtlinien für die Standardrollen (beispielsweise `AmazonElasticMapReduceforEC2Role` und `AmazonElasticMapReduceRole`). Kopieren Sie anschließend die Inhalte in die neuen Richtlinienanweisungen, modifizieren Sie die Berechtigungen entsprechend und fügen Sie die geänderten Richtlinien zu den von Ihnen erstellten Rollen hinzu. Sie müssen über die entsprechenden IAM-Berechtigungen für die Arbeit mit Rollen und Richtlinien verfügen. Weitere Informationen finden Sie unter Benutzern und Gruppen gestatten, Rollen zu erstellen und zu ändern.

Wenn Sie eine benutzerdefinierte EMR-Rolle für EC2 erstellen, folgen Sie dem grundlegenden Workflow, der automatisch ein Instance-Profil mit demselben Namen erstellt. Amazon EC2 ermöglicht es Ihnen, Instance-Profile und Rollen mit unterschiedlichen Namen zu erstellen, aber Amazon EMR unterstützt diese Konfiguration nicht und führt zu einem Fehler „Ungültiges Instance-Profil“, wenn Sie den Cluster erstellen.

> **Important**
>
> Eingebundene Richtlinien werden nicht automatisch aktualisiert, wenn sich Serviceanforderungen ändern. Beachten Sie beim Erstellen und Anhängen von Inline-Richtlinien, dass es zu Serviceaktualisierungen kommen kann, die plötzlich zu Berechtigungsfehlern führen. Weitere Informationen hierzu finden Sie unter Verwaltete Richtlinien und eingebundene Richtlinien im IAM-Benutzerhandbuch und Angabe benutzerdefinierter IAM-Rollen beim Erstellen eines Clusters.

Weitere Informationen über die Arbeit mit IAM-Rollen finden Sie in den folgenden Themen im IAM-Benutzerhandbuch:

- Erstellen einer Rolle zum Delegieren von Berechtigungen an einen AWS-Service
- Ändern einer Rolle
- Löschen einer Rolle

Angabe benutzerdefinierter IAM-Rollen beim Erstellen eines Clusters

Sie geben die Servicerolle für Amazon EMR und die Rolle für das Amazon-EC2-Instance-Profil an, wenn Sie einen Cluster erstellen. Der Benutzer, der Cluster erstellt, benötigt Berechtigungen, um Rollen abzurufen und sie Amazon EMR und den EC2-Instances zuzuweisen. Andernfalls tritt der Fehler Benutzerkonto ist nicht zum Aufruf von EC2 autorisiert auf. Weitere Informationen finden Sie unter Benutzern und Gruppen gestatten, Rollen zu erstellen und zu ändern.

Mit der Konsole benutzerdefinierte Rollen angeben

Beim Erstellen eines Clusters können Sie eine benutzerdefinierte Servicerolle für Amazon EMR, eine benutzerdefinierte Rolle für das EC2-Instance-Profil und eine benutzerdefinierte Auto-Scaling-Rolle in Erweiterte Optionen angeben. Wenn Sie Quick options (Schnelloptionen) verwenden, werden die Service-Standardrolle und die Standardrolle für das EC2-Instance-Profil angegeben. Weitere Informationen finden Sie unter Von Amazon EMR verwendete IAM-Servicerollen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So geben Sie benutzerdefinierte IAM-Rollen mithilfe der Konsole an

Sie geben die Servicerolle für Amazon EMR und die Rolle für das Amazon-EC2-Instance-Profil an, wenn Sie einen Cluster erstellen. Weitere Informationen finden Sie unter Von Amazon EMR verwendete IAM-Servicerollen.

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Suchen Sie unter Sicherheitskonfiguration und Berechtigungen die Felder IAM-Rolle für Instance-Profil und Servicerolle für Amazon EMR. Wählen Sie für jeden Rollentyp eine Rolle aus der Liste aus. Nur Rollen innerhalb Ihres Kontos, die die entsprechende Vertrauensstellungen für diesen Rollentyp besitzen, sind aufgeführt.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So geben Sie benutzerdefinierte IAM-Rollen mithilfe der Konsole an

Wenn Sie mit der alten Konsole einen Cluster erstellen, können Sie mithilfe der erweiterten Optionen eine benutzerdefinierte Servicerolle für Amazon EMR, eine benutzerdefinierte Rolle für das EC2-Instance-Profil und eine benutzerdefinierte Auto-Scaling-Rolle angeben. Wenn Sie Quick options (Schnelloptionen) verwenden, werden die Service-Standardrolle und die Standardrolle für das EC2-Instance-Profil angegeben. Weitere Informationen finden Sie unter Von Amazon EMR verwendete IAM-Servicerollen.

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.
3. Wählen Sie die Cluster-Einstellungen für Ihre Anwendung aus, bis Sie Security Options (Sicherheitsoptionen) erreichen. Unter Permissions sind die Default-Rollen für Amazon EMR ausgewählt.
4. Wählen Sie Custom (Benutzerdefiniert) aus.
5. Wählen Sie für jeden Rollentyp eine Rolle aus der Liste aus. Nur Rollen innerhalb Ihres Kontos, die die entsprechende Vertrauensstellungen für diesen Rollentyp besitzen, sind aufgeführt.

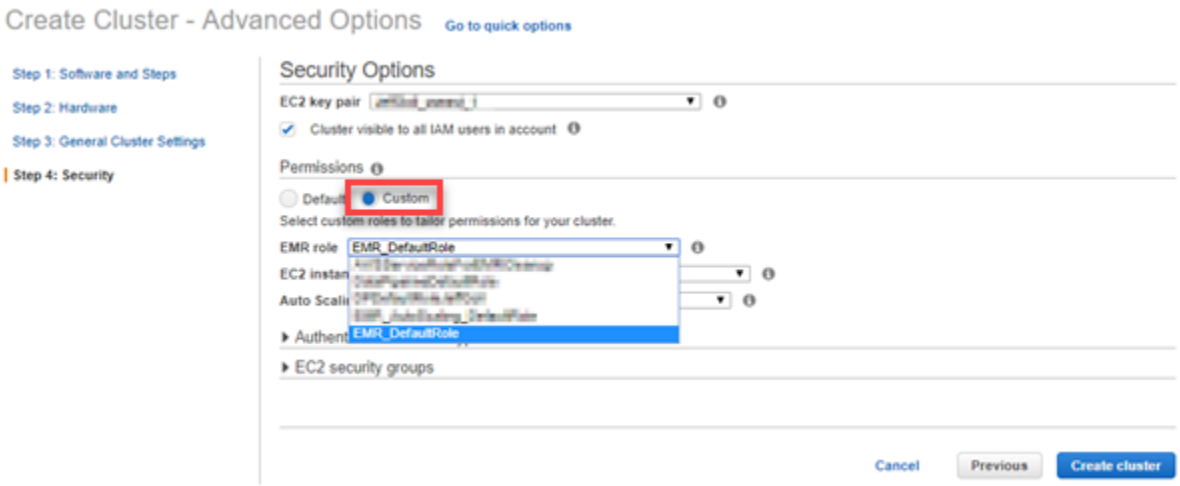

6. Wählen Sie weitere Optionen wie für Ihren Cluster erforderlich aus. Wählen Sie dann Create Cluster (Cluster erstellen) aus.

Mit der AWS CLI benutzerdefinierte Rollen angeben

Sie können eine Servicerolle für Amazon EMR und eine `create-cluster` Servicerolle für EC2 Instance Cluster explizit mithilfe von Optionen mit dem -Befehl in der AWS CLI angeben. Verwenden Sie die Option `--service-role`, um die Servicerolle anzugeben. Verwenden Sie das Argument `InstanceProfile` der Option `--ec2-attributes`, um die Rolle für das EC2-Instance-Profil anzugeben.

Die Auto Scaling-Rolle wird einer separaten Option angegeben, `--auto-scaling-role`. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .

So geben Sie benutzerdefinierte IAM-Rollen über die AWS CLI an

- Der folgende Befehl gibt die benutzerdefinierte Servicerolle an, *MyCustomServiceRoleForEMR*, und eine benutzerdefinierte Rolle für das EC2-Instance-Profil, *MyCustomServiceRoleForClusterEC2Instances*, wenn Sie einen Cluster starten. Dieses Beispiel verwendet die Amazon-EMR-Standardrolle.

  > **Note**
  >
  > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "Test cluster" --release-label emr-5.36.1 \
--applications Name=Hive Name=Pig --service-role MyCustomServiceRoleForEMR \
--ec2-attributes InstanceProfile=MyCustomServiceRoleForClusterEC2Instances,\
KeyName=myKey --instance-type m5.xlarge --instance-count 3
```

Sie können diese Optionen verwenden, um Standardrollen explizit anzugeben, statt die Option `--use-default-roles` zu verwenden. Die `--use-default-roles`-Option gibt die Servicerolle an sowie die Rolle für das EC2-Instance-Profil, das in der `config`-Datei für die AWS CLI definiert ist.

Das folgende Beispiel zeigt den Inhalt einer `config`-Datei für die AWS CLI, die benutzerdefinierten Rollen für Amazon EMR angibt. Mit dieser Konfigurationsdatei wird der Cluster, wenn die `--use-default-roles`-Option angegeben ist, mit dem *MyCustomServiceRoleForEMR* und *MyCustomServiceRoleForClusterEC2Instances* erstellt. Standardmäßig gibt die `config`-Datei die standardmäßige `service_role` als `AmazonElasticMapReduceRole` und das standardmäßige `instance_profile` als `EMR_EC2_DefaultRole` an.

```
[default]
output = json
region = us-west-1
aws_access_key_id = myAccessKeyID
```

```
aws_secret_access_key = mySecretAccessKey
emr =
     service_role = MyCustomServiceRoleForEMR
     instance_profile = MyCustomServiceRoleForClusterEC2Instances
```

Konfigurieren von IAM-Rollen für EMRFS-Anforderungen an Amazon S3

Wenn eine Anwendung, die auf einem -Cluster ausgeführt wird, auf Daten mithilfe des `s3://mydata`-Formats verweist, wird EMRFS von Amazon EMR verwendet, um die Anforderung zu stellen. Für die Interaktion mit Amazon S3 geht EMRFS von den Berechtigungsrichtlinien aus, die mit Ihrem Amazon-EC2-Instance-Profil verknüpft sind. Es wird dasselbe Amazon-EC2-Instance-Profil verwendet, unabhängig vom Benutzer oder der Gruppe, die die Anwendung ausführt, oder vom Speicherort der Daten in Amazon S3.

Wenn Sie Cluster mit mehreren Benutzern haben, die unterschiedliche Zugriffsebenen auf Daten in Amazon S3 über EMRFS benötigen, können Sie eine Sicherheitskonfiguration mit IAM-Rollen für EMRFS einrichten. EMRFS kann eine andere Servicerolle für EC2-Instance-Cluster übernehmen, basierend auf dem Benutzer oder der Gruppe, der bzw. die die Anforderung stellt, oder vom Speicherort der Daten in Amazon S3. Jede IAM-Rolle für EMRFS kann andere Berechtigungen für den Zugriff auf Daten in Amazon S3 besitzen. Weitere Informationen zur Servicerolle für Cluster-EC2-Instances finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).

Die Verwendung benutzerdefinierter IAM-Rollen für EMRFS wird in Amazon-EMR-Versionen 5.10.0 und höher unterstützt. Wenn Sie eine ältere Version verwenden oder zusätzliche Berechtigungsanforderungen haben, die über das, was IAM-Rollen für EMRFS bieten, hinausgehen, können Sie stattdessen einen benutzerdefinierten Anmeldeinformationsanbieter erstellen. Weitere Informationen finden Sie unter Autorisieren des Zugriffs auf die EMRFS Daten in Amazon S3.

Wenn Sie eine Sicherheitskonfiguration nutzen, um IAM-Rollen für EMRFS anzugeben, richten Sie Rollenzuordnungen ein. Jede Rollenzuordnung gibt eine IAM-Rolle an, die Kennungen entspricht. Diese Kennungen bestimmen die Basis für den Zugriff auf Amazon S3 über EMRFS. Die Kennungen können Benutzer, Gruppen oder Amazon-S3-Präfixe sein, die einen Datenspeicherort angeben. Wenn EMRFS eine Anforderung an Amazon S3 stellt und die die Anfrage den Grundlagen für den Zugriff entspricht, sorgt EMRFS dafür, dass EC2-Cluster-Instances die entsprechende IAM-Rolle für die Anfrage übernehmen. Die mit dieser Rolle verknüpften IAM-Berechtigungen gelten anstelle der IAM-Berechtigungen, die der Servicerolle für Cluster-EC2-Instances zugewiesen sind.

Die Benutzer und Gruppen in einer Rollenzuordnung sind Hadoop-Benutzer und -gruppen, die auf dem Cluster definiert sind. Benutzer und Gruppen werden EMRFS im Kontext der Anwendung übergeben, die es verwendet (z. B. YARN-Benutzer-Identitätswechsel). Das Amazon-S3-Präfix kann ein Bucket-Spezifizierer beliebiger Tiefe sein (z. B. `s3://mybucket` oder `s3://mybucket/myproject/mydata`). Sie können mehrere Kennungen in einer einzigen Rollenzuordnung angeben, die jedoch alle vom selben Typ sein müssen.

> **Important**
>
> IAM-Rollen für EMRFS bieten die Isolierung auf Anwendungsebene zwischen Benutzern der Anwendung. Sie bieten keine Isolierung auf Host-Ebene zwischen Benutzern auf dem Host. Jeder Benutzer mit Zugriff auf das Cluster kann die Isolation umgehen, um eine Rolle zu übernehmen.

Wenn eine Cluster-Anwendung über EMRFS eine Anforderung an Amazon S3 stellt, wertet EMRFS Rollenzuordnungen in der Reihenfolge von oben nach unten aus, in der sie in der Sicherheitskonfiguration erscheinen. Wenn eine über EMRFS gestellte Anforderung nicht mit einer Kennung übereinstimmt, verwendet EMRFS die Servicerolle für Cluster-EC2-Instances. Aus diesem Grund empfehlen wir, dass Sie die Richtlinien, die dieser Rolle zugeordnet werden, auf Berechtigungen in Amazon S3 begrenzen. Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).

Konfigurieren von -Rollen

Bevor Sie eine Sicherheitskonfiguration mit IAM-Rollen für EMRFS einrichten, müssen Sie die Rollen und die Berechtigungsrichtlinien für die Rollen planen und erstellen. Weitere Informationen finden Sie unter Wie funktionieren IAM Rollen für EC2-Instances? im IAM-Benutzerhandbuch. Wenn Sie Berechtigungsrichtlinien erstellen, empfehlen wir, dass Sie mit der verwalteten Richtlinie beginnen, die der Standard-Amazon-EMR-Rolle für EC2 zugeordnet ist. Bearbeiten Sie diese Richtlinien dann entsprechend Ihren Anforderungen. Der standardmäßige Rollename ist `EMR_EC2_DefaultRole`, und die zu bearbeitende verwaltete Standardrichtlinie ist `AmazonElasticMapReduceforEC2Role`. Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).

Aktualisieren von Vertrauensrichtlinien, um Rollenberechtigungen zu übernehmen

Jede Rolle, die EMRFS verwendet, muss über eine Vertrauensrichtlinie verfügen, die es der Amazon EMR-Rolle für EC2 des Clusters erlaubt, diese zu übernehmen. Entsprechend muss die Amazon-

EMR-Rolle des Clusters für EC2 über eine Vertrauensrichtlinie verfügen, die EMRFS-Rollen deren Übernahme erlaubt.

Das folgende Beispiel einer Vertrauensrichtlinie ist den Rollen für EMRFS zugeordnet. Mit der Anweisung kann die standardmäßige Amazon EMR-Rolle für EC2 die Rolle übernehmen. Beispiel: Sie verfügen über die zwei fiktiven EMRFS-Rollen `EMRFSRole_First` und `EMRFSRole_Second`. In diesem Fall wird diese Richtlinienanweisung den Vertrauensrichtlinien für jede davon hinzugefügt.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Effect":"Allow",
         "Principal":{
            "AWS":"arn:aws:iam::AWSAcctID:role/EMR_EC2_DefaultRole"
         },
         "Action":"sts:AssumeRole"
      }
   ]
}
```

Außerdem wird im folgenden Beispiel die Vertrauensrichtlinienanweisung der `EMR_EC2_DefaultRole` hinzugefügt, um zu erlauben, dass die beiden fiktiven EMRFS-Rollen diese übernehmen.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Effect":"Allow",
         "Principal":{
            "AWS": ["arn:aws:iam::AWSAcctID:role/EMRFSRole_First",
 "arn:aws:iam::AWSAcctID:role/EMRFSRole_Second"]
         },
         "Action":"sts:AssumeRole"
      }
   ]
}
```

So aktualisieren Sie die Vertrauensrichtlinie einer IAM-Rolle

Öffnen Sie die IAM-Konsole unter https://console.aws.amazon.com/iam/.

1. Wählen Sie Roles (Rollen), geben Sie den Namen der Rolle unter Search (Suche) ein und wählen Sie dann Role name (Rollenname) aus.
2. Wählen Sie auf der Registerkarte Trust Relationships (Vertrauensbeziehungen) Edit Trust Relationship (Vertrauensbeziehung bearbeiten) aus.
3. Fügen Sie eine Vertrauensanweisung gemäß dem Richtliniendokument und den Richtlinien oben hinzu und wählen Sie dann Vertrauensrichtlinie updaten.

Angeben einer Rolle als Schlüsselbenutzer

Wenn eine Rolle den Zugriff auf einen Speicherort in Amazon S3 zulässt, der mit einem AWS KMS key verschlüsselt ist, muss die Rolle als Schlüsselbenutzer angegeben werden. So erhält die Rolle die Berechtigung, den KMS-Schlüssel zu verwenden. Weitere Informationen finden Sie unter Schlüsselrichtlinien in AWS KMS im Entwicklerhandbuch für AWS Key Management Service.

Einrichten einer Sicherheitskonfiguration mit IAM-Rollen für EMRFS

> **Important**
>
> Kann keine der IAM-Rollen für EMRFS, die Sie angeben, angewendet werden, verwendet EMRFS die Amazon EMR-Rolle für EC2. Sie sollten die Berechtigungen dieser Rolle auf Amazon S3 einschränken wie für Ihre Anwendung erforderlich, und dann diese benutzerdefinierte Rolle anstelle von `EMR_EC2_DefaultRole` angeben, wenn Sie einen Cluster erstellen. Weitere Informationen finden Sie unter IAM-Rollen anpassen und Angabe benutzerdefinierter IAM-Rollen beim Erstellen eines Clusters.

So geben Sie IAM-Rollen für EMRFS-Anforderungen an Amazon S3 mithilfe der Konsole an

1. Erstellen Sie eine Sicherheitskonfiguration, die Rollenzuordnungen spezifiziert:
   a. Wählen Sie in der Amazon-EMR-Konsole die Optionen Sicherheitskonfigurationen und Erstellen aus.
   b. Geben Sie in Name (Name) einen Namen für die Sicherheitskonfiguration ein. Verwenden Sie diesen Namen zum Angeben der Sicherheitskonfiguration, wenn Sie einen Cluster erstellen.
   c. Wählen Sie IAM-Rollen für EMRFS-Anforderungen an Amazon S3 verwenden aus.

d. Wählen Sie eine anzuwendende IAM-Rolle aus. Wählen Sie zudem unter Grundlage für Zugriff einen ID-Typ (Benutzer, Gruppen oder S3-Präfixen) aus der Liste aus und geben Sie die entsprechenden Kennungen ein. Wenn Sie mehrere Kennungen verwenden, trennen Sie diese durch Komma (ohne Leerzeichen dazwischen) voneinander ab. Weitere Informationen zu den einzelnen ID-Typen finden Sie unten in der JSON configuration reference.

e. Wählen Sie Add role (Rolle hinzufügen) aus, um zusätzliche Rollenzuordnungen einzurichten wie im vorherigen Schritt beschrieben.

f. Richten Sie weitere Sicherheitskonfigurationsoptionen ein wie erforderlich. Wählen Sie Create (Erstellen) aus. Weitere Informationen finden Sie unter Eine Sicherheitskonfiguration erstellen.

2. Geben Sie die Sicherheitskonfiguration an, die Sie oben erstellt haben, wenn Sie einen Cluster erstellen. Weitere Informationen finden Sie unter Angabe einer Sicherheitskonfiguration für einen Cluster.

So geben Sie IAM-Rollen für EMRFS-Anforderungen an Amazon S3 mithilfe AWS CLI an

1. Verwenden Sie den Befehl `aws emr create-security-configuration`. Dadurch wie ein Name für die Sicherheitskonfiguration spezifiziert sowie die Sicherheitskonfigurationsdetails im JSON-Format.

   Der unten gezeigte Beispielbefehl erstellt eine Sicherheitskonfiguration namens `EMRFS_Roles_Security_Configuration`. Diese basiert auf einer JSON-Struktur aus der Datei `MyEmrfsSecConfig.json`, die in demselben Verzeichnis gespeichert ist, in dem der Befehl ausgeführt wird.

   ```
   aws emr create-security-configuration --name EMRFS_Roles_Security_Configuration --
   security-configuration file://MyEmrFsSecConfig.json.
   ```

   Verwenden Sie die folgenden Richtlinien für die Struktur der Datei `MyEmrFsSecConfig.json`. Sie können diese Struktur zusammen mit Strukturen für andere Sicherheitskonfigurationsoptionen angeben. Weitere Informationen finden Sie unter Eine Sicherheitskonfiguration erstellen.

   Im Folgenden finden Sie ein JSON-Beispiel für die Angabe benutzerdefinierter IAM-Rollen für EMRFS innerhalb einer Sicherheitskonfiguration. Es zeigt Rollenzuordnungen für die drei verschiedenen Identifier-Typen, gefolgt von einer Parameterreferenz.

```
{
  "AuthorizationConfiguration": {
    "EmrFsConfiguration": {
      "RoleMappings": [{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_for_user1",
        "IdentifierType": "User",
        "Identifiers": [ "user1" ]
      },{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_to_MyBuckets",
        "IdentifierType": "Prefix",
        "Identifiers": [ "s3://MyBucket/","s3://MyOtherBucket/" ]
      },{
        "Role": "arn:aws:iam::123456789101:role/allow_EMRFS_access_for_AdminGroup",
        "IdentifierType": "Group",
        "Identifiers": [ "AdminGroup" ]
      }]
    }
  }
}
```

Parameter	Beschreibung
`"AuthorizationConfiguration":`	Erforderlich.
`"EmrFsConfiguration":`	Erforderlich. Enthält Rollenzuordnungen.
`"RoleMappings":`	Erforderlich. Enthält eine oder mehrere Rollenzuordnungsdefinitionen. Rollenzuordnungen werden in der Reihenfolge bewertet, in der sie von oben nach unten angezeigt werden. Wenn eine Rollenzuweisung für einen EMRFS-Datenaufruf in Amazon S3 als wahr bewertet wird, werden keine weiteren Rollenzuordnungen ausgewertet und EMRFS verwendet die angegebene IAM-Rolle für die Anfrage. Rollenzuordnungen bestehen aus den folgenden erforderlichen Parametern:

Parameter	Beschreibung
`"Role":`	Gibt den ARN-Bezeichner einer IAM-Rolle im Format `arn:aws:iam::` *`account-id`* `:role/`*`role-name`* an. Dies ist die IAM-Rolle, die Amazon EMR übernimmt, wenn die EMRFS-Anfrage an Amazon S3 mit einer der angegebenen `Identifiers` übereinstimmt.
`"IdentifierType":`	Kann einer der folgenden sein: • `"User"` gibt an, dass es sich bei den Kennungen um einen oder mehrere Hadoop-Benutzer handelt, bei denen es sich um Linux-Kontobenutzer oder Kerberos-Prinzipale handeln kann. Wenn die EMRFS-Anfrage von dem oder den angegebenen Benutzern stammt, wird die IAM-Rolle übernommen. • `"Prefix"` gibt an, dass der Identifier ein Amazon-S3-Speicherort ist. Die IAM-Rolle wird für Anrufe an den Standort oder die Standorte mit den angegebenen Präfixen übernommen. Das Präfix `s3://mybucket/` entspricht beispielsweise `s3://mybucket/mydir` und `s3://mybucket/yetanotherdir` . • `"Group"` gibt an, dass es sich bei den Identifikatoren um eine oder mehrere Hadoop-Gruppen handelt. Die IAM-Rolle wird übernommen, wenn die Anfrage von einem Benutzer in der oder den angegebenen Gruppen stammt.

Parameter	Beschreibung
`"Identifiers":`	Gibt einen oder mehrere Kennungen des entsprechenden Kennungstyps an. Trennen Sie mehrere Bezeichner durch Kommas ohne Leerzeichen.

2. Verwenden Sie den Befehl `aws emr create-cluster`, um einen Cluster einzurichten, und geben Sie die Sicherheitskonfiguration an, die Sie im vorherigen Schritt erstellt haben.

   Im folgenden Beispiel wird ein Cluster erstellt, bei dem Standard-Core-Hadoop-Anwendungen installiert sind. Der Cluster verwendet die oben erstellte Sicherheitskonfiguration als `EMRFS_Roles_Security_Configuration` und verwendet außerdem eine benutzerdefinierte Amazon-EMR-Rolle für EC2, `EC2_Role_EMR_Restrict_S3`, die mit dem `InstanceProfile`-Argument des `--ec2-attributes`-Parameters angegeben wird.

   > **Note**
   >
   > Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name MyEmrFsS3RolesCluster \
--release-label emr-5.36.1 --ec2-attributes
 InstanceProfile=EC2_Role_EMR_Restrict_S3,KeyName=MyKey \
--instance-type m5.xlarge --instance-count 3 \
--security-configuration EMRFS_Roles_Security_Configuration
```

Ressourcenbasierte Richtlinien für den Zugriff von Amazon EMR auf AWS Glue Data Catalog verwenden

Wenn Sie AWS Glue in Verbindung mit Hive, Spark oder Presto in Amazon EMR verwenden, unterstützt AWS Glue ressourcenbasierte Richtlinien zur Steuerung des Zugriffs auf Datenkatalogressourcen. Zu diesen Ressourcen gehören Datenbanken, Tabellen, Verbindungen und benutzerdefinierte Funktionen. Weitere Informationen finden Sie unter Verwenden von ressourcenbasierten Richtlinien für AWS Glue im AWS-Glue-Entwicklerhandbuch.

Wenn Sie ressourcenbasierte Richtlinien verwenden, um den Zugriff auf AWS Glue von Amazon EMR aus zu beschränken, muss der Prinzipal, den Sie in der Berechtigungsrichtlinie angeben, der Rollen-ARN sein, der dem EC2-Instance-Profil zugeordnet ist, das bei der Erstellung eines Clusters angegeben wird. Beispielsweise können Sie für eine ressourcenbasierte Richtlinie, die an einen Katalog angehängt ist, den Rollen-ARN für die Standard-Servicerolle für Cluster-EC2-Instances, *EMR_EC2_DefaultRole*, als `Principal` angeben. Verwenden Sie dazu das im folgenden Beispiel gezeigte Format:

```
arn:aws:iam::acct-id:role/EMR_EC2_DefaultRole
```

Die *Konto-ID* kann sich von der AWS Glue-Konto-ID unterscheiden. Dies ermöglicht den Zugriff von EMR-Clustern in verschiedenen Konten aus. Sie können mehrere Principals angeben, von denen jeder aus einem anderen Konto stammt.

IAM-Rollen mit Anwendungen verwenden, die AWS-Services direkt aufrufen

Anwendungen, die auf den EC2-Instances eines Clusters ausgeführt werden, können das Instance-Profil dazu verwenden, um temporäre Sicherheitsanmeldeinformationen zu erhalten, wenn Sie AWS-Services aufrufen.

Die Hadoop-Versionen verfügbar mit Amazon EMR Version 2.3.0 und höher wurden bereits aktualisiert, um IAM-Rollen zu nutzen. Wenn Ihre Anwendung ausschließlich auf der Hadoop-Architektur ausgeführt wird und keine Services in AWS direkt aufruft, sollte sie ohne Änderungen mit den IAM-Rollen funktionieren.

Wenn Ihre Anwendung Services in AWS direkt aufruft, müssen Sie sie aktualisieren, um die Vorteile von IAM-Rollen nutzen zu können. Dies bedeutet, dass Ihre Anwendung, anstelle die Anmeldeinformationen von `/etc/hadoop/conf/core-site.xml` auf den EC2-Instances im Cluster zu erwerben, jetzt ein SDK verwendet, um mithilfe der IAM-Rollen auf die Ressourcen zuzugreifen oder die EC2-Instance-Metadaten aufzurufen, um die temporären Anmeldeinformationen zu erhalten.

So greifen Sie über ein SDK mit IAM-Rollen auf AWS-Ressourcen zu

- Die folgenden Themen zeigen, wie verschiedene AWS-SDKs verwendet werden können, um mittels IAM-Rollen auf temporäre Anmeldeinformationen zuzugreifen. Jedes Thema beginnt mit einer Anwendungsversion, die keine IAM-Rollen verwendet, und führt Sie anschließend schrittweise durch die Konvertierung der Anwendung, um sie auf die Verwendung der IAM-Rollen vorzubereiten.

- Verwenden von IAM-Rollen für Amazon-EC2-Instances mit dem SDK für Java im AWS SDK for Java-Entwicklerhandbuch
- Verwenden von IAM-Rollen für Amazon-EC2-Instances mit dem SDK für .NET im AWS SDK for .NET-Entwicklerhandbuch
- Verwenden von IAM-Rollen für Amazon-EC2-Instances mit dem SDK für PHP im AWS SDK for PHP-Entwicklerhandbuch
- Verwenden von IAM-Rollen für Amazon-EC2-Instances mit dem SDK für Ruby im AWS SDK for Ruby-Entwicklerhandbuch

Abrufen von temporären Anmeldeinformationen aus den EC2-Instance-Metadaten

- Rufen Sie die folgende URL von einer EC2-Instance ab, die unter der angegebenen IAM-Rolle ausgeführt wird, gibt sie die temporären Sicherheitsanmeldeinformationen zurück (AccessKeyId, SecretAccessKey, SessionToken und Expiration). Das folgende Beispiel verwendet das Standard-Instance-Profil für Amazon EMR, `EMR_EC2_DefaultRole`.

```
GET http://169.254.169.254/latest/meta-data/iam/security-
credentials/EMR_EC2_DefaultRole
```

Weitere Informationen zum Schreiben von Anwendungen, die IAM-Rollen verwenden, finden Sie unter Erteilen des Zugriffs auf Amazon EC2 für auf AWS ausgeführte Anwendungen.

Weitere Informationen zu temporären Sicherheitsanmeldeinformationen finden Sie unter Verwenden temporärer Sicherheitsanmeldeinformationen im Handbuch Verwenden temporärer Sicherheitsanmeldeinformationen.

Benutzern und Gruppen gestatten, Rollen zu erstellen und zu ändern

IAM-Prinzipale (Benutzer und Gruppen), die Rollen für einen Cluster erstellen, ändern und festlegen, einschließlich Standardrollen, müssen die Berechtigung haben, die folgenden Aktionen durchzuführen. Weitere Informationen zu den einzelnen Aktionen finden Sie unter Aktionen in der IAM-API-Referenz.

- `iam:CreateRole`

- `iam:PutRolePolicy`
- `iam:CreateInstanceProfile`
- `iam:AddRoleToInstanceProfile`
- `iam:ListRoles`
- `iam:GetPolicy`
- `iam:GetInstanceProfile`
- `iam:GetPolicyVersion`
- `iam:AttachRolePolicy`
- `iam:PassRole`

Die Berechtigung `iam:PassRole` gewährt die Erstellung von Clustern. Die restlichen Berechtigungen gewähren die Erstellung von Standardrollen.

Weitere Informationen zum Zuweisen von Berechtigungen in IAM finden Sie unter Ändern von Berechtigungen für einen IAM-Benutzer im IAM-Benutzerhandbuch.

Beispiele für identitätsbasierte Amazon-EMR-Richtlinien

Benutzer und Rollen besitzen standardmäßig keine Berechtigungen zum Erstellen oder Ändern von Amazon EMR-Ressourcen. Sie können auch keine Aufgaben ausführen, die die AWS Management Console-, AWS CLI- oder AWS-API benutzen. Ein IAM-Administrator muss IAM-Richtlinien erstellen, die Benutzern und Rollen die Berechtigung zum Ausführen bestimmter API-Operationen für die angegebenen Ressourcen gewähren, die diese benötigen. Der Administrator muss diese Richtlinien anschließend den Benutzern oder -Gruppen anfügen, die diese Berechtigungen benötigen.

Informationen dazu, wie Sie unter Verwendung dieser beispielhaften JSON-Richtliniendokumente eine identitätsbasierte IAM-Richtlinie erstellen, finden Sie unter Erstellen von Richtlinien auf der JSON-Registerkarte im IAM-Benutzerhandbuch.

Themen

- Bewährte Methoden für Richtlinien für Amazon EMR
- Gewähren der Berechtigung zur Anzeige der eigenen Berechtigungen für Benutzer
- Verwaltete Richtlinien von Amazon EMR
- IAM-Richtlinien für Tag-basierten Zugriff auf Cluster und EMR-Notebooks
- Die ModifyInstanceGroup-Aktion wird verweigert

- Fehlerbehebung für Amazon-EMR-Identität und -Zugriff

Bewährte Methoden für Richtlinien für Amazon EMR

Identitätsbasierte Richtlinien sind sehr leistungsfähig. Damit wird bestimmt, ob jemand Amazon-EMR-Ressourcen in Ihrem Konto erstellen, löschen oder darauf zugreifen kann. Dies kann zusätzliche Kosten für Ihr AWS-Konto verursachen. Befolgen Sie beim Erstellen oder Bearbeiten identitätsbasierter Richtlinien die folgenden Anleitungen und Empfehlungen:

- Erste Schritte mit AWS-verwalteten Richtlinien – Damit Sie Amazon EMR schnell nutzen können, verwenden Sie AWS-verwaltete Richtlinien, um Ihren Mitarbeitern die erforderlichen Berechtigungen zu erteilen. Diese Richtlinien sind bereits in Ihrem Konto verfügbar und werden von AWS. Weitere Informationen finden Sie unter Erste Schritte zur Verwendung von Berechtigungen mit AWS-verwalteten Richtlinien im IAM-Benutzerhandbuch und Verwaltete Richtlinien von Amazon EMR.
- Gewähren Sie die geringstmöglichen Berechtigungen – Gewähren Sie beim Erstellen benutzerdefinierter Richtlinien nur die Berechtigungen, die zum Ausführen einer Aufgabe erforderlich sind. Beginnen Sie mit einem Mindestsatz von Berechtigungen und gewähren Sie zusätzliche Berechtigungen wie erforderlich. Dies ist sicherer, als mit Berechtigungen zu beginnen, die zu weit gefasst sind, und dann später zu versuchen, sie zu begrenzen. Weitere Informationen finden Sie unter Gewähren von geringsten Rechten im IAM-Benutzerhandbuch.
- Aktivieren Sie für sensible Vorgänge MFA – Fordern Sie von Benutzern die Verwendung von Multi-Faktor-Authentifizierung (MFA), um zusätzliche Sicherheit beim Zugriff auf sensible Ressourcen oder API-Operationen zu bieten. Weitere Informationen finden Sie unter Verwenden der Multi-Faktor-Authentifizierung (MFA) in AWS im IAM-Benutzerhandbuch.
- Verwenden Sie Richtlinienbedingungen, um zusätzliche Sicherheit zu bieten – Definieren Sie die Bedingungen, unter denen Ihre identitätsbasierten Richtlinien den Zugriff auf eine Ressource zulassen, soweit praktikabel. Beispielsweise können Sie Bedingungen schreiben, die eine Reihe von zulässigen IP-Adressen festlegen, von denen eine Anforderung stammen muss. Sie können auch Bedingungen schreiben, die Anforderungen nur innerhalb eines bestimmten Datums- oder Zeitbereichs zulassen oder die Verwendung von SSL oder MFA fordern. Weitere Informationen finden Sie unter IAM-JSON-Richtlinienelemente: Bedingung im IAM-Benutzerhandbuch.

Gewähren der Berechtigung zur Anzeige der eigenen Berechtigungen für Benutzer

In diesem Beispiel wird gezeigt, wie Sie eine Richtlinie erstellen, die Benutzern die Berechtigung zum Anzeigen der eingebundenen Richtlinien und verwalteten Richtlinien gewährt, die ihrer Benutzeridentität angefügt sind. Diese Richtlinie enthält Berechtigungen für die Ausführung dieser Aktion auf der Konsole oder für die programmgesteuerte Ausführung über die AWS CLI oder die AWS-API.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Sid":"ViewOwnUserInfo",
         "Effect":"Allow",
         "Action":[
            "iam:GetUser",
            "iam:GetUserPolicy",
            "iam:ListAttachedUserPolicies",
            "iam:ListGroupsForUser",
            "iam:ListUserPolicies"
         ],
         "Resource":[
            "arn:aws:iam:::user/${aws:username}"
         ]
      },
      {
         "Sid":"NavigateInConsole",
         "Effect":"Allow",
         "Action":[
            "iam:GetGroupPolicy",
            "iam:GetPolicy",
            "iam:GetPolicyVersion",
            "iam:ListAttachedGroupPolicies",
            "iam:ListGroupPolicies",
            "iam:ListGroups",
            "iam:ListPolicies",
            "iam:ListPolicyVersions",
            "iam:ListUsers"
         ],
         "Resource":""
      }
   ]
```

```
}
```

Verwaltete Richtlinien von Amazon EMR

Die einfachste Möglichkeit, Vollzugriff oder Lesezugriff auf benötigte Amazon-EMR-Aktionen zu erteilen, besteht in der Verwendung von IAM-verwalteten Richtlinien für Amazon EMR. Verwaltete Richtlinien haben den Vorteil, automatisch aktualisiert zu werden, wenn sich die Berechtigungsanforderungen ändern. Wenn Sie eingebundene Richtlinien verwenden, können Service-Veränderungen auftreten, die zu Berechtigungsfehlern führen.

Amazon EMR wird bestehende verwaltete Richtlinien (v1-Richtlinien) zugunsten neuer verwalteter Richtlinien (v2-Richtlinien) ablehnen. Die neuen verwalteten Richtlinien wurden im Hinblick auf die Einhaltung bewährter AWS-Methoden heruntergestuft. Sobald die bestehenden verwalteten Richtlinien der Version 1 veraltet sind, können Sie diese Richtlinien keinen neuen IAM-Rollen oder -Benutzern mehr zuordnen. Bestehende Rollen und Benutzer, die veraltete Richtlinien verwenden, können diese weiterhin verwenden. Die verwalteten v2-Richtlinien schränken den Zugriff mithilfe von Tags ein. Sie lassen nur bestimmte Amazon-EMR-Aktionen zu und erfordern Cluster-Ressourcen, die mit einem EMR-spezifischen Schlüssel gekennzeichnet sind. Wir empfehlen Ihnen, die Dokumentation sorgfältig zu lesen, bevor Sie die neuen v2-Richtlinien verwenden.

Die v1-Richtlinien werden in der Liste der Richtlinien der IAM-Konsole mit einem Warnsymbol daneben als veraltet markiert. Die veralteten Richtlinien werden die folgenden Merkmale aufweisen:

- Sie werden unverändert für alle gegenwärtig angefügten Benutzer, Gruppen und Rollen funktionsfähig. Alles funktioniert normal.
- Sie können nicht neuen Benutzern, Gruppen oder Rollen angefügt werden. Wenn Sie eine der Richtlinien von einer gegenwärtigen Entität trennen, können Sie sie nicht wieder anfügen.
- Nachdem Sie eine v1-Richtlinie von allen aktuellen Entitäten getrennt haben, ist die Richtlinie nicht mehr sichtbar und kann nicht mehr verwendet werden.

In der folgenden Tabelle werden die Änderungen zwischen den aktuellen Richtlinien (v1) und v2-Richtlinien zusammengefasst.

Änderungen von EMR-verwalteten Richtlinien

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie
Von IAM verwaltete Richtlinie für vollständigen EMR-Zugriff durch angehängte Benutzer, Rollen oder Gruppen	V1-Richtlinie (wird veraltet): **AmazonElasticMapReduceFullAccess** V2-Richtlinienname (mit Geltungsbereich): **AmazonEMRFullAccessPolicy_v2**	Erlaubt Benutzern volle Berechtigungen für EMR-Aktionen. Beinhaltet iam:PassRole-Berechtigungen für Ressourcen.	Die Richtlinie setzt voraus, dass Benutzer Benutzer-Tags zu Ressourcen hinzufügen müssen, bevor sie diese Richtlinie verwenden können. Siehe Taggen von Ressourcen zur Verwendung verwalteter Richtlinien. Für die Aktion iam:PassRole muss die Bedingung iam:PassedToService auf den angegebenen Service gesetzt sein. Der Zugriff auf Amazon EC2, Amazon S3 und andere Services ist standardmäßig nicht zulässig. Weitere Informationen finden Sie unter Verwaltete IAM-Richtlinie für vollen Zugriff (verwaltete Standardrichtlinie v2).

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie
Von IAM verwaltete Richtlinie für vollständigen EMR-Zugriff durch angehängte Benutzer, Rollen oder Gruppen	V1-Richtlinie (wird veraltet): **AmazonElasticMapReduceReadOnlyAccess** V2-Richtlinienname (mit Geltungsbereich): **AmazonEMRReadOnlyAccessPolicy_v2**	Ermöglicht Benutzern nur Leseberechtigungen für Amazon-EMR-Aktionen.	Mit Berechtigungen können nur bestimmte schreibgeschützte ElasticMapReduce-Aktionen ausgeführt werden. Der Zugriff auf Amazon S3 ist standardmäßig nicht zulässig. Weitere Informationen finden Sie unter Verwaltete IAM-Richtlinie für vollen Zugriff (verwaltete Standardrichtlinie v2)

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie
Standard-EMR-Servicerolle und angehängte verwaltete Richtlinie	Rollenname: EMR_DefaultRole V1-Richtlinie (wird nicht mehr unterstützt): AmazonElasticMapReduceRole (EMR Service Role) V2-Richtlinienname (mit eingeschränktem Geltungsbereich): **AmazonEMRServicePolicy_v2**	Ermöglicht Amazon EMR das Aufrufen anderer AWS-Services in Ihrem Namen, wenn Ressourcen bereitgestellt und Aktionen auf Serviceebene durchgeführt werden. Diese Rolle ist für alle Cluster erforderlich.	Die v2-Servicerolle und die v2-Standardrichtlinie ersetzen die veraltete Rolle und Richtlinie. Die Richtlinie setzt voraus, dass Benutzer Benutzer-Tags zu Ressourcen hinzufügen müssen, bevor sie diese Richtlinie verwenden können. Siehe Taggen von Ressourcen zur Verwendung verwalteter Richtlinien. Siehe Servicerolle für Amazon EMR (EMR-Rolle).

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie
Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil)	V1-Richtlinie (wird nicht mehr unterstützt): EMR_EC2_DefaultRole (Instance-Profil) Veralteter Richtlinienname: AmazonElasticMapReduceforEC2Role	Ermöglicht Anwendungen, die auf einem EMR-Cluster ausgeführt werden, auf andere AWS-Ressourcen wie Amazon S3 zuzugreifen. Wenn Sie beispielsweise Apache-Spark-Aufträge ausführen, die Daten von Amazon S3 verarbeiten, muss die Richtlinie den Zugriff auf solche Ressourcen zulassen.	Sowohl die Standardrolle als auch die Standardrichtlinie werden demnächst veraltet sein. Es gibt keinen Ersatz für die verwaltete AWS-Standardrolle oder -Richtlinie. Sie müssen eine ressourcen- oder identitätsbasierte Richtlinie bereitstellen. Das bedeutet, dass Anwendungen, die auf einem EMR-Cluster ausgeführt werden, standardmäßig keinen Zugriff auf Amazon S3 oder andere Ressourcen haben, es sei denn, Sie fügen diese manuell zur Richtlinie hinzu. Siehe Standardrolle und verwaltete Richtlinie.

Richtlinientyp	Richtliniennamen	Zweck der Richtlinie	Änderungen der v2-Richtlinie
Andere Richtlinien für EC2-Servicerollen	Aktuelle Richtlinienennamen: AmazonElasticMapReduceforAutoScalingRole, AmazonElasticMapReduceEditorsRole, AmazonEMRCleanupPolicy	Stellt Berechtigungen bereit, die EMR benötigt, um auf andere AWS Ressourcen zuzugreifen und Aktionen auszuführen, wenn Auto Scaling, Notebooks oder zum Bereinigen von EC2-Ressourcen verwendet werden.	Keine Änderungen für Version 2.

Sicherung von iam:PassRole

Die verwalteten Standardrichtlinien von Amazon EMR mit vollen Berechtigungen beinhalten `iam:PassRole`-Sicherheitskonfigurationen, darunter die folgenden:

- `iam:PassRole`-Berechtigungen nur für bestimmte Amazon-EMR-Standardrollen.
- `iam:PassedToService`-Bedingungen, die es Ihnen ermöglichen, die Richtlinie nur mit bestimmten AWS-Services zu verwenden, z. B. `elasticmapreduce.amazonaws.com` und `ec2.amazonaws.com`.

Sie können die JSON-Version der Richtlinien AmazonEMRFullAccessPolicy_v2 und AmazonEMRServicePolicy_v2 in der IAM-Konsole anzeigen. Wir empfehlen, dass Sie neue Cluster mit den verwalteten v2-Richtlinien erstellen.

Wenn Sie benutzerdefinierte Richtlinien erstellen müssen, empfehlen wir ihnen, mit verwalteten Richtlinien zu beginnen und diese entsprechend Ihren Anforderungen zu bearbeiten.

Informationen zum Anfügen von Richtlinien an -Benutzer (Prinzipale) finden Sie unter Arbeiten mit verwalteten Richtlinien über die AWS Management Console im IAM-Benutzerhandbuch.

Taggen von Ressourcen zur Verwendung verwalteter Richtlinien

AmazonEMRServicePolicy_v2 und AmazonEMRFullAccessPolicy_v2 hängen vom begrenzten Zugriff auf Ressourcen ab, die Amazon EMR bereitstellt oder verwendet. Der eingeschränkte Umfang wird dadurch erreicht, dass der Zugriff nur auf die Ressourcen beschränkt wird, denen ein vordefiniertes Benutzer-Tag zugeordnet ist. Wenn Sie eine dieser beiden Richtlinien verwenden, müssen Sie bei der Bereitstellung des Clusters das vordefinierte Benutzer-Tag `for-use-with-amazon-emr-managed-policies = true` übergeben. Amazon EMR verbreitet diese Tags automatisch. Darüber hinaus müssen Sie den im folgenden Abschnitt aufgelisteten Ressourcen ein Benutzer-Tag hinzufügen. Wenn Sie die Amazon-EMR-Konsole verwenden, um Ihren Cluster zu starten, finden Sie weitere Informationen unter Überlegungen zur Verwendung der Amazon-EMR-Konsole zum Starten von Clustern mit verwalteten v2-Richtlinien.

Um verwaltete Richtlinien zu verwenden, übergeben Sie das Benutzer-Tag `for-use-with-amazon-emr-managed-policies = true`, wenn Sie einen Cluster mit der CLI, dem SDK oder einer anderen Methode bereitstellen.

Wenn Sie das Tag übergeben, leitet Amazon EMR das Tag an die privaten Subnetz-ENI-, EC2-Instance- und EBS-Volumes weiter, die es erstellt. Amazon EMR kennzeichnet auch automatisch Sicherheitsgruppen, die es erstellt. Wenn Sie jedoch möchten, dass Amazon EMR mit einer bestimmten Sicherheitsgruppe gestartet wird, müssen Sie sie taggen. Für Ressourcen, die nicht von Amazon EMR erstellt wurden, müssen Sie diesen Ressourcen Tags hinzufügen. Beispielsweise müssen Sie Amazon-EC2-Subnetze, EC2-Sicherheitsgruppen (sofern sie nicht von Amazon EMR erstellt wurden) und VPCs (wenn Amazon EMR Sicherheitsgruppen erstellen soll) kennzeichnen. Um Cluster mit verwalteten v2-Richtlinien in VPCs zu starten, müssen Sie diese VPCs mit dem vordefinierten Benutzer-Tag kennzeichnen. Siehe Überlegungen zur Verwendung der Amazon-EMR-Konsole zum Starten von Clustern mit verwalteten v2-Richtlinien.

Weiterverbreitetes benutzerdefiniertes Tagging

Amazon EMR kennzeichnet Ressourcen, die es mit den Amazon-EMR-Tags erstellt, die Sie bei der Erstellung eines Clusters angeben. Amazon EMR wendet Tags auf die Ressourcen an, die es während der Lebensdauer des Clusters erstellt.

Amazon EMR verbreitet Benutzer-Tags für die folgenden Ressourcen:

- Privates Subnetz-ENI (elastische Netzwerkschnittstellen für Servicezugriff)
- EC2-Instances
- EBS-Datenträger

- EC2-Startvorlage

Automatisch getaggte Sicherheitsgruppen

Amazon EMR kennzeichnet EC2-Sicherheitsgruppen, die es erstellt, mit dem Tag, das für verwaltete v2-Richtlinien für Amazon EMR erforderlich ist `for-use-with-amazon-emr-managed-policies`, unabhängig davon, welche Tags Sie im Befehl „Cluster erstellen“ angeben. Für eine Sicherheitsgruppe, die vor der Einführung der verwalteten Richtlinien der Version 2 erstellt wurde, kennzeichnet Amazon EMR die Sicherheitsgruppe nicht automatisch. Wenn Sie verwaltete v2-Richtlinien mit den Standardsicherheitsgruppen verwenden möchten, die bereits im Konto vorhanden sind, müssen Sie die Sicherheitsgruppen manuell mit `for-use-with-amazon-emr-managed-policies = true` taggen.

Manuell getaggte Clusterressourcen

Sie müssen einige Cluster-Ressourcen manuell taggen, damit sie über Amazon-EMR-Standardrollen abgerufen werden können.

- Sie müssen EC2-Sicherheitsgruppen und EC2-Subnetze manuell mit dem von Amazon EMR verwalteten Richtlinien-Tag `for-use-with-amazon-emr-managed-policies` kennzeichnen.
- Sie müssen eine VPC manuell taggen, wenn Amazon EMR Standardsicherheitsgruppen erstellen soll. EMR versucht, eine Sicherheitsgruppe mit dem spezifischen Tag zu erstellen, falls die Standardsicherheitsgruppe noch nicht existiert.

Amazon EMR kennzeichnet automatisch die folgenden Ressourcen:

- Von EMR erstellte EC2-Sicherheitsgruppen

Sie müssen die folgenden Ressourcen manuell taggen:

- EC2-Subnetz
- EC2-Sicherheitsgruppen

Optional können Sie die folgenden Ressourcen manuell taggen:

- VPC – nur wenn Sie möchten, dass Amazon EMR Sicherheitsgruppen erstellt

Überlegungen zur Verwendung der Amazon-EMR-Konsole zum Starten von Clustern mit verwalteten v2-Richtlinien

Sie können Cluster mit verwalteten v2-Richtlinien mithilfe der Amazon-EMR-Konsole bereitstellen. Im Folgenden finden Sie einige Überlegungen, wenn Sie die Konsole zum Starten von Amazon-EMR-Clustern verwenden.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet. Die Auto-Tagging-Funktion ist in der neuen Konsole noch nicht verfügbar, und die neue Konsole zeigt Ihnen auch nicht, welche Ressourcen (VPC/Subnetze) markiert werden müssen. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

- Sie müssen das vordefinierte Tag nicht übergeben. Amazon EMR fügt das Tag automatisch hinzu und leitet es an die entsprechenden Komponenten weiter.
- Bei Komponenten, die manuell markiert werden müssen, versucht die alte Amazon-EMR-Konsole, sie automatisch zu kennzeichnen, sofern Sie über die erforderlichen Berechtigungen zum Taggen von Ressourcen verfügen. Wenn Sie nicht über die Berechtigungen zum Taggen von Ressourcen verfügen oder die neue Konsole verwenden möchten, bitten Sie Ihren Administrator, diese Ressourcen zu taggen.
- Sie können Cluster mit verwalteten v2-Richtlinien nur starten, wenn alle Voraussetzungen erfüllt sind.
- Die alte Amazon-EMR-Konsole zeigt Ihnen, welche Ressourcen (VPC/Subnetze) markiert werden müssen.

Verwaltete IAM-Richtlinie für vollen Zugriff (verwaltete Standardrichtlinie v2)

Die standardmäßigen verwalteten EMR-Richtlinien mit Geltungsbereich v2 gewähren Benutzern bestimmte Zugriffsrechte. Sie benötigen ein vordefiniertes Amazon-EMR-Ressourcen-Tag und `iam:PassRole` Zustandsschlüssel für Ressourcen, die von Amazon EMR verwendet werden, wie z. B. die `Subnet` und die `SecurityGroup`, die Sie zum Starten Ihres Clusters verwenden.

Um alle erforderlichen Aktionen für Amazon EMR zuzulassen, fügen Sie die `AmazonEMRFullAccessPolicy_v2`-verwaltete Richtlinie an. Diese aktualisierte verwaltete Standardrichtlinie ersetzt die `AmazonElasticMapReduceFullAccess` verwaltete Richtlinie.

`AmazonEMRFullAccessPolicy_v2` hängt vom begrenzten Zugriff auf Ressourcen ab, die Amazon EMR bereitstellt oder nutzt. Wenn Sie diese Richtlinie verwenden, müssen Sie bei der Bereitstellung des Clusters das Benutzer-Tag `for-use-with-amazon-emr-managed-policies = true` übergeben. Amazon EMR verbreitet diese Tags automatisch. Darüber hinaus müssen Sie möglicherweise manuell ein Benutzer-Tag zu bestimmten Ressourcentypen hinzufügen, z. B. EC2-Sicherheitsgruppen, die nicht von Amazon EMR erstellt wurden. Weitere Informationen finden Sie unter Taggen von Ressourcen zur Verwendung verwalteter Richtlinien.

Die `AmazonEMRFullAccessPolicy_v2`-Richtlinie schützt Ressourcen, indem sie wie folgt vorgeht:

- Erfordert, dass Ressourcen für die Clustererstellung und den Zugriff auf Amazon EMR mit dem vordefinierten Tag `for-use-with-amazon-emr-managed-policies` für verwaltete Amazon-EMR-Richtlinien gekennzeichnet werden.
- Beschränkt die `iam:PassRole`-Aktion auf bestimmte Standardrollen und den `iam:PassedToService`-Zugriff auf bestimmte Services.
- Bietet standardmäßig keinen Zugriff mehr auf Amazon EC2, Amazon S3 und andere Services.

Im Folgenden finden Sie den Inhalt dieser Richtlinie.

> **Note**
>
> Sie können die Richtlinie auch über den Konsolenlink `AmazonEMRFullAccessPolicy_v2` anzeigen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "RunJobFlowExplicitlyWithEMRManagedTag",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:RunJobFlow"
            ],
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "aws:RequestTag/for-use-with-amazon-emr-managed-policies": "true"
                }
```

```
            }
        },
        {
            "Sid": "ElasticMapReduceActions",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:AddInstanceFleet",
                "elasticmapreduce:AddInstanceGroups",
                "elasticmapreduce:AddJobFlowSteps",
                "elasticmapreduce:AddTags",
                "elasticmapreduce:CancelSteps",
                "elasticmapreduce:CreateEditor",
                "elasticmapreduce:CreateSecurityConfiguration",
                "elasticmapreduce:DeleteEditor",
                "elasticmapreduce:DeleteSecurityConfiguration",
                "elasticmapreduce:DescribeCluster",
                "elasticmapreduce:DescribeEditor",
                "elasticmapreduce:DescribeJobFlows",
                "elasticmapreduce:DescribeSecurityConfiguration",
                "elasticmapreduce:DescribeStep",
                "elasticmapreduce:DescribeReleaseLabel",
                "elasticmapreduce:GetBlockPublicAccessConfiguration",
                "elasticmapreduce:GetManagedScalingPolicy",
                "elasticmapreduce:GetAutoTerminationPolicy",
                "elasticmapreduce:ListBootstrapActions",
                "elasticmapreduce:ListClusters",
                "elasticmapreduce:ListEditors",
                "elasticmapreduce:ListInstanceFleets",
                "elasticmapreduce:ListInstanceGroups",
                "elasticmapreduce:ListInstances",
                "elasticmapreduce:ListSecurityConfigurations",
                "elasticmapreduce:ListSteps",
                "elasticmapreduce:ListSupportedInstanceTypes",
                "elasticmapreduce:ModifyCluster",
                "elasticmapreduce:ModifyInstanceFleet",
                "elasticmapreduce:ModifyInstanceGroups",
                "elasticmapreduce:OpenEditorInConsole",
                "elasticmapreduce:PutAutoScalingPolicy",
                "elasticmapreduce:PutBlockPublicAccessConfiguration",
                "elasticmapreduce:PutManagedScalingPolicy",
                "elasticmapreduce:RemoveAutoScalingPolicy",
                "elasticmapreduce:RemoveManagedScalingPolicy",
                "elasticmapreduce:RemoveTags",
                "elasticmapreduce:SetTerminationProtection",
```

```
                "elasticmapreduce:StartEditor",
                "elasticmapreduce:StopEditor",
                "elasticmapreduce:TerminateJobFlows",
                "elasticmapreduce:ViewEventsFromAllClustersInConsole"
            ],
            "Resource": "*"
        },
        {
            "Sid": "ViewMetricsInEMRConsole",
            "Effect": "Allow",
            "Action": [
                "cloudwatch:GetMetricStatistics"
            ],
            "Resource": "*"
        },
        {
            "Sid": "PassRoleForElasticMapReduce",
            "Effect": "Allow",
            "Action": "iam:PassRole",
            "Resource": [
                "arn:aws:iam::*:role/EMR_DefaultRole",
                "arn:aws:iam::*:role/EMR_DefaultRole_V2"
            ],
            "Condition": {
                "StringLike": {
                    "iam:PassedToService": "elasticmapreduce.amazonaws.com*"
                }
            }
        },
        {
            "Sid": "PassRoleForEC2",
            "Effect": "Allow",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::*:role/EMR_EC2_DefaultRole",
            "Condition": {
                "StringLike": {
                    "iam:PassedToService": "ec2.amazonaws.com*"
                }
            }
        },
        {
            "Sid": "PassRoleForAutoScaling",
            "Effect": "Allow",
            "Action": "iam:PassRole",
```

```
            "Resource": "arn:aws:iam::*:role/EMR_AutoScaling_DefaultRole",
            "Condition": {
                "StringLike": {
                    "iam:PassedToService": "application-autoscaling.amazonaws.com*"
                }
            }
        },
        {
            "Sid": "ElasticMapReduceServiceLinkedRole",
            "Effect": "Allow",
            "Action": "iam:CreateServiceLinkedRole",
            "Resource": "arn:aws:iam::*:role/aws-service-role/
elasticmapreduce.amazonaws.com*/AWSServiceRoleForEMRCleanup*",
            "Condition": {
                "StringEquals": {
                    "iam:AWSServiceName": [
                        "elasticmapreduce.amazonaws.com",
                        "elasticmapreduce.amazonaws.com.cn"
                    ]
                }
            }
        },
        {
            "Sid": "ConsoleUIActions",
            "Effect": "Allow",
            "Action": [
                "ec2:DescribeAccountAttributes",
                "ec2:DescribeAvailabilityZones",
                "ec2:DescribeImages",
                "ec2:DescribeKeyPairs",
                "ec2:DescribeNatGateways",
                "ec2:DescribeRouteTables",
                "ec2:DescribeSecurityGroups",
                "ec2:DescribeSubnets",
                "ec2:DescribeVpcs",
                "ec2:DescribeVpcEndpoints",
                "s3:ListAllMyBuckets",
                "iam:ListRoles"
            ],
            "Resource": "*"
        }
    ]
}
```

Von IAM verwaltete Richtlinie für vollen Zugriff (demnächst veraltet)

Die verwalteten Richtlinien `AmazonElasticMapReduceFullAccess` und `AmazonEMRFullAccessPolicy_v2` AWS Identity and Access Management (IAM) gewähren alle erforderlichen Aktionen für Amazon EMR und andere Services.

> **Important**
>
> Die verwaltete Richtlinie `AmazonElasticMapReduceFullAccess` ist veraltet und wird nicht mehr für die Verwendung mit Amazon EMR empfohlen. Verwenden Sie stattdessen `AmazonEMRFullAccessPolicy_v2`. Wenn der IAM-Service die v1-Richtlinie irgendwann als veraltet markiert, können Sie sie keiner Rolle zuordnen. Sie können einem Cluster jedoch eine bestehende Rolle zuordnen, auch wenn diese Rolle die veraltete Richtlinie verwendet.

Die verwalteten Standardrichtlinien von Amazon EMR mit vollen Berechtigungen beinhalten `iam:PassRole`-Sicherheitskonfigurationen, darunter die folgenden:

- `iam:PassRole`-Berechtigungen nur für bestimmte Amazon-EMR-Standardrollen.
- `iam:PassedToService`-Bedingungen, die es Ihnen ermöglichen, die Richtlinie nur mit bestimmten AWS-Services zu verwenden, z. B. `elasticmapreduce.amazonaws.com` und `ec2.amazonaws.com`.

Sie können die JSON-Version der Richtlinien AmazonEMRFullAccessPolicy_v2 und AmazonEMRServicePolicy_v2 in der IAM-Konsole anzeigen. Wir empfehlen, dass Sie neue Cluster mit den verwalteten v2-Richtlinien erstellen.

Sie können den Inhalt der veralteten v1-Richtlinie in AWS Management Console unter `AmazonElasticMapReduceFullAccess` einsehen. Die `ec2:TerminateInstances`-Aktion in der Richtlinie gewährt einem Benutzer oder einer Rolle die Erlaubnis, eine der Amazon-EC2-Instances zu kündigen, die mit dem IAM-Konto verknüpft sind. Dies schließt Instances ein, die nicht Teil eines EMR-Clusters sind.

Weitere Informationen finden Sie unter Verwaltete IAM-Richtlinie für vollen Zugriff (verwaltete Standardrichtlinie v2)

Um Amazon EMR nur Leserechte zu erteilen, fügen Sie die verwaltete Richtlinie AmazonEMRReadOnlyAccessPolicy_v2 an. Diese verwaltete Standardrichtlinie ersetzt die `AmazonElasticMapReduceReadOnlyAccess` verwaltete Richtlinie.

Der Inhalt dieser Richtlinienerklärung wird im folgenden Ausschnitt dargestellt. Im Vergleich zur `AmazonElasticMapReduceReadOnlyAccess`-Richtlinie verwendet die `AmazonEMRReadOnlyAccessPolicy_v2`-Richtlinie keine Platzhalterzeichen für das `elasticmapreduce`-Element. Stattdessen beschränkt sich die standardmäßige v2-Richtlinie auf die zulässigen `elasticmapreduce`-Aktionen.

> **Note**
>
> Sie können die Richtlinie auch über den AWS Management Console-Link AmazonEMRReadOnlyAccessPolicy_v2 anzeigen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ElasticMapReduceActions",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:DescribeCluster",
                "elasticmapreduce:DescribeEditor",
                "elasticmapreduce:DescribeJobFlows",
                "elasticmapreduce:DescribeSecurityConfiguration",
                "elasticmapreduce:DescribeStep",
                "elasticmapreduce:DescribeReleaseLabel",
                "elasticmapreduce:GetBlockPublicAccessConfiguration",
                "elasticmapreduce:GetManagedScalingPolicy",
                "elasticmapreduce:GetAutoTerminationPolicy",
                "elasticmapreduce:ListBootstrapActions",
                "elasticmapreduce:ListClusters",
                "elasticmapreduce:ListEditors",
                "elasticmapreduce:ListInstanceFleets",
                "elasticmapreduce:ListInstanceGroups",
                "elasticmapreduce:ListInstances",
                "elasticmapreduce:ListSecurityConfigurations",
                "elasticmapreduce:ListSteps",
                "elasticmapreduce:ListSupportedInstanceTypes",
                "elasticmapreduce:ViewEventsFromAllClustersInConsole"
            ],
            "Resource": "*"
        },
        {
```

```
            "Sid": "ViewMetricsInEMRConsole",
            "Effect": "Allow",
            "Action": [
                "cloudwatch:GetMetricStatistics"
            ],
            "Resource": "*"
        }
    ]
}
```

Von IAM verwaltete Richtlinie für vollen Zugriff (demnächst veraltet)

Die `AmazonElasticMapReduceReadOnlyAccess`-verwaltete Richtlinie ist demnächst veraltet. Sie können diese Richtlinie nicht anhängen, wenn Sie neue Cluster starten. `AmazonElasticMapReduceReadOnlyAccess` wurde durch die verwaltete Standardrichtlinie `AmazonEMRReadOnlyAccessPolicy_v2` von Amazon EMR ersetzt. Der Inhalt dieser Richtlinienerklärung wird im folgenden Ausschnitt dargestellt. Platzhalterzeichen für das `elasticmapreduce`-Element geben an, dass nur Aktionen, die mit der angegebenen Zeichenfolgen beginnen, zulässig sind. Hinweis: Da diese Richtlinie Aktionen nicht ausdrücklich verweigert, kann dennoch eine andere Richtlinienanweisung verwendet werden, um den Zugriff auf bestimmte Aktionen zu gewähren.

> **Note**
>
> Sie können die Richtlinie auch über den AWS Management Console anzeigen.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:Describe*",
        "elasticmapreduce:List*",
        "elasticmapreduce:ViewEventsFromAllClustersInConsole",
        "s3:GetObject",
        "s3:ListAllMyBuckets",
        "s3:ListBucket",
        "sdb:Select",
        "cloudwatch:GetMetricStatistics"
```

```
      ],
      "Resource": "*"
    }
  ]
}
```

AWS-verwaltete Richtlinien für Amazon EMR

Um Benutzern, Gruppen und Rollen Berechtigungen hinzuzufügen, ist es einfacher, von AWS verwaltete Richtlinien zu verwenden, als selbst Richtlinien zu schreiben. Es erfordert Zeit und Fachwissen, um von Kunden verwaltete IAM-Richtlinien zu erstellen, die Ihrem Team nur die benötigten Berechtigungen bieten. Um schnell loszulegen, können Sie unsere von AWS verwalteten Richtlinien verwenden. Diese Richtlinien decken häufige Anwendungsfälle ab und sind in Ihrem AWS-Konto verfügbar. Weitere Informationen zu verwalteten AWS-Richtlinien finden Sie unter Verwaltete AWS-Richtlinien im IAM-Leitfaden.

AWS-Services pflegen und Aktualisieren von verwalteten AWS-Richtlinien. Die Berechtigungen in von AWS verwalteten Richtlinien können nicht geändert werden. Services fügen einer von AWS verwalteten Richtlinien gelegentlich zusätzliche Berechtigungen hinzu, um neue Features zu unterstützen. Diese Art von Update betrifft alle Identitäten (Benutzer, Gruppen und Rollen), an welche die Richtlinie angehängt ist. Services aktualisieren eine von AWS verwaltete Richtlinie am ehesten, ein neues Feature gestartet wird oder neue Vorgänge verfügbar werden. Services entfernen keine Berechtigungen aus einer von AWS verwalteten Richtlinie, so dass Richtlinien-Aktualisierungen Ihre vorhandenen Berechtigungen nicht beeinträchtigen.

Darüber hinaus unterstützt AWS verwaltete Richtlinien für Auftragsfunktionen, die mehrere Services umfassen. Die von ReadOnlyAccessAWS verwaltete Richtlinie bietet beispielsweise schreibgeschützten Zugriff auf alle AWS-Services und -Ressourcen. Wenn ein Service ein neues Feature startet, fügt AWS schreibgeschützte Berechtigungen für neue Vorgänge und Ressourcen hinzu. Eine Liste und Beschreibungen der Richtlinien für Auftragsfunktionen finden Sie in Verwaltete AWS-Richtlinien für Auftragsfunktionen im IAM-Leitfaden.

Amazon-EMR-Aktualisierungen für AWS-verwaltete Richtlinien

Anzeigen von Details zu Aktualisierungen für AWS-verwaltete Richtlinien für Amazon EMR, seit dieser Service mit der Verfolgung dieser Änderungen begonnen hat. Um automatische Warnungen über Änderungen an dieser Seite zu erhalten, abonnieren Sie den RSS-Feed auf der Amazon EMR-Dokumentverlauf-Seite.

Änderung	Beschreibung	Datum
AmazonEMRFullAccessPolicy_v2 und **AmazonEMRReadOnlyAccessPolicy_v2** – Zur Aktualisierung einer bestehenden Richtlinie	`elasticmapreduce:ListSupportedInstanceTypes` hinzugefügt.	13. Juli 2023
AmazonEMRFullAccessPolicy_v2 und **AmazonEMRReadOnlyAccessPolicy_v2** – Zur Aktualisierung einer bestehenden Richtlinie	`elasticmapreduce:DescribeReleaseLabel` und `elasticmapreduce:GetAutoTerminationPolicy` hinzugefügt.	21. April 2022
AmazonEMRFullAccessPolicy_v2 – Aktualisierung auf eine bestehende Richtlinie	`ec2:DescribeImages` hinzugefügt für Verwenden eines benutzerdefinierten AMI.	15. Februar 2022
Verwaltete Richtlinien von Amazon EMR	Aktualisiert, um die Verwendung vordefinierter Benutzer-Tags zu verdeutlichen. Es wurde ein Abschnitt zur Verwendung der AWS-Konsole zum Starten von Clustern mit verwalteten v2-Richtlinien hinzugefügt.	29. September 2021

Änderung	Beschreibung	Datum
AmazonEMRFullAccessPolicy_v2 – Aktualisierung auf eine bestehende Richtlinie	Die Aktionen `PassRoleForAutoScaling` und `PassRoleForEC2` wurden dahingehend geändert, dass der `StringLike` -Bedingungsoperator entsprechend `"iam:PassedToService":"application-autoscaling.amazonaws.com*"` und `"iam:PassedToService":"ec2.amazonaws.com*"` verwendet wird.	20. Mai 2021
AmazonEMRFullAccessPolicy_v2 – Aktualisierung auf eine bestehende Richtlinie	Ungültige Aktion `s3:ListBuckets` wurde entfernt und durch `s3:ListAllMyBuckets` -Aktion ersetzt. Die Erstellung von serviceverknüpften Rollen (SLR) wurde aktualisiert und ist nun explizit auf die einzige SLR beschränkt, die Amazon EMR mit expliziten Serviceprinzipien hat. Die SLRs, die erstellt werden können, sind genau dieselben wie vor dieser Änderung.	23. März 2021

Änderung	Beschreibung	Datum
AmazonEMRFullAccessPolicy_v2 – Neue Richtlinie.	Amazon EMR hat neue Berechtigungen für den Bereichszugriff auf Ressourcen hinzugefügt und eine Voraussetzung hinzugefügt, dass Benutzer Ressourcen vordefinierte Benutzer-Tags hinzufügen müssen, bevor sie von Amazon EMR verwaltete Richtlinien verwenden können. `iam:PassRole` - Aktion erfordert, dass die `iam:PassedToService` - Bedingung auf den angegebenen Service gesetzt ist. Der Zugriff auf Amazon EC2, Amazon S3 und andere Services ist standardmäßig nicht zulässig.	11. März 2021
AmazonEMRServicePolicy_v2 – Neue Richtlinie.	Fügt die Voraussetzung hinzu, dass Benutzer Benutzer-Tags zu Ressourcen hinzufügen müssen, bevor sie diese Richtlinie verwenden können.	11. März 2021
AmazonEMRReadOnlyAccessPolicy_v2 – Neue Richtlinie.	Mit Berechtigungen können nur bestimmte schreibgeschützte ElasticMapReduce-Aktionen ausgeführt werden. Der Zugriff auf Amazon S3 ist standardmäßig nicht zulässig.	11. März 2021

Änderung	Beschreibung	Datum
Amazon EMR hat mit der Nachverfolgung von Änderungen begonnen	Amazon EMR hat mit der Nachverfolgung von Änderungen für seine AWS-verwaltete Richtlinien begonnen.	11. März 2021

IAM-Richtlinien für Tag-basierten Zugriff auf Cluster und EMR-Notebooks

Sie können in Ihrer identitätsbasierten Richtlinie auf Tags basierende Bedingungen zum Steuern des Zugriffs auf Cluster und EMR-Notebooks verwenden.

Weitere Informationen zum Hinzufügen von Tags zu Clustern finden Sie unter Tagging EMR Clusters.

Die folgenden Beispiele zeigen verschiedene Szenarien und Möglichkeiten zur Nutzung der Bedingungsoperatoren mit Amazon-EMR-Bedingungskontextschlüsseln. Diese IAM-Richtlinienanweisungen dienen nur zu Demonstrationszwecken und sollten nicht in Produktionsumgebungen verwendet werden. Es gibt mehrere Möglichkeiten für die Kombination von Richtlinienanweisungen zum Gewähren oder Verweigern von Berechtigungen entsprechend Ihren Anforderungen. Weitere Informationen zum Planen und Testen von IAM-Richtlinien finden Sie im IAM-Benutzerhandbuch.

> **Important**
>
> Das explizite Ablehnen von Berechtigungen für Markierungsaktionen stellt eine wichtige Überlegung dar. Dadurch wird verhindert, dass Benutzer eine Ressource markieren und sich dadurch selbst Berechtigungen erteilen, die Sie nicht gewähren wollten. Wenn Sie Tagging-Aktionen für eine Ressource nicht verweigern, kann ein Benutzer Tags ändern und die Absicht der tagbasierten Richtlinien umgehen.

Beispiel identitätsbasierter Richtlinienanweisungen für Cluster

Die folgenden Beispiele zeigen identitätsbasierte Berechtigungsrichtlinien, die verwendet werden, um die Aktionen zu steuern, die mit EMR-Clustern zulässig sind.

> **Important**
>
> Für die `ModifyInstanceGroup`-Aktion in Amazon EMR müssen Sie keine Cluster-ID angeben. Aus diesem Grund sind zusätzliche Überlegungen erforderlich, um diese Aktion auf der Grundlage von Cluster-Tags abzulehnen. Weitere Informationen finden Sie unter Die ModifyInstanceGroup-Aktion wird verweigert.

Themen

- Zulassen von Aktionen nur für Cluster mit bestimmten Tag-Werten
- Erfordert Cluster-Tagging, wenn ein Cluster erstellt wird
- Aktionen für Cluster mit einem bestimmten Tag zulassen, unabhängig vom Tag-Wert

Zulassen von Aktionen nur für Cluster mit bestimmten Tag-Werten

Die folgenden Beispiele veranschaulichen eine Richtlinie, mit der ein Benutzer Aktionen auf der Grundlage des Cluster-Tags *`department`* mit dem Wert *`dev`* durchführen, sowie Cluster mit demselben Tag markieren kann. Das letzte Richtlinienbeispiel zeigt, wie Sie Rechte zum Markieren von EMR-Clustern mit etwas anderem als demselben Tag ablehnen.

Im folgenden Richtlinienbeispiel versucht der `StringEquals`-Bedingungsoperator, *`dev`* und den Wert für das Tag *`department`* abzugleichen. Wenn das Tag *`department`* dem Cluster nicht hinzugefügt wurde oder den Wert *`dev`* nicht enthält, ist die Richtlinie nicht anzuwenden und die Aktionen werden von dieser Richtlinie nicht zugelassen. Wenn keine anderen Richtlinienanweisungen die Aktionen zulassen, kann der Benutzer nur mit Clustern arbeiten, die dieses Tag mit diesem Wert enthalten.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "Stmt12345678901234",
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:DescribeCluster",
        "elasticmapreduce:ListSteps",
        "elasticmapreduce:TerminateJobFlows",
        "elasticmapreduce:SetTerminationProtection",
        "elasticmapreduce:ListInstances",
```

```
        "elasticmapreduce:ListInstanceGroups",
        "elasticmapreduce:ListBootstrapActions",
        "elasticmapreduce:DescribeStep"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
          "elasticmapreduce:ResourceTag/department": "dev"
        }
      }
    }
  ]
}
```

Sie können auch mehrere Tag-Werte mithilfe eines Bedingungsoperators angeben. Um beispielsweise alle Aktionen in Clustern zuzulassen, in denen das Tag *department* den Wert *dev* oder *test* enthält können Sie den Bedingungsblock im vorherigen Beispiel durch Folgendes ersetzen.

```
            "Condition": {
              "StringEquals": {
                "elasticmapreduce:ResourceTag/department":["dev", "test"]
              }
            }
```

Erfordert Cluster-Tagging, wenn ein Cluster erstellt wird

Wie im oben stehenden Beispiel sucht die folgenden Beispielrichtlinie dasselbe übereinstimmende Tag: den Wert *dev* für das Tag *department*. In diesem Beispiel gibt der `RequestTag`-Bedingungsschlüssel jedoch an, dass die Richtlinie während der Tag-Erstellung gilt. Sie müssen also einen Cluster mit einem Tag erstellen, der dem angegebenen Wert entspricht.

Um einen Cluster mit einem Tag zu erstellen, benötigen Sie auch die Erlaubnis für die `elasticmapredue:AddTags`-Aktion. Bei dieser Anweisung stellt der `elasticmapreduce:ResourceTag` Bedingungsschlüssel sicher, dass IAM nur Zugriff auf Tag-Ressourcen gewährt, deren Wert *dev* auf dem *department* Tag steht. Das `Resource`-Element wird verwendet, um diese Berechtigung auf Clusterressourcen zu beschränken.

Für die `PassRole`-Ressourcen müssen Sie die AWS-Konto-ID oder den Alias, den Namen der Servicerolle in der `PassRoleForEMR`-Anweisung und den Namen des Instance-Profils in der `PassRoleForEC2`-Anweisung angeben. Weitere Informationen zu ARNs finden Sie unter IAM-ARNs im IAM-Benutzerhandbuch.

Weitere Informationen zum Abgleichen von Tag-Schlüsselwerten finden Sie unter `aws:RequestTag/tag-key` im IAM-Benutzerhandbuch.

```
{
    "Version": "2012-10-17",
    "Statement": [
      {
        "Sid": "RunJobFlowExplicitlyWithTag",
        "Effect": "Allow",
        "Action": [
          "elasticmapreduce:RunJobFlow"
        ],
        "Resource": "*",
        "Condition": {
          "StringEquals": {
            "aws:RequestTag/department": "dev"
          }
        }
      },
      {
        "Sid": "AddTagsForDevClusters",
        "Effect": "Allow",
        "Action": "elasticmapreduce:AddTags",
        "Resource": "arn:aws:elasticmapreduce:*:*:cluster/*",
        "Condition": {
          "StringEquals": {
            "elasticmapreduce:ResourceTag/department": "dev"
          }
        }
      },
      {
        "Sid": "PassRoleForEMR",
        "Effect": "Allow",
        "Action": "iam:PassRole",
        "Resource": "arn:aws:iam::AccountId:role/Role-Name-With-Path",
        "Condition": {
          "StringLike": {
            "iam:PassedToService": "elasticmapreduce.amazonaws.com*"
```

```
          }
        }
      },
      {
        "Sid": "PassRoleForEC2",
        "Effect": "Allow",
        "Action": "iam:PassRole",
        "Resource": "arn:aws:iam::AccountId:role/Role-Name-With-Path",
        "Condition": {
          "StringLike": {
            "iam:PassedToService": "ec2.amazonaws.com*"
          }
        }
      }
    ]
}
```

Aktionen für Cluster mit einem bestimmten Tag zulassen, unabhängig vom Tag-Wert

Sie können auch Aktionen nur für Cluster mit einem bestimmten Tag, unabhängig vom Tag-Wert, zulassen. Dazu können Sie den `Null`-Operator verwenden. Weitere Informationen finden Sie unter Bedingungsoperator zum Überprüfen der Existenz von Bedingungsschlüsseln im IAM-Benutzerhandbuch. Um beispielsweise Aktionen nur in EMR-Clustern mit dem Tag *`department`* unabhängig von dem enthaltenen Wert, zuzulassen, können Sie die Bedingungsblöcke im vorherigen Beispiel durch Folgendes ersetzen. Der `Null`-Operator sucht einem vorhandenen *`department`*-Tag in einem EMR-Cluster. Wenn das Tag vorhanden ist, wird die Anweisung `Null` entsprechend der in dieser Richtlinienanweisung angegebenen Bedingung mit "false" ausgewertet und die jeweiligen Aktionen werden zugelassen.

```
"Condition": {
  "Null": {
    "elasticmapreduce:ResourceTag/department":"false"
  }
}
```

Mit der folgenden Richtlinienanweisung kann ein Benutzer einen EMR-Cluster nur erstellen, wenn der Cluster über ein *`department`*-Tag mit einem beliebigen Wert verfügt. Für die `PassRole`-Ressource müssen Sie die AWS-Konto-ID oder den Alias und den Namen der Servicerolle angeben. Weitere Informationen zu ARNs finden Sie unter IAM-ARNs im IAM-Benutzerhandbuch.

Weitere Informationen finden Sie unter Bedingungsoperator zum Überprüfen der Existenz von Bedingungsschlüsseln im IAM-Benutzerhandbuch.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "CreateClusterTagNullCondition",
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:RunJobFlow"
            ],
            "Resource": [
                "*"
            ],
            "Condition": {
                "Null": {
                    "aws:RequestTag/department": "false"
                }
            }
        },
        {
            "Sid": "AddTagsNullCondition",
            "Effect": "Allow",
            "Action": "elasticmapreduce:AddTags",
            "Resource": "arn:aws:elasticmapreduce:*:*:cluster/*",
            "Condition": {
                "Null": {
                    "elasticmapreduce:ResourceTag/department": "false"
                }
            }
        },
        {
            "Sid": "PassRoleForElasticMapReduce",
            "Effect": "Allow",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::AccountId:role/Role-Name-With-Path",
            "Condition": {
                "StringLike": {
                    "iam:PassedToService": "elasticmapreduce.amazonaws.com*"
                }
            }
        },
```

```
        {
            "Sid": "PassRoleForEC2",
            "Effect": "Allow",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::AccountId:role/Role-Name-With-Path",
            "Condition": {
                "StringLike": {
                    "iam:PassedToService": "ec2.amazonaws.com*"
                }
            }
        }
    ]
}
```

Beispielhafte identitätsbasierte Richtlinienanweisungen für EMR Notebooks

Die IAM-Beispiel-Richtlinienanweisungen in diesem Abschnitt zeigen häufige Szenarien für die Verwendung von Schlüsseln, um zulässige Aktionen mit EMR Notebooks zu beschränken. Solange keine andere mit dem Prinzipal (Benutzer) verknüpfte Richtlinie die Aktionen zulässt, schränken die Bedingungskontextschlüssel die zulässigen Aktionen wie angegeben ein.

Example – Erlaubt nur den Zugriff auf EMR Notebooks, die ein Benutzer auf der Grundlage von Tagging erstellt

Wenn die folgende Beispiel-Richtlinienanweisung an eine Rolle oder einen Benutzer angefügt wird, können Benutzer nur mit Notebooks arbeiten, die sie selbst erstellt haben. Diese Richtlinienanweisung verwendet das bei der Erstellung eines Notebooks angewendete Standard-Tag.

In diesem Beispiel versucht der Bedingungsoperator `StringEquals`, eine Variable, die die Benutzer-ID (`{aws:userId}`) des aktuellen Benutzers darstellt, dem Wert des Tags `creatorUserID` zuzuordnen. Wenn das Tag `creatorUserID` nicht zum Notebook hinzugefügt wurde oder den Wert der ID des aktuellen Benutzers nicht enthält, ist die Richtlinie nicht anzuwenden und die Aktionen werden von dieser Richtlinie nicht zugelassen. Wenn keine anderen Richtlinienanweisungen die Aktionen zulassen, kann der Benutzer nur mit Notebooks arbeiten, die dieses Tag mit diesem Wert enthalten.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
```

```
                "elasticmapreduce:DescribeEditor",
                "elasticmapreduce:StartEditor",
                "elasticmapreduce:StopEditor",
                "elasticmapreduce:DeleteEditor",
                "elasticmapreduce:OpenEditorInConsole"
            ],
            "Effect": "Allow",
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/creatorUserId": "${aws:userId}"
                }
            }
        }
    ]
}
```

Example – Notebook-Tagging anfordern, wenn ein Notebook erstellt wird

In diesem Beispiel wird der Kontextschlüssel `RequestTag` verwendet. Die Aktion `CreateEditor` ist nur dann zulässig, wenn der Benutzer das `creatorUserID` Tag, das standardmäßig hinzugefügt wird, nicht ändert oder löscht. Die Variable ${aws:userId} gibt die Benutzer-ID des aktuell aktiven Benutzers an. Dies ist der Standardwert des Tags.

Die Richtlinienanweisung kann verwendet werden, um sicherzustellen, dass Benutzer das Tag `createUserId` nicht entfernen und dessen Wert nicht ändern.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:CreateEditor"
            ],
            "Effect": "Allow",
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:RequestTag/creatorUserId": "${aws:userid}"
                }
            }
        }
    ]
```

```
}
```

Dieses Beispiel erfordert, dass der Benutzer den Cluster mit einem Tag mit der Schlüsselzeichenfolge `dept` und einem der folgenden Werte erstellt: `datascience`, `analytics`, `operations`.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:CreateEditor"
            ],
            "Effect": "Allow",
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:RequestTag/dept": [
                        "datascience",
                        "analytics",
                        "operations"
                    ]
                }
            }
        }
    ]
}
```

Example – Die Notebook-Erstellung auf getaggte Cluster beschränken und Notebook-Tags anfordern

Dieses Beispiel erlaubt die Notebook-Erstellung nur, wenn das Notebook mit einem Tag erstellt wird, bei dem die Schlüsselzeichenfolge `owner` auf einen der angegebenen Werte festgelegt ist. Darüber hinaus kann das Notebook nur erstellt werden, wenn der Cluster ein Tag enthält, bei dem die Schlüsselzeichenfolge `department` auf einen der angegebenen Werte festgelegt ist.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:CreateEditor"
            ],
```

```
            "Effect": "Allow",
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:RequestTag/owner": [
                        "owner1",
                        "owner2",
                        "owner3"
                    ],
                    "elasticmapreduce:ResourceTag/department": [
                        "dep1",
                        "dep3"
                    ]
                }
            }
        }
    ]
}
```

Example – Basierend auf Tags die Möglichkeit einschränken, ein Notebook zu starten

Dieses Beispiel schränkt die Möglichkeit, ein Notebook zu starten, auf Notebooks ein, die ein Tag enthalten, bei dem die Schlüsselzeichenfolge `owner` auf einen der angegebenen Werte festgelegt ist. Da das Element `Resource` verwendet wird, um nur den `editor` anzugeben, gilt die Bedingung nicht für den Cluster und ein Tagging ist nicht erforderlich.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:StartEditor"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:editor/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/owner": [
                        "owner1",
                        "owner2"
                    ]
                }
            }
```

```
        }
    ]
}
```

Dieses Beispiel ähnelt dem obigen. Die Einschränkung gilt hier jedoch nur für getaggte Cluster, nicht für Notebooks.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:StartEditor"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:cluster/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/department": [
                        "dep1",
                        "dep3"
                    ]
                }
            }
        }
    ]
}
```

Dieses Beispiel verwendet andere Notebook- und Cluster-Tags. Es ermöglicht das Starten eines Notebooks nur, wenn Folgendes zutrifft:

- Das Notebook enthält ein Tag, bei dem die Schlüsselzeichenfolge `owner` auf einen der angegebenen Wert festgelegt ist.

  – und –

- Der Cluster enthält ein Tag, bei dem die Schlüsselzeichenfolge `department` auf einen der angegebenen Wert festgelegt ist.

```
{
    "Version": "2012-10-17",
    "Statement": [
```

```
        {
            "Action": [
                "elasticmapreduce:StartEditor"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:editor/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/owner": [
                        "user1",
                        "user2"
                    ]
                }
            }
        },
        {
            "Action": [
                "elasticmapreduce:StartEditor"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:cluster/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/department": [
                        "datascience",
                        "analytics"
                    ]
                }
            }
        }
    ]
}
```

Example – Basierend auf Tags die Möglichkeit einschränken, den Notebook-Editor zu öffnen

In diesem Beispiel kann der Notebook-Editor nur geöffnet werden, wenn Folgendes zutrifft:

- Das Notebook enthält ein Tag, bei dem die Schlüsselzeichenfolge `owner` auf einen der angegebenen Wert festgelegt ist.

  – und –

- Der Cluster enthält ein Tag, bei dem die Schlüsselzeichenfolge `department` auf einen der angegebenen Wert festgelegt ist.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:OpenEditorInConsole"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:editor/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/owner": [
                        "user1",
                        "user2"
                    ]
                }
            }
        },
        {
            "Action": [
                "elasticmapreduce:OpenEditorInConsole"
            ],
            "Effect": "Allow",
            "Resource": "arn:aws:elasticmapreduce:*:123456789012:cluster/*",
            "Condition": {
                "StringEquals": {
                    "elasticmapreduce:ResourceTag/department": [
                        "datascience",
                        "analytics"
                    ]
                }
            }
        }
    ]
}
```

Die ModifyInstanceGroup-Aktion wird verweigert

Für die Aktion ModifyInstanceGroups in Amazon EMR müssen Sie bei der Aktion keine Cluster-ID angeben. Stattdessen können Sie nur eine Instance-Gruppen-ID angeben. Aus diesem Grund hat eine scheinbar einfache Ablehnungsrichtlinie für diese Aktion, die auf der Cluster-ID oder einem

Cluster-Tag basiert, möglicherweise nicht die beabsichtigte Wirkung. Betrachten Sie die folgende Beispielrichtlinie.

```
{
 "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Effect": "Allow",
            "Resource": "*"
        },
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Effect": "Deny",
            "Resource": "arn:aws:elasticmapreduce:us-east-1:123456789012:cluster/
j-12345ABCDEFG67"
        }
    ]

}
```

Wenn ein Benutzer, dem diese Richtlinie zugewiesen ist, eine `ModifyInstanceGroup`-Aktion ausführt und nur die Instance-Gruppen-ID angibt, gilt die Richtlinie nicht. Da die Aktion für alle anderen Ressourcen zulässig ist, ist die Aktion erfolgreich.

Eine Lösung für dieses Problem besteht darin, der Identität eine Richtlinienanweisung anzuhängen, die ein NotResource-Element verwendet, um jede `ModifyInstanceGroup`-Aktion zu verweigern, die ohne Cluster-ID ausgeführt wurde. Die folgende Beispielrichtlinie fügt eine solche Deny-Anweisung hinzu, sodass jede `ModifyInstanceGroups`-Anfrage fehlschlägt, sofern keine Cluster-ID angegeben ist. Da eine Identität bei der Aktion eine Cluster-ID angeben muss, sind Ablehnungsbefehle, die auf der Cluster-ID basieren, daher wirksam.

```
{
 "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
```

```
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Effect": "Allow",
            "Resource": "*"
        },
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Effect": "Deny",
            "Resource": "arn:aws:elasticmapreduce:us-east-1:123456789012:cluster/
j-12345ABCDEFG67"
        },
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Effect": "Deny",
            "NotResource": "arn:*:elasticmapreduce:*:*:cluster/*"
        }
    ]

}
```

Ein ähnliches Problem tritt auf, wenn Sie die `ModifyInstanceGroups`-Aktion auf der Grundlage des mit einem Cluster-Tag verknüpften Werts ablehnen möchten. Die Lösung ist ähnlich. Zusätzlich zu einer Ablehnungs-Anweisung, die den Tag-Wert angibt, können Sie eine Richtlinienanweisung hinzufügen, die die `ModifyInstanceGroup`-Aktion ablehnt, wenn das von Ihnen angegebene Tag nicht vorhanden ist, unabhängig vom Wert.

Das folgende Beispiel zeigt eine Richtlinie, die, wenn sie an eine Identität angehängt ist, der Identität die `ModifyInstanceGroups`-Aktion aller Cluster verweigert, bei denen das Tag `department` auf `dev` gesetzt ist. Diese Anweisung ist nur aufgrund der Ablehnungs-Anweisung wirksam, die die `StringNotLike`-Bedingung verwendet, um die Aktion zu verweigern, sofern das `department`-Tag nicht vorhanden ist.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
```

```
            ],
            "Effect": "Allow",
            "Resource": "*"
        },
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Condition": {
                "StringEquals": {
                    "aws:ResourceTag/department": "dev"
                }
            },
            "Effect": "Deny",
            "Resource": "*"
        },
        {
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups"
            ],
            "Condition": {
                "StringNotLike": {
                    "aws:ResourceTag/department": "?*"
                }
            },
            "Effect": "Deny",
            "Resource": "*"
        }
    ],
}
```

Fehlerbehebung für Amazon-EMR-Identität und -Zugriff

Diagnostizieren und beheben Sie mithilfe der folgenden Informationen gängige Probleme, die bei der Verwendung von Amazon EMR und IAM auftreten können.

Themen

- Ich bin nicht autorisiert, eine Aktion in Amazon EMR auszuführen
- Ich bin nicht zur Ausführung von iam:PassRole autorisiert
- Ich möchte Personen außerhalb meines AWS-Kontos Zugriff auf meine Amazon-EMR-Ressourcen erteilen

Ich bin nicht autorisiert, eine Aktion in Amazon EMR auszuführen

Wenn die AWS Management Console Ihnen mitteilt, dass Sie nicht zur Ausführung einer Aktion autorisiert sind, müssen Sie sich an Ihren Administrator wenden, um Unterstützung zu erhalten. Ihr Administrator ist die Person, die Ihnen Ihren Benutzernamen und Ihr Passwort bereitgestellt hat.

Der folgende Beispielfehler tritt auf, wenn der `mateojackson`-Benutzer versucht, die Konsole zum Anzeigen von Details zu einer fiktiven *`my-example-widget`*-Ressource zu verwenden, jedoch nicht über `EMR:`*`GetWidget`*-Berechtigungen verfügt.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform:
 EMR:GetWidget on resource: my-example-widget
```

In diesem Fall bittet Mateo seinen Administrator um die Aktualisierung seiner Richtlinien, um unter Verwendung der Aktion *`my-example-widget`* auf die Ressource `EMR:`*`GetWidget`* zugreifen zu können.

Ich bin nicht zur Ausführung von iam:PassRole autorisiert

Wenn Sie die Fehlermeldung erhalten, dass Sie nicht zur Ausführung der Aktion `iam:PassRole` autorisiert sind, müssen Ihre Richtlinien aktualisiert werden, um eine Rolle an Amazon EMR übergeben zu können.

Einige AWS-Services erlauben die Übergabe einer vorhandenen Rolle an diesen Service, sodass keine neue Servicerolle oder serviceverknüpfte Rolle erstellt werden muss. Hierzu benötigen Sie Berechtigungen für die Übergabe der Rolle an den Service.

Der folgende Beispielfehler tritt auf, wenn ein IAM-Benutzer mit dem Namen `marymajor` versucht, die Konsole zu verwenden, um eine Aktion in Amazon EMR auszuführen. Die Aktion erfordert jedoch, dass der Service über Berechtigungen verfügt, die durch eine Servicerolle gewährt werden. Mary besitzt keine Berechtigungen für die Übergabe der Rolle an den Service.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform:
 iam:PassRole
```

In diesem Fall müssen die Richtlinien von Mary aktualisiert werden, um die Aktion `iam:PassRole` ausführen zu können.

Wenden Sie sich an Ihren AWS-Administrator, falls Sie weitere Unterstützung benötigen. Ihr Administrator hat Ihnen Ihre Anmeldeinformationen zur Verfügung gestellt.

Ich möchte Personen außerhalb meines AWS-Kontos Zugriff auf meine Amazon-EMR-Ressourcen erteilen

Sie können eine Rolle erstellen, die Benutzer in anderen Konten oder Personen außerhalb Ihrer Organisation für den Zugriff auf Ihre Ressourcen verwenden können. Sie können festlegen, wem die Übernahme der Rolle anvertraut wird. Im Fall von Services, die ressourcenbasierte Richtlinien oder Zugriffskontrolllisten (Access Control Lists, ACLs) verwenden, können Sie diese Richtlinien verwenden, um Personen Zugriff auf Ihre Ressourcen zu gewähren.

Weitere Informationen dazu finden Sie hier:

- Informationen dazu, ob Amazon EMR diese Features unterstützt, finden Sie unter Funktionsweise von Amazon EMR mit IAM.
- Informationen zum Gewähren des Zugriffs auf Ihre Ressourcen für alle Ihre AWS-Konten finden Sie unter Gewähren des Zugriffs für einen IAM-Benutzer in einem anderen Ihrer AWS-Konto im IAM-Benutzerhandbuch.
- Informationen dazu, wie Sie AWS-Konten-Drittanbieter Zugriff auf Ihre Ressourcen bereitstellen, finden Sie unter Gewähren des Zugriffs auf AWS-Konten von externen Benutzern im IAM-Benutzerhandbuch.
- Informationen dazu, wie Sie über einen Identitätsverbund Zugriff gewähren, finden Sie unter Gewähren von Zugriff für extern authentifizierte Benutzer (Identitätsverbund) im IAM-Benutzerhandbuch.
- Informationen zum Unterschied zwischen der Verwendung von Rollen und ressourcenbasierten Richtlinien für den kontenübergreifenden Zugriff finden Sie unter So unterscheiden sich IAM-Rollen von ressourcenbasierten Richtlinien im IAM-Benutzerhandbuch.

Authentifizieren von Amazon-EMR-Cluster-Knoten

SSH-Clients können mit einem Amazon-EC2-Schlüsselpaar Cluster-Instances authentifizieren. Alternativ können Sie bei Amazon EMR Version 5.10.0 oder höher Kerberos so konfigurieren, dass Benutzer und SSH-Verbindungen gegenüber dem Primärknoten authentifiziert werden. Und mit den Amazon-EMR-Versionen 5.12.0 und höher können Sie sich mit LDAP authentifizieren.

Themen

- Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen
- Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR

- Active-Directory- oder LDAP-Server für die Authentifizierung mit Amazon EMR verwenden

Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen

Amazon-EMR-Clusterknoten werden auf Amazon-EC2-Instances ausgeführt. Sie können mit Cluster-Knoten auf die gleiche Weise eine Verbindung herstellen wie mit Amazon-EC2-Instances. Mit Amazon EC2 können Sie ein Schlüsselpaar erstellen, oder Sie können ein Schlüsselpaar importieren. Wenn Sie einen Cluster erstellen, können Sie das Amazon-EC2-Schlüsselpaar angeben, das für SSH-Verbindungen mit allen Cluster-Instances verwendet wird. Außerdem können Sie auch einen Cluster ohne ein Schlüsselpaar erstellen. Dies geschieht normalerweise mit vorübergehenden Clusters, die starten, gewisse Schritte ausführen und dann automatisch beendet werden.

Der SSH-Client, mit dem Sie sich mit dem Cluster verbinden, benötigt die Datei mit dem privaten Schlüssel, der mit diesem Schlüsselpaar verknüpft ist. Dies ist eine .pem-Datei für SSH-Clients unter Linux, Unix und macOS. Sie müssen die Berechtigungen so festlegen, dass nur der Schlüsselbesitzer berechtigt ist, auf die Datei zuzugreifen. Dies ist eine.ppk-Datei für SSH-Clients mit Windows, und die.ppk-Datei wird in der Regel von der .pem-Datei erstellt.

- Weitere Informationen zum Zugriff auf Ihr Amazon-EC2-Schlüsselpaar finden Sie unter Amazon-EC2-Schlüsselpaare im Benutzerhandbuch von Amazon EC2 für Linux-Instances.
- Weitere Informationen über die Verwendung von PuTTYgen zum Erstellen einer.ppk-Datei aus einer .pem-Datei finden Sie unter Konvertieren Ihres privaten Schlüssels per PuTTYgen im Benutzerhandbuch für Amazon EC2 für Linux-Instances.
- Weitere Informationen zum Einrichten von Berechtigungen für .pem-Dateien und zum Verbinden mit dem Primärknoten eines EMR-Clusters über verschiedene Methoden, einschließlich `ssh` in Linux oder macOS, PuTTY in Windows oder die AWS CLI eines unterstützten Betriebssystems finden Sie unter Mit dem Primärknoten über SSH verbinden.

Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR

Amazon-EMR-Versionen 5.10.0 und höher unterstützen Kerberos. Kerberos ist ein Netzwerkauthentifizierungsprotokoll, das eine Verschlüsselung mit geheimen Schlüsseln verwendet, um eine starke Authentifizierung bereitzustellen, sodass Passwörter oder andere Anmeldeinformationen nicht in einem unverschlüsselten Format über das Netzwerk gesendet werden.

In Kerberos werden Services und Benutzer, die sich authentifizieren müssen, als Prinzipale bezeichnet. Prinzipale befinden sich in einem Kerberos-Bereich. Innerhalb des Bereichs gewährt ein

Kerberos-Server, der als Key Distribution Center (KDC) bezeichnet wird, Prinzipalen die Möglichkeit, sich zu authentifizieren. Dazu stellt das KDC Tickets für die Authentifizierung aus. Das KDC unterhält eine Datenbank der Prinzipale in seinem Bereich, mit ihren Passwörtern und anderen administrativen Informationen zu jedem Prinzipal. Ein KDC kann auch Anmeldeinformationen für die Authentifizierung von Prinzipalen aus anderen Bereichen akzeptieren. Dies wird als bereichsübergreifendes Vertrauen bezeichnet. Darüber hinaus kann ein EMR-Cluster ein externes KDC verwenden, um Prinzipale zu authentifizieren.

Ein gängiges Szenario für die Einrichtung einer bereichsübergreifenden Vertrauensstellung oder für die Verwendung eines externen KDC ist die Authentifizierung von Benutzern von einer Active-Directory-Domain aus. Auf diese Weise können Benutzer mit ihrem Domainkonto auf einen EMR-Cluster zugreifen, wenn sie SSH verwenden, um eine Verbindung zu einem Cluster herzustellen oder mit Big-Data-Anwendungen zu arbeiten.

Bei Verwendung der Kerberos-Authentifizierung konfiguriert Amazon EMR Kerberos für die Anwendungen, Komponenten und Subsysteme, die es auf dem Cluster installiert, damit sie gegenseitig authentifiziert werden.

> **Important**
>
> Amazon EMR unterstützt AWS Directory Service for Microsoft Active Directory in einer bereichsübergreifenden Vertrauensstellung oder als externes KDC nicht.

Bevor Sie Kerberos mit Amazon EMR konfigurieren, empfehlen wir, dass Sie sich über Kerberos-Konzepte, die Services für die Ausführung auf einem KDC und die Tools für die Verwaltung von Kerberos-Services informieren. Weitere Informationen finden Sie in der MIT-Kerberos-Dokumentation, die vom Kerberos Consortium veröffentlicht wird.

Themen

- Unterstützte Anwendungen
- Kerberos-Architektur-Optionen
- Konfiguration von Kerberos in Amazon EMR
- Verwenden von SSH zum Herstellen einer Verbindung mit durch Kerberos geschützten Clustern
- Tutorial: Konfigurieren eines Cluster-spezifischen KDC
- Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain

Unterstützte Anwendungen

In einem EMR-Cluster sind Kerberos-Prinzipale die Big Data-Anwendungsservices und Sub-Systemen, die auf allen Cluster-Knoten ausgeführt werden. Amazon EMR kann die Anwendungen und die unten aufgeführten Komponenten für die Verwendung von Kerberos konfigurieren. Jeder Anwendung ist ein Kerberos-Benutzer-Prinzipal zugeordnet.

Amazon EMR unterstützt kein bereichsübergreifendes Vertrauen für AWS Directory Service for Microsoft Active Directory.

Amazon EMR konfiguriert nur die Open-Source-Authentifizierungsfeatures für Kerberos für die unten aufgelisteten Anwendungen und Komponenten. Alle anderen installierten Anwendungen sind nicht durch Kerberos geschützt. Dies kann zu einer Unfähigkeit der Kommunikation mit durch Kerberos geschützten Komponenten führen und Anwendungsfehler verursachen. Für Anwendungen und Komponenten, die nicht durch Kerberos geschützt sind, ist keine Authentifizierung aktiviert. Die unterstützten Anwendungen und Komponenten können je nach Amazon EMR Versionen variieren.

Die Livy-Benutzeroberfläche ist die einzige Weboberfläche, die auf dem Kerberized Cluster gehostet wird.

- Hadoop MapReduce
- Hbase
- HCatalog
- HDFS
- Hive
  - Aktivieren Sie keine Hive mit LDAP-Authentifizierung. Dies kann Probleme bei der Kommunikation mit durch Kerberos geschütztem YARN verursachen.
- Hue
  - Die Hue-Benutzerauthentifizierung wird nicht automatisch eingerichtet und kann unter Verwendung der Konfigurations-API konfiguriert werden.
  - Der Hue-Server ist durch Kerberos geschützt. Das Hue Front-End (UI) ist nicht für die Authentifizierung konfiguriert. Die LDAP-Authentifizierung kann für die Hue-UI konfiguriert werden.
- Livy
  - Livy-Identitätswechsel mit kerberisierten Clustern wird in Amazon-EMR-Versionen 5.22.0 und höher unterstützt.

- Oozie
- Phoenix
- Presto
  - Presto unterstützt die Kerberos-Authentifizierung in Amazon-EMR-Versionen 6.9.0 und höher.
  - Um die Kerberos-Authentifizierung für Presto zu verwenden, müssen Sie die Verschlüsselung bei der Übertragung aktivieren.
- Spark
- Tez
- Trino
  - Trino unterstützt die Kerberos-Authentifizierung in Amazon-EMR-Versionen 6.11.0 und höher.
  - Um die Kerberos-Authentifizierung für Trino zu verwenden, müssen Sie die Verschlüsselung bei der Übertragung aktivieren.
- YARN
- Zeppelin
  - Zeppelin ist nur mit dem Spark-Interpreter für die Verwendung von Kerberos konfiguriert. Es ist nicht für andere Interpreter konfiguriert.
  - Der Identitätswechsel von Benutzern wird für Kerberized-Zeppelin-Interpreter außer Spark nicht unterstützt.
- Zookeeper
  - Der Zookeeper-Client wird nicht unterstützt.

Kerberos-Architektur-Optionen

Wenn Sie Kerberos mit Amazon EMR verwenden, können Sie aus den in diesem Abschnitt aufgeführten Architekturen wählen. Unabhängig von der gewählten Architektur konfigurieren Sie Kerberos anhand der gleichen Schritte. Sie erstellen eine Sicherheitskonfiguration, legen die Sicherheitskonfiguration und kompatible Cluster-spezifische Kerberos-Optionen fest, wenn Sie den Cluster erstellen. Zudem erstellen Sie HDFS-Verzeichnisse für Linux-Benutzer auf dem Cluster, der den Benutzerprinzipalen auf dem KDC entspricht. Weitere Informationen zu Konfigurationsoptionen und Beispielkonfigurationen für jede Architektur finden Sie unter Konfiguration von Kerberos in Amazon EMR.

Cluster-spezifisches KDC (KDC auf dem Primärknoten)

Diese Konfiguration ist nur mit Amazon-EMR-Versionen 5.10.0 und höher verfügbar.

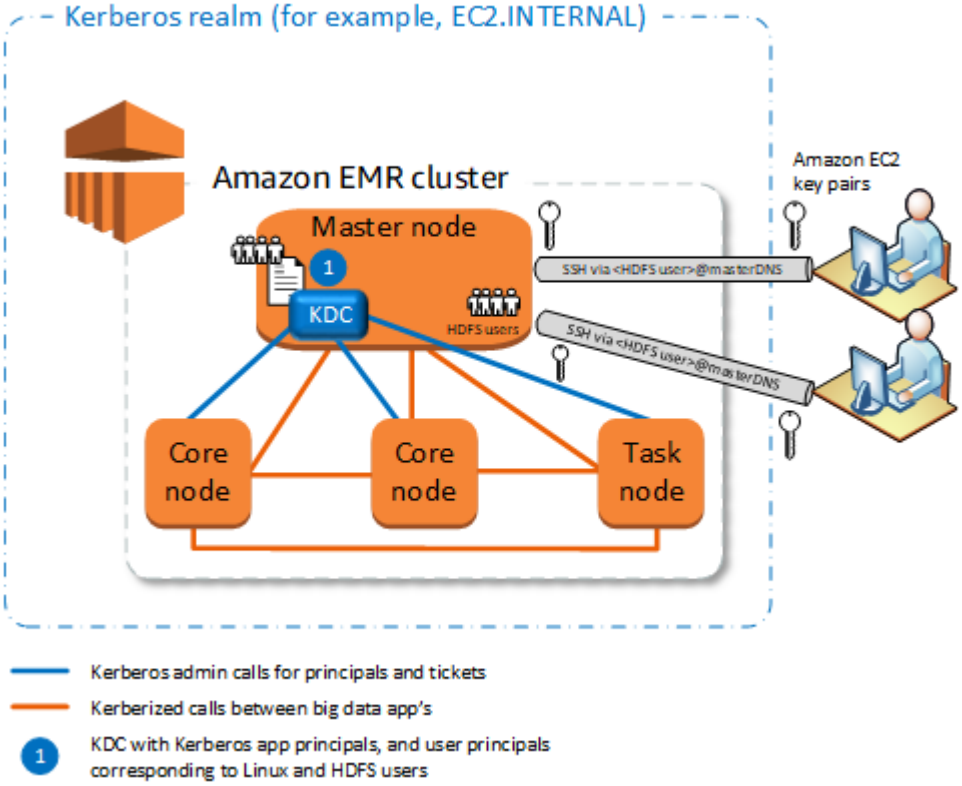

Vorteile

- Amazon EMR ist im vollständigen Besitz des KDC.
- Das KDC auf dem EMR-Cluster ist unabhängig von zentralisierten KDC-Implementierungen wie Microsoft Active Directory oder AWS Managed Microsoft AD.
- Die Auswirkungen auf die Performance sind minimal, da das KDC die Authentifizierung nur für lokale Knoten innerhalb des Clusters verwaltet.
- Optional können andere Kerberos-Cluster auf das KDC als externes KDC verweisen. Weitere Informationen finden Sie unter Externes KDC – Primärknoten auf einem anderen Cluster.

Überlegungen und Einschränkungen

- Kerberos-Cluster können einander nicht authentifizieren, sodass für die Anwendungen keine Interoperabilität besteht. Wenn Cluster-Anwendungen interagieren müssen, müssen Sie eine bereichsübergreifende Vertrauensstellung zwischen Clustern oder einen Cluster als externes KDC

für andere Cluster einrichten. Wenn eine bereichsübergreifende Vertrauensstellung eingerichtet ist, müssen die KDCs unterschiedliche Kerberos-Bereiche aufweisen.

- Erstellen Sie Linux-Benutzer auf der EC2-Instance des Primärknotens, der den KDC-Benutzerprinzipalen entspricht, zusammen mit den HDFS-Verzeichnissen für jeden Benutzer.
- Benutzerprinzipale müssen eine EC2-Datei mit privatem Schlüssel und `kinit`-Anmeldeinformationen verwenden, um mittels SSH eine Verbindung zum Cluster herzustellen.

Bereichsübergreifende Vertrauensstellung

In dieser Konfiguration werden Prinzipale (in der Regel Benutzer) aus einem anderen Kerberos-Bereich an den Anwendungskomponenten auf einem durch Kerberos geschützten EMR-Cluster authentifiziert, der über ein eigenes KDC verfügt. Das KDC auf dem Hauptknoten richtet eine Vertrauensstellung mit einem anderen KDC unter Verwendung eines bereichsübergreifenden Prinzipals ein, der in beiden KDCs existiert. Der Name des Prinzipals und das Passwort stimmen in jedem KDC genau überein. Bereichsübergreifende Vertrauensstellungen kommen am häufigsten in Active Directory-Implementierungen vor, wie in der folgenden Abbildung dargestellt. Bereichsübergreifende Vertrauensstellungen mit einem externen MIT KDC oder einem KDC auf einem anderen Amazon–EMR Cluster werden ebenfalls unterstützt.

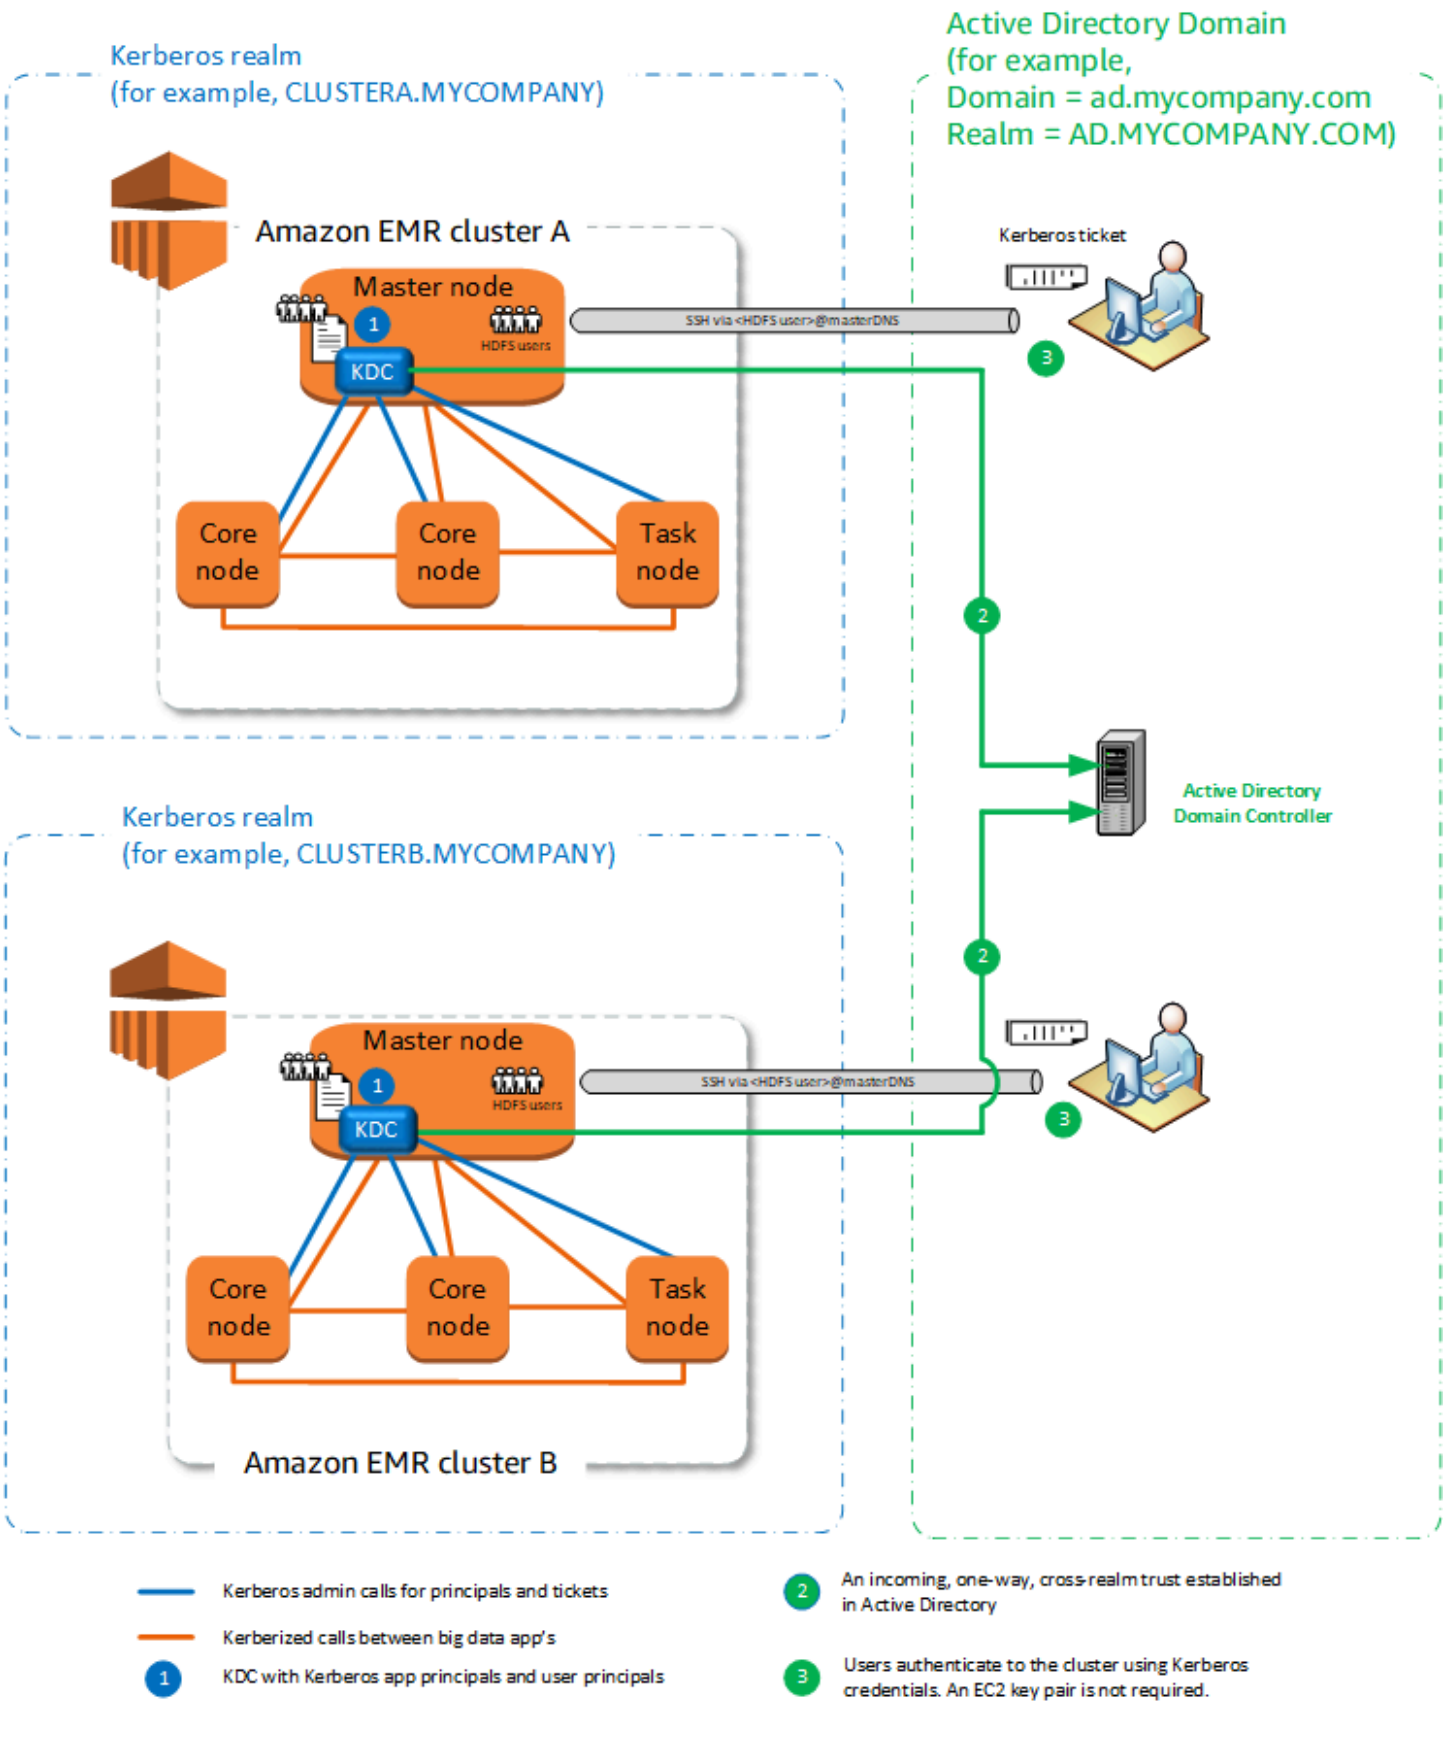
Active Directory Domain
(for example,
Domain = ad.mycompany.com
Realm = AD.MYCOMPANY.COM)
Kerberos realm
(for example, CLUSTERA.MYCOMPANY)
Amazon EMR cluster A
Master node
1
KDC
HDFS users
SSH via <HDFS user>@masterDNS
Kerberos ticket
3
Core node
Core node
Task node
2
Active Directory Domain Controller
Kerberos realm
(for example, CLUSTERB.MYCOMPANY)
Master node
1
KDC
HDFS users
SSH via <HDFS user>@masterDNS
2
3
Core node
Core node
Task node
Amazon EMR cluster B
Kerberos admin calls for principals and tickets
Kerberized calls between big data app's
1
KDC with Kerberos app principals and user principals
2
An incoming, one-way, cross-realm trust established in Active Directory
3
Users authenticate to the cluster using Kerberos credentials. An EC2 key pair is not required.

Vorteile

- Der EMR-Cluster, auf dem das KDC installiert ist, ist im vollständigen Besitz des KDC.
- Mit Active Directory erstellt Amazon EMR automatisch Linux-Benutzer, die Benutzerprinzipalen aus dem KDC entsprechen. Sie müssen dennoch für jeden Benutzer HDFS-Verzeichnisse erstellen. Darüber hinaus können Benutzerprinzipale in der Active-Directory-Domain mit `kinit`-Anmeldeinformationen durch Kerberos geschützte Cluster ohne die EC2-Datei mit privatem Schlüssel aufrufen. Dies beseitigt die Notwendigkeit, die Datei mit dem privaten Schlüssel für die Cluster-Benutzer freizugeben.
- Da jedes Cluster-KDC die Authentifizierung für die Knoten im Cluster verwaltet, werden die Auswirkungen der Netzwerklatenz und des Verwaltungsaufwands für eine große Anzahl an Knoten in Clustern minimiert.

Überlegungen und Einschränkungen

- Wenn Sie eine Vertrauensstellung mit einem Active-Directory-Bereich einrichten, müssen Sie beim Erstellen des Clusters Active Directory-Benutzername und -Passwort mit Berechtigungen zum Hinzufügen von Prinzipalen zur Domain angeben.
- Bereichsübergreifende Vertrauensstellungen können nicht zwischen Kerberos-Bereichen mit demselben Namen eingerichtet werden.
- Bereichsübergreifende Vertrauensstellungen müssen explizit eingerichtet werden. Beispiel: Wenn Cluster A und Cluster B eine bereichsübergreifende Vertrauensstellung mit einem KDC einrichten, vertrauen diese einander nicht inhärent und ihre Anwendungen können einander nicht authentifizieren, um miteinander zu interagieren.
- KDCs müssen unabhängig voneinander verwaltet und koordiniert werden, damit die Anmeldeinformationen von Benutzerprinzipalen genau übereinstimmen.

Externes KDC

Konfigurationen mit einem externen KDC werden mit Amazon EMR 5.20.0 und höher unterstützt.

- Externes KDC – MIT KDC
- Externes KDC – Primärknoten auf einem anderen Cluster
- Externes KDC – Cluster-KDC mit anderer bereichsübergreifender Active-Directory-Vertrauensstellung

Externes KDC – MIT KDC

Diese Konfiguration ermöglicht mindestens einem EMR-Cluster die Verwendung von Prinzipalen, die in einem MIT KDC-Server definiert und verwaltet werden.

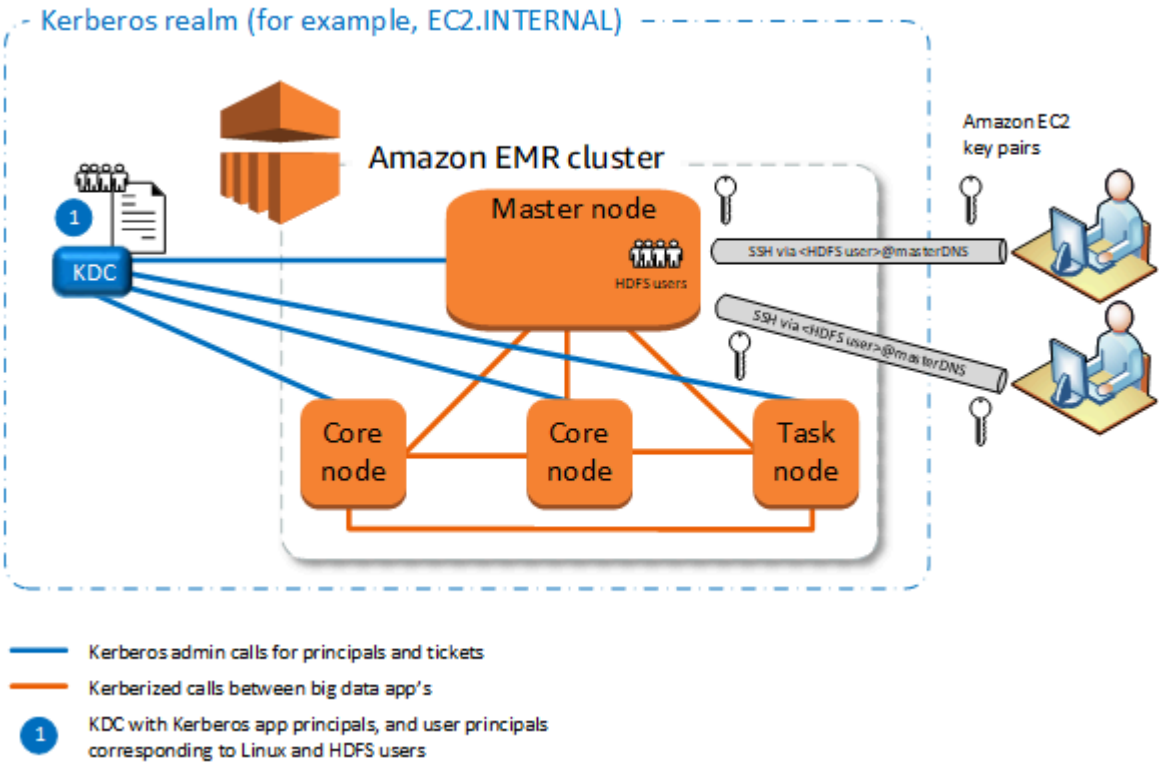

Vorteile

- Die Verwaltung von Prinzipalen ist in einem einzigen KDC zusammengefasst.
- Mehrere Cluster können dasselbe KDC im selben Kerberos-Bereich verwenden. Weitere Informationen finden Sie unter Anforderungen für die Verwendung mehrerer Cluster mit demselben KDC.
- Der Primärknoten auf einem durch Kerberos geschützten Cluster hat nicht die Performance-Einbußen zu verzeichnen wie der Unterhalt des KDC.

Überlegungen und Einschränkungen

- Erstellen Sie Linux-Benutzer auf der EC2-Instance des Primärknotens vom allen durch Kerberos geschützten Clustern, die den KDC-Benutzerprinzipalen entsprechen, zusammen mit den HDFS-Verzeichnissen für jeden Benutzer.

- Benutzerprinzipale müssen eine EC2-Datei mit privatem Schlüssel und `kinit`-Anmeldeinformationen verwenden, um mittels SSH eine Verbindung zu den durch Kerberos geschützten Clustern herzustellen.
- Jeder Knoten in durch Kerberos geschützten EMR-Clustern muss über eine Netzwerkroute zum KDC verfügen.
- Jeder -Knoten in durch Kerberos geschützten Clustern platziert auf dem externen KDC eine Authentifizierungshürde, sodass die Konfiguration des KDC sich auf die Cluster-Performance auswirkt. Berücksichtigen Sie bei der Konfiguration der Hardware des KDC-Servers die maximale Anzahl der Amazon-EMR-Knoten, die gleichzeitig unterstützt werden können.
- Die Cluster-Performance hängt von der Netzwerklatenz zwischen Knoten in durch Kerberos geschützten Clustern und dem KDC ab.
- Die Fehlerbehebung kann sich aufgrund von Abhängigkeiten untereinander schwieriger gestalten.

Externes KDC – Primärknoten auf einem anderen Cluster

Diese Konfiguration ist nahezu identisch mit der oben erwähnten externen MIT KDC-Implementierung, mit der Ausnahme, dass sich das KDC auf dem Primärknoten eines EMR-Clusters befindet. Weitere Informationen finden Sie unter Cluster-spezifisches KDC (KDC auf dem Primärknoten) und Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.

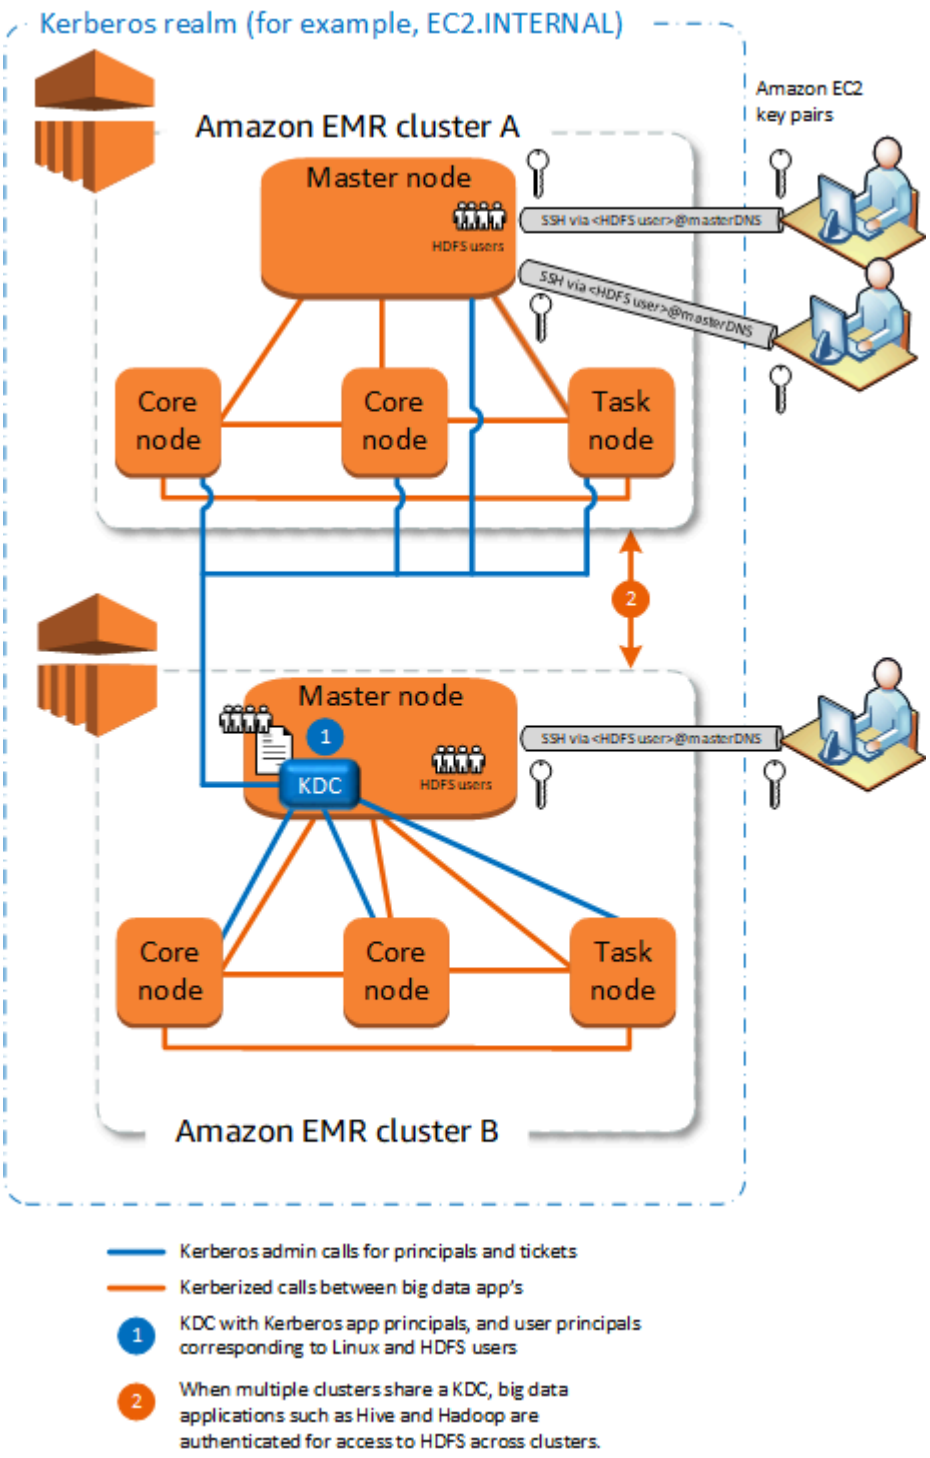

Vorteile

- Die Verwaltung von Prinzipalen ist in einem einzigen KDC zusammengefasst.

- Mehrere Cluster können dasselbe KDC im selben Kerberos-Bereich verwenden. Weitere Informationen finden Sie unter Anforderungen für die Verwendung mehrerer Cluster mit demselben KDC.

Überlegungen und Einschränkungen

- Erstellen Sie Linux-Benutzer auf der EC2-Instance des Primärknotens vom allen durch Kerberos geschützten Clustern, die den KDC-Benutzerprinzipalen entsprechen, zusammen mit den HDFS-Verzeichnissen für jeden Benutzer.
- Benutzerprinzipale müssen eine EC2-Datei mit privatem Schlüssel und `kinit`-Anmeldeinformationen verwenden, um mittels SSH eine Verbindung zu den durch Kerberos geschützten Clustern herzustellen.
- Jeder Knoten in jedem EMR-Cluster muss über eine Netzwerkroute zum KDC verfügen.
- Jeder Amazon EMR-Knoten in durch Kerberos geschützten Clustern platziert auf dem externen KDC eine Authentifizierungshürde, sodass die Konfiguration des KDC sich auf die Cluster-Performance auswirkt. Berücksichtigen Sie bei der Konfiguration der Hardware des KDC-Servers die maximale Anzahl der Amazon-EMR-Knoten, die gleichzeitig unterstützt werden können.
- Die Cluster-Performance hängt von der Netzwerklatenz zwischen Knoten in den Clustern und dem KDC ab.
- Die Fehlerbehebung kann sich aufgrund von Abhängigkeiten untereinander schwieriger gestalten.

Externes KDC – Cluster-KDC mit anderer bereichsübergreifender Active-Directory-Vertrauensstellung

Bei dieser Konfiguration erstellen Sie zunächst einen Cluster mit einem Cluster-spezifischen KDC, das eine unidirektionale bereichsübergreifende Vertrauensstellung mit Active Directory aufweist. Ein detailliertes Tutorial finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain. Anschließend starten Sie zusätzliche Cluster, die auf das Cluster-KDC verweisen, das die Vertrauensstellung als externes KDC besitzt. Ein Beispiel finden Sie unter Externes Cluster-KDC mit bereichsübergreifender Active-Directory-Vertrauensstellung. Auf diese Weise können Sie jedem Amazon EMR-Cluster, der das externe KDC verwendet, die Authentifizierung von Prinzipalen erlauben, die in einer Domain von Microsoft Active Directory definiert und verwaltet werden.

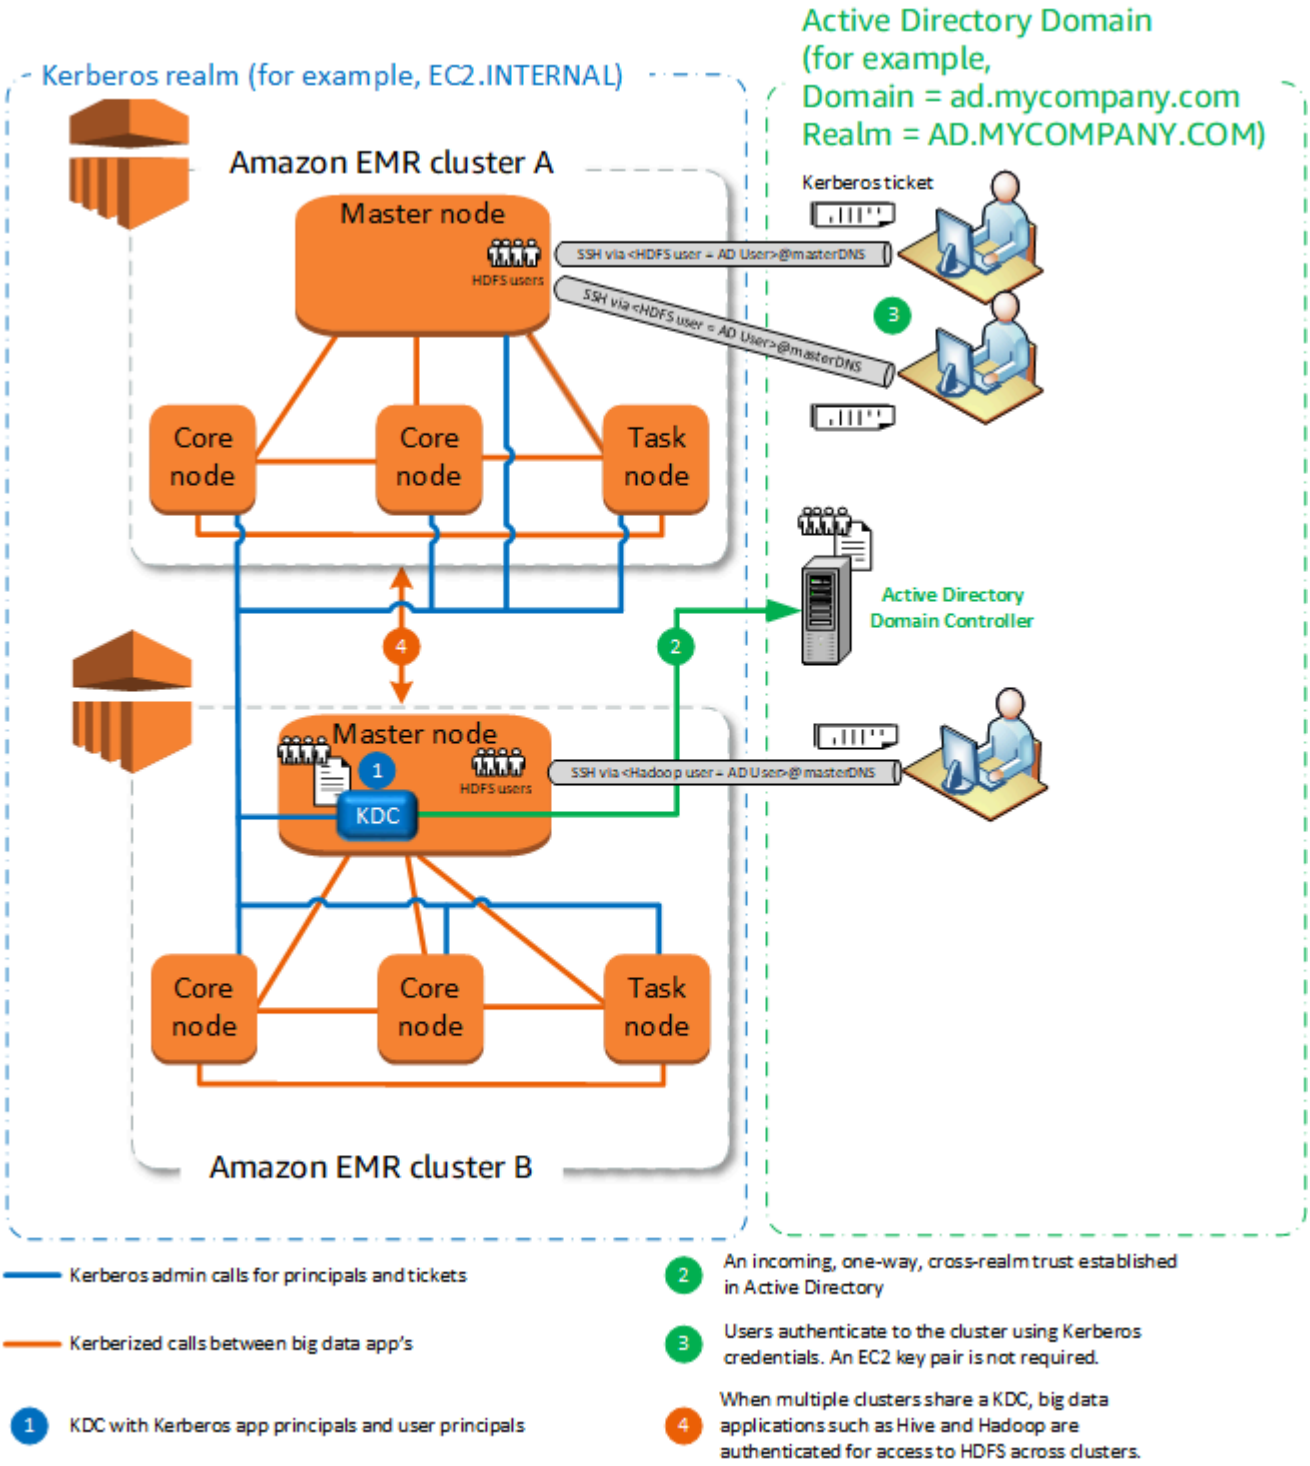

Vorteile

- Die Verwaltung von Prinzipalen ist in der Active-Directory-Domain zusammengefasst.

- Amazon EMR tritt dem Active-Directory-Bereich bei. Dadurch müssen keine Linux-Benutzer mehr erstellt werden, die Active-Directory-Benutzern entsprechen. Sie müssen dennoch für jeden Benutzer HDFS-Verzeichnisse erstellen.
- Mehrere Cluster können dasselbe KDC im selben Kerberos-Bereich verwenden. Weitere Informationen finden Sie unter Anforderungen für die Verwendung mehrerer Cluster mit demselben KDC.
- Benutzerprinzipale können in der Active-Directory-Domain mit `kinit`-Anmeldeinformationen durch Kerberos geschützte Cluster ohne die EC2-Datei mit privatem Schlüssel aufrufen. Dies beseitigt die Notwendigkeit, die Datei mit dem privaten Schlüssel für die Cluster-Benutzer freizugeben.
- Da nur ein einziger Amazon-EMR-Primärknoten für die KDC-Verwaltung verantwortlich ist, muss nur dieser Cluster mit Active-Directory-Anmeldeinformationen erstellt werden, um die bereichsübergreifende Vertrauensstellung zwischen dem KDC und Active Directory herzustellen.

Überlegungen und Einschränkungen

- Jeder Knoten in jedem EMR-Cluster muss über eine Netzwerkroute zum KDC und den Active-Directory-Domain-Controller verfügen.
- Jeder Amazon-EMR-Knoten platziert auf dem externen KDC eine Authentifizierungshürde, sodass die Konfiguration des KDC sich auf die Cluster-Performance auswirkt. Berücksichtigen Sie bei der Konfiguration der Hardware des KDC-Servers die maximale Anzahl der Amazon-EMR-Knoten, die gleichzeitig unterstützt werden können.
- Die Cluster-Performance hängt von der Netzwerklatenz zwischen Knoten in den Clustern und dem KDC-Server ab.
- Die Fehlerbehebung kann sich aufgrund von Abhängigkeiten untereinander schwieriger gestalten.

Anforderungen für die Verwendung mehrerer Cluster mit demselben KDC

Mehrere Cluster können dasselbe KDC im selben Kerberos-Bereich verwenden. Wenn die Cluster jedoch gleichzeitig ausgeführt werden, schlagen die Cluster möglicherweise fehl, wenn sie Kerberos-ServicePrincipal-Namen verwenden, die in Konflikt geraten.

Wenn Sie mehrere gleichzeitige Cluster mit demselben externen KDC haben, stellen Sie sicher, dass die Cluster unterschiedliche Kerberos-Bereiche verwenden. Wenn die Cluster denselben Kerberos-Bereich verwenden müssen, stellen Sie sicher, dass sich die Cluster in unterschiedlichen Subnetzen befinden und dass sich ihre CIDR-Bereiche nicht überschneiden.

Konfiguration von Kerberos in Amazon EMR

Dieser Abschnitt enthält Konfigurationsdetails und Beispiele für das Einrichten von Kerberos mit gängigen Architekturen. Unabhängig von der gewählten Architektur sind die Konfigurationsgrundlagen identisch und in drei Schritte unterteilt. Wenn Sie ein externes KDC verwenden oder eine bereichsübergreifende Vertrauensstellung einrichten, müssen Sie sicherstellen, dass alle Knoten in einem Cluster über eine Netzwerkroute zu einem externen KDC verfügen, einschließlich der Konfiguration der entsprechenden Sicherheitsgruppen, die den ein- und ausgehenden Kerberos-Datenverkehr erlauben.

Schritt 1: Eine Sicherheitskonfiguration mit Kerberos-Eigenschaften erstellen

Die Sicherheitskonfiguration gibt Details über das Kerberos-KDC an und ermöglicht, dass die Kerberos-Konfiguration beim Erstellen eines Clusters wiederverwendet wird. Sie können eine Sicherheitskonfiguration mithilfe der Amazon-EMR-Konsole, der AWS CLI oder der EMR-API erstellen. Die Sicherheitskonfiguration kann auch andere Sicherheitsoptionen enthalten, wie beispielsweise die Verschlüsselung. Weitere Informationen zum Erstellen von Sicherheitskonfigurationen und Festlegen einer Sicherheitskonfiguration beim Erstellen eines Clusters finden Sie unter Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden. Informationen zu Kerberos-Eigenschaften in einer Sicherheitskonfiguration finden Sie unter Kerberos-Einstellungen für Sicherheitskonfigurationen.

Schritt 2: Einen Cluster erstellen und Cluster-spezifische Kerberos-Attribute festlegen

Beim Erstellen eines Clusters legen Sie eine Kerberos-Sicherheitskonfiguration sowie Cluster-spezifische Kerberos-Optionen fest. Wenn Sie die Amazon EMR-Konsole verwenden, sind nur die mit der angegebenen Sicherheitskonfiguration kompatiblen Kerberos-Optionen verfügbar. Wenn Sie die AWS CLI oder die Amazon-EMR-API verwenden, stellen Sie sicher, dass Sie nur die mit der angegebenen Sicherheitskonfiguration kompatiblen Kerberos-Optionen festlegen. Beispiel: Wenn Sie beim Erstellen eines Clusters mithilfe der CLI ein Prinzipal-Passwort für eine bereichsübergreifende Vertrauensstellung verwenden und die angegebene Sicherheitskonfiguration nicht mit den Parametern der bereichsübergreifenden Vertrauensstellung konfiguriert ist, tritt ein Fehler auf. Weitere Informationen finden Sie unter Kerberos-Einstellungen für Cluster.

Schritt 3: Den Cluster-Primärknoten konfigurieren

Abhängig von den Anforderungen an Ihre Architektur und Implementierung ist möglicherweise eine zusätzliche Einrichtung auf dem Cluster erforderlich. Sie können dies nach dem Erstellen oder anhand der Schritte oder Bootstrap-Aktionen während des Erstellungsvorgangs erledigen.

Für jeden Kerberos-authentifizierten Benutzer, der mittels SSH eine Verbindung mit dem Cluster herstellt, müssen Sie sicherstellen, dass Linux-Konten erstellt werden, die dem Kerberos-Benutzer entsprechen. Wenn Benutzerprinzipale von einem Active-Directory-Domain-Controller als externes KDC oder über eine bereichsübergreifende Vertrauensstellung bereitgestellt werden, erstellt Amazon EMR automatisch Linux-Benutzerkonten. Wenn Active Directory nicht verwendet wird, müssen Sie Prinzipale für jeden Benutzer erstellen, der ihrem Linux-Benutzer entspricht. Weitere Informationen finden Sie unter Konfigurieren eines Clusters für mit Kerberos authentifizierte HDFS-Benutzer und SSH-Verbindungen.

Jeder Benutzer muss zudem über ein HDFS-Benutzerverzeichnis in seinem Besitz verfügen, das Sie erstellen müssen. Darüber hinaus muss SSH mit GSSAPI konfiguriert werden, damit Verbindungen von über Kerberos authentifizierten Benutzern zulässig sind. GSSAPI muss auf dem Primärknoten aktiviert sein und die Client-SSH-Anwendung muss so konfiguriert werden, dass sie GSSAPI verwendet. Weitere Informationen finden Sie unter Konfigurieren eines Clusters für mit Kerberos authentifizierte HDFS-Benutzer und SSH-Verbindungen.

Sicherheitskonfiguration und Cluster-Einstellungen für Kerberos auf Amazon EMR

Wenn Sie einen durch Kerberos geschützten Cluster erstellen, geben Sie die Sicherheitskonfiguration zusammen mit den Kerberos-Attributen an, die spezifisch für den Cluster sind. Sie können eine Gruppe nicht ohne die andere angeben, sonst tritt ein Fehler auf.

Dieses Thema bietet eine Übersicht über die für Kerberos verfügbaren Konfigurationsparameter, wenn Sie eine Sicherheitskonfiguration und einen Cluster erstellen. Darüber hinaus werden CLI-Beispiele zum Erstellen von kompatiblen Sicherheitskonfigurationen und Clustern für gängige Architekturen bereitgestellt.

Kerberos-Einstellungen für Sicherheitskonfigurationen

Sie können eine Sicherheitskonfiguration erstellen, die Kerberos-Attribute unter Verwendung der Amazon-EMR-Konsole, der AWS CLI oder der EMR-API spezifiziert. Die Sicherheitskonfiguration kann auch andere Sicherheitsoptionen enthalten, wie beispielsweise die Verschlüsselung. Weitere Informationen finden Sie unter Eine Sicherheitskonfiguration erstellen.

Verwenden Sie die folgenden Referenzen, um die verfügbaren Sicherheitskonfigurationseinstellungen für die Kerberos-Architektur zu verstehen, die Sie auswählen. Die Amazon-EMR-Konsoleneinstellungen werden angezeigt. Informationen zu den entsprechenden CLI-Optionen finden Sie unter Angeben von Kerberos-Einstellungen unter Verwendung der AWS CLI oder Beispiele für Konfigurationen.

Parameter		Beschreibung
Kerberos		Gibt an, dass Kerberos für Cluster aktiviert ist, die diese Sicherheitskonfiguration verwenden. Wenn ein Cluster diese Sicherheitskonfiguration verwendet, müssen für den Cluster auch Kerberos-Einstellungen angegeben sein, andernfalls tritt ein Fehler auf.
Anbieter	Cluster-dediziertes KDC	Gibt an, dass Amazon EMR einen KDC auf dem Primärknoten eines Clusters erstellt, der diese Sicherheitskonfiguration verwendet. Sie geben den Bereichsnamen und das KDC-Administratorkennwort an, wenn Sie den Cluster erstellen. Bei Bedarf können Sie von anderen Clustern aus auf diesen KDC verweisen. Erstellen Sie diese Cluster mit einer anderen Sicherheitskonfiguration, geben Sie ein externes KDC an und verwenden Sie den Bereichsn amen und das KDC-Administratorkennwort, die Sie für das clusterspezifische KDC angeben.
	Externes KDC	Nur in Amazon EMR-Version 5.20.0 und höher verfügbar. Gibt an, dass Cluster, die diese Sicherhei tskonfiguration verwenden, Kerberos-Prinzipale mithilfe eines KDC-Servers außerhalb des Clusters authentifizieren. Auf dem Cluster wird kein KDC erstellt. Sie geben den Bereichsnamen und das KDC-Administratorkennwort an, wenn Sie den Cluster erstellen.
Gültigkeitsdauer des Tickets		Optional. Gibt den Zeitraum an, für den ein vom KDC ausgestelltes Kerberos-Ticket auf Clustern gültig ist, die diese Sicherheitskonfiguration verwenden. Ticket-Gültigkeitsdauern werden aus Sicherhei tsgründen beschränkt. Cluster-Anwendungen und Services verlängern Tickets automatisch, wenn sie ablaufen. Benutzer, die eine Verbindung mit dem

Parameter		Beschreibung
		Cluster über SSH mit Kerberos-Anmeldeinformation en einrichten, müssen `kinit` von der Befehlszeile des Primärknoten aus ausführen, um eine Verlängerung auszuführen, nachdem ein Ticket abgelaufen ist.
Bereichsübergreifende Vertrauen sstellung		Gibt eine bereichsübergreifende Vertrauensstellung zwischen einem clusterspezifischen KDC auf Clustern, die diese Sicherheitskonfiguration verwenden, und einem KDC in einem anderen Kerberos-Bereich an. Prinzipale (in der Regel Benutzer) aus einem anderen Bereich werden gegenüber Clustern authentifiziert, die diese Konfiguration verwenden. Eine zusätzlic he Konfiguration im anderen Kerberos-Bereich ist erforderlich. Weitere Informationen finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.
Realitäts übergreif ende Vertrauen seigensch aften	Bereich	Gibt den Kerberos-Bereichsnamen des anderen Bereichs in der Vertrauensstellung an. Gemäß der Konvention sind Kerberos-Bereichsnamen mit dem Domainnamen identisch, jedoch ausschließlich in Großbuchstaben.
	Bereich	Gibt den Domain-Namen des anderen Bereichs in der Vertrauensstellung an.

Parameter		Beschreibung
	Admin-Server	Gibt den Fully Qualified Domain Name (FQDN, vollständig qualifizierter Domainname) oder IP-Adresse des Admin-Servers im anderen Bereich der Vertrauensstellung an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet , da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com :749`).
	KDC-Server	Gibt den vollständig qualifizierten Domain-Namen (FQDN, Fully Qualified Domain Name) oder IP-Adresse des KDC-Servers im anderen Bereich der Vertrauensstellung an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet , da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com :88`).
Externes KDC		Gibt an, dass das externe KDC des Clusters vom Cluster verwendet wird.

Parameter			Beschreibung
Eigenschaften des externen KDCs	Admin-Server		Gibt den vollqualifizierten Domainnamen oder die IP-Adresse des externen Admin-Servers an. Der Admin-Server und KDC-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, kommunizieren jedoch über andere Ports. Falls kein Port angegeben ist, wird Port 749 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:749`*).
	KDC-Server		Gibt den vollqualifizierten Domainnamen des externen KDC-Servers an. Der KDC-Server und Admin-Server werden normalerweise auf demselben Rechner mit demselben FQDN ausgeführt, nutzen jedoch andere Ports. Falls kein Port angegeben ist, wird Port 88 verwendet, da es dabei um den Kerberos-Standard handelt. Sie können optional einen Port angeben (beispielsweise `domain.example.com` *`:88`*).
	Active-Directory-Integration		Gibt an, dass die Kerberos-Prinzipalauthentifizierung in eine Microsoft-Active-Directory-Domain integriert ist.
	Active-Directory-Integrationseigenschaften	Active-Directory-Bereich	Gibt den Kerberos-Bereichsnamen der Active-Directory-Domain an. Gemäß der Konvention sind Kerberos-Bereichsnamen in der Regel identisch mit dem Domainnamen, jedoch ausschließlich in Großbuchstaben.
		Active-Directory-Domain	Gibt den Active-Directory-Domainnamen an.

Parameter			Beschreibung
		Active-Directory-Server	Gibt den vollqualifizierten Domainnamen des Microsoft Active Directory-Domain-Controllers an.

Kerberos-Einstellungen für Cluster

Sie können Kerberos-Einstellungen festlegen, wenn Sie einen Cluster mithilfe der Amazon EMR-Konsole, der AWS CLI oder der EMR-API erstellen.

Verwenden Sie die folgenden Referenzen, um die verfügbaren Clusterkonfigurationseinstellungen für die Kerberos-Architektur zu verstehen, die Sie auswählen. Die Amazon-EMR-Konsoleneinstellungen werden angezeigt. Informationen zu den entsprechenden CLI-Optionen finden Sie unter Beispiele für Konfigurationen.

Parameter	Beschreibung
Bereich	Der Kerberos-Bereichsname für den Cluster. Die Kerberos-Konvention ist, denselben Namen wie den Domain-Namen zu verwenden, aber in Großbuchstaben. Beispielsweise für die Domain `ec2.internal` mit `EC2.INTERNAL` als Bereichsnamen.
KDC-Administratorpasswort	Das im Cluster verwendete Passwort für `kadmin` oder `kadmin.local` . Dabei handelt es sich um Befehlszeilen-Schnittstellen zum Kerberos V5-Verwaltungssystem, das Kerberos-Prinzipale, Passwortrichtlinien und Keytabs für den Cluster verwaltet.
Prinzipal-Passwort für bereichsübergreifende Vertrauensstellungen (optional)	Erforderlich, wenn eine bereichsübergreifende Vertrauensstellung eingerichtet wird. Das Passwort für die bereichsübergreifende

Parameter	Beschreibung
	Vertrauensstellung, die über alle Bereiche hinweg identisch sein muss. Verwenden Sie ein sicheres Passwort.
Benutzer für die Verbindung mit der Active-Directory-Domain (optional)	Erforderlich bei Verwendung von Active Directory in einer bereichsübergreifenden Vertrauensstellung. Dies ist der Benutzeranmeldename eines Active-Directory-Kontos mit der Berechtigung, der Domain Computer hinzuzufügen. Amazon EMR verwendet diese Identität, um der Domain Cluster hinzuzufügen. Weitere Informationen finden Sie unter the section called “Schritt 3: Konten zu der Domain für den EMR-Cluster hinzufügen”.
Passwort für die Verbindung mit der Active-Directory-Domain (optional)	Das Passwort für den Benutzer für die Verbindung mit der Active-Directory-Domain. Weitere Informationen finden Sie unter the section called “Schritt 3: Konten zu der Domain für den EMR-Cluster hinzufügen”.

Beispiele für Konfigurationen

Die folgenden Beispiele zeigen Sicherheitskonfigurationen und Clusterkonfigurationen für gängige Szenarien. AWS CLI-Befehle werden zur Abkürzung angezeigt.

Lokales KDC

Mit den folgenden Befehlen erstellen Sie einen Cluster mit einem Cluster-spezifischen KDC, das auf dem Primärknoten ausgeführt wird. Eine zusätzliche Konfiguration auf dem Cluster ist erforderlich. Weitere Informationen finden Sie unter Konfigurieren eines Clusters für mit Kerberos authentifizierte HDFS-Benutzer und SSH-Verbindungen.

Sicherheitskonfiguration erstellen

```
aws emr create-security-configuration --name LocalKDCSecurityConfig \
--security-configuration '{"AuthenticationConfiguration": \
{"KerberosConfiguration": {"Provider": "ClusterDedicatedKdc",\
"ClusterDedicatedKdcConfiguration": {"TicketLifetimeInHours": 24 }}}}'
```

Erstellen eines Clusters

```
aws emr create-cluster --release-label emr-5.36.1 \
--instance-count 3 --instance-type m5.xlarge \
--applications Name=Hadoop Name=Hive --ec2-attributes
 InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2Key \
--service-role EMR_DefaultRole \
--security-configuration LocalKDCSecurityConfig \
--kerberos-attributes Realm=EC2.INTERNAL,KdcAdminPassword=MyPassword
```

Cluster-spezifisches KDC mit bereichsübergreifender Active-Directory-Vertrauensstellung

Mit den folgenden Befehlen erstellen Sie einen Cluster mit einem Cluster-spezifischen KDC, das auf dem Primärknoten mit einer bereichsübergreifenden Vertrauensstellung an einer Active-Directory-Domain ausgeführt wird. Zusätzliche Konfiguration auf dem Cluster und in Active Directory ist erforderlich. Weitere Informationen finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.

Sicherheitskonfiguration erstellen

```
aws emr create-security-configuration --name LocalKDCWithADTrustSecurityConfig \
--security-configuration '{"AuthenticationConfiguration": \
{"KerberosConfiguration": {"Provider": "ClusterDedicatedKdc", \
"ClusterDedicatedKdcConfiguration": {"TicketLifetimeInHours": 24, \
"CrossRealmTrustConfiguration": {"Realm":"AD.DOMAIN.COM", \
"Domain":"ad.domain.com", "AdminServer":"ad.domain.com", \
"KdcServer":"ad.domain.com"}}}}}'
```

Erstellen eines Clusters

```
aws emr create-cluster --release-label emr-5.36.1 \
--instance-count 3 --instance-type m5.xlarge --applications Name=Hadoop Name=Hive \
--ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2Key \
--service-role EMR_DefaultRole --security-configuration KDCWithADTrustSecurityConfig \
--kerberos-attributes Realm=EC2.INTERNAL,KdcAdminPassword=MyClusterKDCAdminPassword,\
ADDomainJoinUser=ADUserLogonName,ADDomainJoinPassword=ADUserPassword,\
```

```
CrossRealmTrustPrincipalPassword=MatchADTrustPassword
```

Externes KDC auf einem anderen Cluster

Mit den folgenden Befehlen erstellen Sie einen Cluster, der auf ein Cluster-spezifisches KDC auf dem Primärknoten eines anderen Clusters verweist, um Prinzipale zu authentifizieren. Eine zusätzliche Konfiguration auf dem Cluster ist erforderlich. Weitere Informationen finden Sie unter Konfigurieren eines Clusters für mit Kerberos authentifizierte HDFS-Benutzer und SSH-Verbindungen.

Sicherheitskonfiguration erstellen

```
aws emr create-security-configuration --name ExtKDCOnDifferentCluster \
--security-configuration '{"AuthenticationConfiguration": \
{"KerberosConfiguration": {"Provider": "ExternalKdc", \
"ExternalKdcConfiguration": {"KdcServerType": "Single", \
"AdminServer": "MasterDNSOfKDCMaster:749", \
"KdcServer": "MasterDNSOfKDCMaster:88"}}}}'
```

Erstellen eines Clusters

```
aws emr create-cluster --release-label emr-5.36.1 \
--instance-count 3 --instance-type m5.xlarge \
--applications Name=Hadoop Name=Hive \
--ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2Key \
--service-role EMR_DefaultRole --security-configuration ExtKDCOnDifferentCluster \
--kerberos-attributes Realm=EC2.INTERNAL,KdcAdminPassword=KDCOnMasterPassword
```

Externes Cluster-KDC mit bereichsübergreifender Active-Directory-Vertrauensstellung

Mit den folgenden Befehlen erstellen Sie einen Cluster ohne KDC. Der Cluster verweist auf ein Cluster-spezifisches KDC, das auf dem Primärknoten eines anderen Clusters ausgeführt wird, um Prinzipale zu authentifizieren. Dieses KDC verfügt über eine bereichsübergreifende Vertrauensstellung mit einem Active-Directory-Domain-Controller. Eine zusätzliche Konfiguration auf dem Primärknoten mit dem KDC ist erforderlich. Weitere Informationen finden Sie unter Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain.

Sicherheitskonfiguration erstellen

```
aws emr create-security-configuration --name ExtKDCWithADIntegration \
--security-configuration '{"AuthenticationConfiguration": \
{"KerberosConfiguration": {"Provider": "ExternalKdc", \
```

```
"ExternalKdcConfiguration": {"KdcServerType": "Single", \
"AdminServer": "MasterDNSofClusterKDC:749", \
"KdcServer": "MasterDNSofClusterKDC.com:88", \
"AdIntegrationConfiguration": {"AdRealm":"AD.DOMAIN.COM", \
"AdDomain":"ad.domain.com", \
"AdServer":"ad.domain.com"}}}}}'
```

Erstellen eines Clusters

```
aws emr create-cluster --release-label emr-5.36.1 \
--instance-count 3 --instance-type m5.xlarge --applications Name=Hadoop Name=Hive \
--ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2Key \
--service-role EMR_DefaultRole --security-configuration ExtKDCWithADIntegration \
--kerberos-attributes Realm=EC2.INTERNAL,KdcAdminPassword=KDCOnMasterPassword,\
ADDomainJoinUser=MyPrivilegedADUserName,ADDomainJoinPassword=PasswordForADDomainJoinUser
```

Konfigurieren eines Clusters für mit Kerberos authentifizierte HDFS-Benutzer und SSH-Verbindungen

Amazon EMR erstellt Kerberos-authentifizierten Clients für Anwendungen, die auf dem Cluster ausgeführt werden, z. B. der `hadoop`-Benutzer, `spark`-Benutzer und andere. Sie können auch Benutzer hinzufügen, die mit Kerberos für Cluster-Prozesse authentifiziert werden. Authentifizierte Benutzer können dann eine Verbindung mit dem Cluster mit ihren Kerberos-Anmeldeinformationen einrichten und mit den Anwendungen arbeiten. Damit sich ein Benutzer am Cluster authentifizieren kann, sind die folgenden Konfigurationen erforderlich:

- Auf dem Cluster muss ein Linux-Konto vorhanden sein, das dem Kerberos-Prinzipal im KDC entspricht. Amazon EMR erledigt dies automatisch in Architekturen, die in Active Directory integriert sind.
- Sie müssen ein HDFS-Benutzerverzeichnis auf dem Primärknoten für jeden Benutzer erstellen und dem Benutzer Berechtigungen für das Verzeichnis erteilen.
- Sie müssen den SSH-Service konfigurieren, sodass GSSAPI auf dem Primärknoten aktiviert ist. Darüber hinaus müssen die Benutzer einen SSH-Client mit aktiviertem GSSAPI aufweisen.

Hinzufügen von Linux-Benutzern und Kerberos-Prinzipalen zum Primärknoten

Wenn Sie Active Directory nicht verwenden, müssen Sie Linux-Konten auf dem Cluster-Primärknoten erstellen und Prinzipale für diese Linux-Benutzer am KDC hinzufügen. Dies umfasst einen Prinzipal im KDC für den Primärknoten. Zusätzlich zu den Benutzerprinzipalen erfordert das KDC, das auf dem Primärknoten ausgeführt wird, einen Prinzipal für den lokalen Host.

Wenn Ihre Architektur eine Active Directory-Integration beinhaltet, werden Linux-Benutzer und Prinzipale auf dem lokalen KDC ggf. automatisch erstellt. Sie können diesen Schritt überspringen. Weitere Informationen finden Sie unter Bereichsübergreifende Vertrauensstellung und Externes KDC – Cluster-KDC mit anderer bereichsübergreifender Active-Directory-Vertrauensstellung.

> **Important**
>
> Das KDC geht zusammen mit der Prinzipaldatenbank verloren, wenn der Primärknoten beendet wird, weil der Primärknoten kurzlebigen Speicher verwendet. Wenn Sie Benutzer für SSH-Verbindungen erstellen, empfehlen wir, eine bereichsübergreifende Vertrauensstellung mit einem externen KDC einzurichten, das für hohe Verfügbarkeit konfiguriert ist. Wenn Sie Benutzer für SSH-Verbindungen mithilfe von Linux-Konten erstellen, automatisieren Sie alternativ den Kontoerstellungsprozess mithilfe von Bootstrap-Aktionen und -Skripts, sodass er wiederholt werden kann, wenn Sie einen neuen Cluster erstellen.

Das Übermitteln eines Schritts an das Cluster nach dem Erstellen oder beim Erstellen des Clusters ist die einfachste Möglichkeit zum Hinzufügen von Benutzern und KDC-Prinzipalen. Alternativ können Sie eine Verbindung mit dem Primärknoten unter Verwendung eines EC2-Schlüsselpaars als standardmäßiger `hadoop`-Benutzer einrichten, um die Befehle auszuführen. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Im folgenden Beispiel wird einem Cluster ein bereits vorhandenes Bash-Skript `configureCluster.sh` übergeben, das auf seine Cluster-ID verweist. Das Skript wird in Amazon S3 gespeichert.

```
aws emr add-steps --cluster-id <j-2AL4XXXXXX5T9> \
--steps Type=CUSTOM_JAR,Name=CustomJAR,ActionOnFailure=CONTINUE,\
Jar=s3://region.elasticmapreduce/libs/script-runner/script-runner.jar,\
Args=["s3://DOC-EXAMPLE-BUCKET/configureCluster.sh"]
```

Das folgende Beispiel veranschaulicht den Inhalt des `configureCluster.sh`-Skripts. Das Skript wickelt zudem die Erstellung von HDFS-Benutzerverzeichnissen und die Aktivierung von GSSAPI für SSH ab, die in den folgenden Abschnitten erläutert werden.

```
#!/bin/bash
#Add a principal to the KDC for the primary node, using the primary node's returned
 host name
sudo kadmin.local -q "ktadd -k /etc/krb5.keytab host/`hostname -f`"
```

```
#Declare an associative array of user names and passwords to add
declare -A arr
arr=([lijuan]=pwd1 [marymajor]=pwd2 [richardroe]=pwd3)
for i in ${!arr[@]}; do
    #Assign plain language variables for clarity
     name=${i}
     password=${arr[${i}]}

     # Create a principal for each user in the primary node and require a new password
 on first logon
     sudo kadmin.local -q "addprinc -pw $password +needchange $name"

     #Add hdfs directory for each user
     hdfs dfs -mkdir /user/$name

     #Change owner of each user's hdfs directory to that user
     hdfs dfs -chown $name:$name /user/$name
done

# Enable GSSAPI authentication for SSH and restart SSH service
sudo sed -i 's/^.*GSSAPIAuthentication.*$/GSSAPIAuthentication yes/' /etc/ssh/
sshd_config
sudo sed -i 's/^.*GSSAPICleanupCredentials.*$/GSSAPICleanupCredentials yes/' /etc/ssh/
sshd_config
sudo systemctl restart sshd
```

Hinzufügen von Benutzer-HDFS-Verzeichnissen

Um Ihren Benutzern zu ermöglichen, sich beim Cluster anzumelden, um Hadoop-Jobs auszuführen, müssen Sie HDFS-Benutzerverzeichnisse für ihre Linux-Konten hinzufügen und jedem Benutzer das Eigentum an ihrem Verzeichnis erteilen.

Das Übermitteln eines Schritts an das Cluster nach dem Erstellen oder beim Erstellen des Clusters ist die einfachste Möglichkeit zum Erstellen von HDFS-Verzeichnissen. Alternativ könnten Sie eine Verbindung mit dem Primärknoten unter Verwendung eines EC2-Schlüsselpaars als standardmäßiger hadoop-Benutzer einrichten, um die Befehle auszuführen. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Im folgenden Beispiel wird einem Cluster ein bereits vorhandenes Bash-Skript `AddHDFSUsers.sh` übergeben, das auf seine Cluster-ID verweist. Das Skript wird in Amazon S3 gespeichert.

```
aws emr add-steps --cluster-id <j-2AL4XXXXXX5T9> \
```

```
--steps Type=CUSTOM_JAR,Name=CustomJAR,ActionOnFailure=CONTINUE,\
Jar=s3://region.elasticmapreduce/libs/script-runner/script-runner.jar,Args=["s3://DOC-EXAMPLE-BUCKET/AddHDFSUsers.sh"]
```

Das folgende Beispiel veranschaulicht den Inhalt des `AddHDFSUsers.sh`-Skripts.

```
#!/bin/bash
# AddHDFSUsers.sh script

# Initialize an array of user names from AD, or Linux users created manually on the
 cluster
ADUSERS=("lijuan" "marymajor" "richardroe" "myusername")

# For each user listed, create an HDFS user directory
# and change ownership to the user

for username in ${ADUSERS[@]}; do
     hdfs dfs -mkdir /user/$username
     hdfs dfs -chown $username:$username /user/$username
done
```

Aktivieren von GSSAPI für SSH

Damit für Kerberos authentifizierte Benutzer mithilfe von SSH eine Verbindung mit dem Primärknoten herstellen, muss für den SSH-Service die GSSAPI-Authentifizierung aktiviert sein. Führen Sie zum Aktivieren von GSSAPI die folgenden Befehle über die Befehlszeile des Primärknotens aus oder verwenden Sie einen Schritt zum Ausführen als Skript. Nachdem Sie SSH neu konfiguriert haben, müssen Sie den Service neu starten.

```
sudo sed -i 's/^.*GSSAPIAuthentication.*$/GSSAPIAuthentication yes/' /etc/ssh/
sshd_config
sudo sed -i 's/^.*GSSAPICleanupCredentials.*$/GSSAPICleanupCredentials yes/' /etc/ssh/
sshd_config
sudo systemctl restart sshd
```

Verwenden von SSH zum Herstellen einer Verbindung mit durch Kerberos geschützten Clustern

Dieser Abschnitt zeigt die Schritte für einen über Kerberos authentifizierten Benutzer, um eine Verbindung mit dem Primärknoten eines EMR-Clusters herzustellen.

Auf jedem Computer, der für eine SSH-Verbindung verwendet wird, müssen SSH-Client- und Kerberos-Client-Anwendungen installiert sein. Linux-Computer enthalten diese höchstwahrscheinlich standardmäßig. OpenSSH wird beispielsweise bei den meisten Linux-, Unix- und MacOS-Betriebssystemen installiert. Sie können nach einem SSH-Client suchen, indem Sie in der Befehlszeile ssh eingeben. Wenn Ihr Computer den Befehl nicht erkennt, installieren Sie einen SSH-Client, um eine Verbindung mit dem Primärknoten herzustellen. Das OpenSSH-Projekt bietet eine kostenlose Implementierung der umfassenden Palette von SSH-Tools. Weitere Informationen finden Sie auf der OpenSSH-Website. Windows-Benutzer können Anwendungen wie PuTTY als SSH-Client verwenden.

Weitere Informationen zu SSH-Verbindungen finden Sie unter Verbinden mit einem Cluster.

SSH verwendet GSSAPI zum Authentifizieren von Kerberos-Clients und müssen die GSSAPI-Authentifizierung für den SSH-Service auf dem Cluster-Primärknoten aktivieren. Weitere Informationen finden Sie unter Aktivieren von GSSAPI für SSH. SSH-Clients müssen auch GSSAPI verwenden.

Für *MasterPublicDNS* verwenden Sie den Wert, der für Öffentlicher Master-DNS auf der Registerkarte Zusammenfassung im Detailbereich des Clusters angezeigt wird, z. B. *ec2-11-222-33-44.compute-1.amazonaws.com*.

Voraussetzung für krb5.conf (nicht Active Directory)

Bei der Verwendung einer Konfiguration ohne Active-Directory-Integration muss zusätzlich zu den SSH-Client- und Kerberos-Client-Anwendungen jeder Client-Computer über eine Kopie der `/etc/krb5.conf`-Datei verfügen, die mit der `/etc/krb5.conf`-Datei auf dem Cluster-Primärknoten übereinstimmt.

So kopieren Sie die krb5.conf-Datei

1. Verwenden Sie SSH, um mithilfe eines EC2-Schlüsselpaars und des `hadoop`-Standardbenutzers eine Verbindung zum Primärknoten herzustellen, zum Beispiel `hadoop@`*MasterPublicDNS*. Detaillierte Anweisungen finden Sie unter Verbinden mit einem Cluster.
2. Kopieren Sie vom Primärknoten die Inhalte der `/etc/krb5.conf`-Datei. Weitere Informationen finden Sie unter Verbinden mit einem Cluster.
3. Erstellen Sie auf jedem Client-Computer, der eine Verbindung zum Cluster herstellt, eine identische `/etc/krb5.conf`-Datei basierend auf der Kopie, die Sie im vorigen Schritt erstellt haben.

Verwenden von Kinit und SSH

Immer wenn ein Benutzer eine Verbindung von einem Client-Computer aus mithilfe von Kerberos-Anmeldeinformationen herstellt, muss der Benutzer zuerst Kerberos-Tickets für seinen Benutzer auf dem Client-Computer verlängern. Darüber hinaus muss der SSH-Client so konfiguriert werden, dass die GSSAPI-Authentifizierung verwendet wird.

So verwenden Sie SSH zum Herstellen einer Verbindung mit einem durch Kerberos geschützten EMR-Cluster

1. Verwenden Sie `kinit` zum Verlängern Ihres Kerberos-Tickets, wie im folgenden Beispiel gezeigt

   ```
   kinit user1
   ```

2. Verwenden Sie einen `ssh`-Client zusammen mit dem Prinzipal, den Sie im Cluster-spezifischen KDC- oder Active Directory-Benutzernamen erstellt haben. Stellen Sie sicher, dass die GSSAPI-Authentifizierung aktiviert ist, wie in den folgenden Beispielen gezeigt.

   Beispiel: Linux-Benutzer

   Die Option `-K` gibt die GSSAPI-Authentifizierung an.

   ```
   ssh -K user1@MasterPublicDNS
   ```

   Beispiel: Windows-Benutzer (PuTTY)

   Stellen Sie sicher, dass die GSSAPI-Authentifizierungsoption für die Sitzung wie angezeigt aktiviert ist:

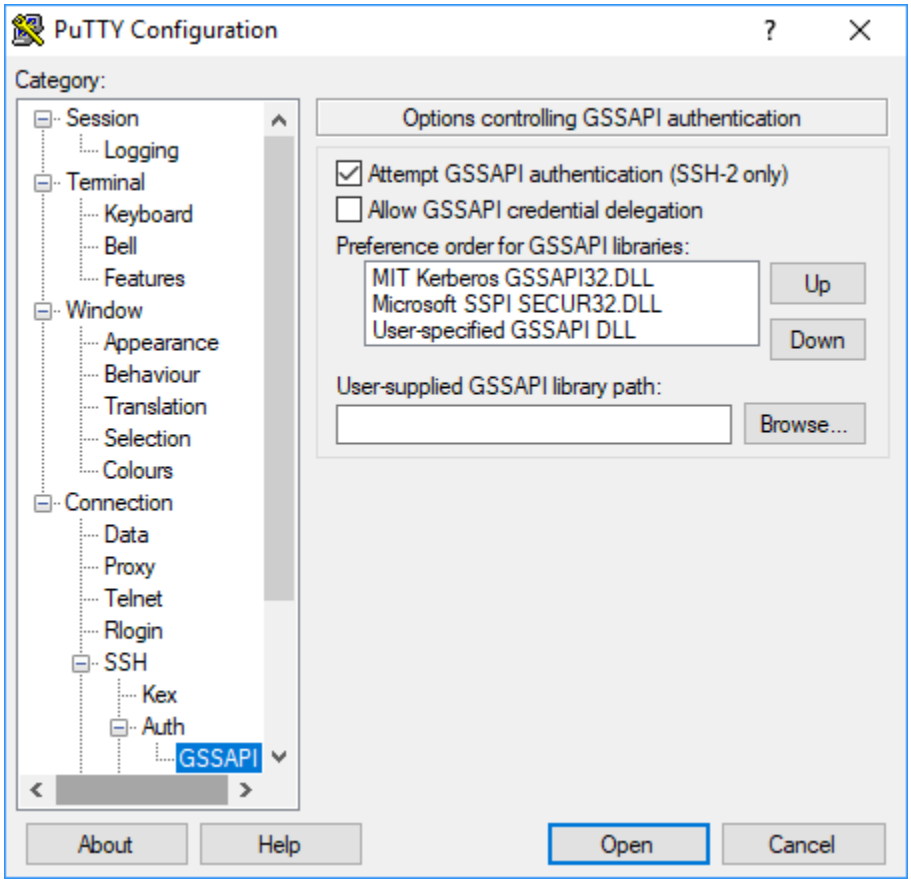

Tutorial: Konfigurieren eines Cluster-spezifischen KDC

Dieses Thema führt Sie durch die Erstellung eines Clusters mit einem cluster-spezifischen Key Distribution Center (KDC), das manuelle Hinzufügen von Linux-Konten zu allen Clusterknoten, das Hinzufügen von Kerberos-Prinzipalen zum KDC auf dem Primärknoten und das Sicherstellen, dass auf den Client-Computern ein Kerberos-Client installiert ist.

Weitere Informationen zur Amazon-EMR-Unterstützung für Kerberos und KDC sowie Links zur MIT-Kerberos-Dokumentation finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.

Schritt 1: Den durch Kerberos geschützten Cluster erstellen

1. Erstellen Sie eine Sicherheitskonfiguration, die Kerberos aktiviert. Das folgende Beispiel zeigt den Befehl `create-security-configuration` unter Verwendung der AWS CLI, der die Sicherheitskonfiguration als Inline-JSON-Struktur angibt. Sie können auch auf eine lokal gespeicherte Datei verweisen.

```
aws emr create-security-configuration --name MyKerberosConfig \
--security-configuration '{"AuthenticationConfiguration": {"KerberosConfiguration":
{"Provider": "ClusterDedicatedKdc", "ClusterDedicatedKdcConfiguration":
 {"TicketLifetimeInHours": 24}}}}'
```

2. Erstellen Sie einen Cluster, der auf die Sicherheitskonfiguration verweist, Kerberos-Attribute für die Cluster einrichtet, und Linux-Konten unter Verwendung einer Bootstrap-Aktion hinzufügt. Das folgende Beispiel zeigt den Befehl `create-cluster` unter Verwendung der AWS CLI. Der Befehl bezieht sich auf die Sicherheitskonfiguration, die Sie oben erstellt haben, `MyKerberosConfig`. Er referenziert auch ein einfaches Skript `createlinuxusers.sh`, als Bootstrap-Aktion, das Sie erstellen und zu Amazon S3 hochladen, bevor Sie den Cluster erstellen.

   ```
   aws emr create-cluster --name "MyKerberosCluster" \
   --release-label emr-5.36.1 \
   --instance-type m5.xlarge \
   --instance-count 3 \
   --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2KeyPair \
   --service-role EMR_DefaultRole \
   --security-configuration MyKerberosConfig \
   --applications Name=Hadoop Name=Hive Name=Oozie Name=Hue Name=HCatalog Name=Spark \
   --kerberos-attributes Realm=EC2.INTERNAL,\
   KdcAdminPassword=MyClusterKDCAdminPwd \
   --bootstrap-actions Path=s3://DOC-EXAMPLE-BUCKET/createlinuxusers.sh
   ```

   Dar folgende Code zeigt den Inhalt des `createlinuxusers.sh`-Skripts, das jedem Knoten im Cluster user1, user2 und user3 hinzufügt. Im nächsten Schritt fügen Sie diese Benutzer als KDC-Prinzipale hinzu.

   ```
   #!/bin/bash
   sudo adduser user1
   sudo adduser user2
   sudo adduser user3
   ```

Schritt 2: Dem KDC Prinzipale hinzufügen, HDFS-Benutzerverzeichnisse erstellen und SSH konfigurieren

Das KDC, das auf dem Primärknoten ausgeführt wird, benötigt einen Prinzipal für den lokalen Host und für jeden Benutzer, den Sie auf dem Cluster erstellen. Sie können auch für jeden Benutzer

HDFS-Verzeichnisse erstellen, wenn sie eine Verbindung mit dem Cluster einrichten und Hadoop-Aufträge ausführen müssen. Analog dazu konfigurieren Sie den SSH-Service, um eine GSSAPI-Authentifizierung zu aktivieren, die für Kerberos erforderlich ist. Nachdem Sie GSSAPI aktiviert haben, starten Sie den SSH-Service neu.

Die einfachste Möglichkeit dafür ist, dem Cluster ein Skript zu übergeben. Das folgende Beispiel übergibt dem Cluster ein bash-Skript `configurekdc.sh`, das Sie im vorherigen Schritt erstellt haben, wobei Sie die Cluster-ID angeben. Das Skript wird in Amazon S3 gespeichert. Alternativ können Sie eine Verbindung mit dem Primärknoten unter Verwendung eines EC2-Schlüsselpaars einrichten, um die Befehle auszuführen oder das Skript bei der Erstellung des Clusters übergeben.

```
aws emr add-steps --cluster-id <j-2AL4XXXXXX5T9> --steps
 Type=CUSTOM_JAR,Name=CustomJAR,ActionOnFailure=CONTINUE,Jar=s3://
myregion.elasticmapreduce/libs/script-runner/script-runner.jar,Args=["s3://DOC-EXAMPLE-
BUCKET/configurekdc.sh"]
```

Das folgende Beispiel veranschaulicht den Inhalt des `configurekdc.sh`-Skripts.

```
#!/bin/bash
#Add a principal to the KDC for the primary node, using the primary node's returned
 host name
sudo kadmin.local -q "ktadd -k /etc/krb5.keytab host/`hostname -f`"
#Declare an associative array of user names and passwords to add
declare -A arr
arr=([user1]=pwd1 [user2]=pwd2 [user3]=pwd3)
for i in ${!arr[@]}; do
    #Assign plain language variables for clarity
     name=${i}
     password=${arr[${i}]}

     # Create principal for sshuser in the primary node and require a new password on
 first logon
     sudo kadmin.local -q "addprinc -pw $password +needchange $name"

     #Add user hdfs directory
     hdfs dfs -mkdir /user/$name

     #Change owner of user's hdfs directory to user
     hdfs dfs -chown $name:$name /user/$name
done

# Enable GSSAPI authentication for SSH and restart SSH service
```

```
sudo sed -i 's/^.*GSSAPIAuthentication.*$/GSSAPIAuthentication yes/' /etc/ssh/
sshd_config
sudo sed -i 's/^.*GSSAPICleanupCredentials.*$/GSSAPICleanupCredentials yes/' /etc/ssh/
sshd_config
sudo systemctl restart sshd
```

Die Benutzer, die Sie hinzugefügt haben, sollten jetzt in der Lage sein, mittels SSH eine Verbindung zum Cluster herzustellen. Weitere Informationen finden Sie unter Verwenden von SSH zum Herstellen einer Verbindung mit durch Kerberos geschützten Clustern.

Tutorial: Konfigurieren einer bereichsübergreifenden Vertrauensstellung mit einer Active-Directory-Domain

Wenn Sie eine bereichsübergreifende Vertrauensstellung einrichten, gestatten Sie Prinzipalen (normalerweise Benutzern) aus einem anderen Kerberos-Bereich, sich bei Anwendungskomponenten auf dem EMR-Cluster zu authentifizieren. Das Cluster-dedizierte Schlüsselverteilungszentrum (KDC) stellt mithilfe eines bereichsübergreifenden Prinzipals, das in beiden KDCs vorhanden ist, eine Vertrauensbeziehung mit einem anderen KDC her. Der Name des Prinzipals und das Passwort stimmen genau überein.

Eine bereichsübergreifende Vertrauensstellung erfordert, dass die KDCs einander über das Netzwerk erreichen und gegenseitig ihre Domain-Namen auflösen. Die Schritte für die Einrichtung einer bereichsübergreifenden Vertrauensstellung mit einem Microsoft-AD-Domain-Controller, der als EC2-Instance ausgeführt wird, sind nachfolgend gezeigt, ebenso wie ein Beispiel für eine Netzwerkeinrichtung, das die erforderliche Konnektivität und die Auflösung des Domainnamens durchführt. Jede beliebige Netzwerkeinrichtung, die den erforderlichen Netzwerkdatenverkehr zwischen KDCs erlaubt, ist akzeptabel.

Optional können Sie nach dem Einrichten einer bereichsübergreifenden Vertrauensstellung bei Active Directory mit einem KDC auf einem Cluster einen anderen Cluster mit einer anderen Sicherheitskonfiguration erstellen, um auf das KDC auf dem ersten Cluster als externes KDC zu verweisen. Ein Beispiel für die Einrichtung einer Sicherheitskonfiguration und eines Clusters finden Sie unter Externes Cluster-KDC mit bereichsübergreifender Active-Directory-Vertrauensstellung.

Weitere Informationen zur Amazon-EMR-Unterstützung für Kerberos und KDC sowie Links zur MIT-Kerberos-Dokumentation finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.

> **Important**
>
> Amazon EMR unterstützt kein bereichsübergreifendes Vertrauen für AWS Directory Service for Microsoft Active Directory.

Schritt 1: Die VPC und das Subnetz einrichten

Schritt 2: Den Active-Directory-Domain-Controller starten und installieren

Schritt 3: Konten zu der Domain für den EMR-Cluster hinzufügen

Schritt 4: Eine eingehende Vertrauensstellung auf dem Active-Directory-Domain-Controller konfigurieren

Schritt 5: DHCP-Optionsmenge verwenden, um den Active-Directory-Domain-Controller zu einem VPC-DNS-Server zu machen

Schritt 6: Starten eines von Kerberos geschützten EMR Clusters

Schritt 7: HDFS-Benutzer erstellen und Berechtigungen für Active-Directory-Benutzerkonten in dem Cluster festlegen

Schritt 1: Die VPC und das Subnetz einrichten

Die folgenden Schritten zeigen, wie eine VPC und ein Subnetz erstellt werden, sodass das Cluster-spezifische KDC den Active-Directory-Domain-Controller erreichen und seinen Domainnamen auflösen kann. In diesen Schritten wird die Auflösung des Domain-Namens durch Angabe des Active-Directory-Domain-Controllers als Domain-Namen-Server in der DHCP-Optionsmenge durchgeführt. Weitere Informationen finden Sie unter Schritt 5: DHCP-Optionsmenge verwenden, um den Active-Directory-Domain-Controller zu einem VPC-DNS-Server zu machen.

Das KDC und der Active-Directory-Domain-Controller müssen in der Lage sein, gegenseitig ihren Domainnamen aufzulösen. Dies gestattet Amazon EMR, der Domain Computer hinzuzufügen und automatisch entsprechende Linux-Konten und SSH-Parameter auf Cluster-Instances zu konfigurieren.

Wenn Amazon EMR den Domain-Namen nicht auflösen kann, können Sie unter Verwendung der IP-Adresse des Active-Directory-Domain-Controllers auf die Vertrauensstellung verweisen. Sie müssen jedoch manuell Linux-Konten hinzufügen, dem Cluster-spezifischen KDC entsprechende Prinzipale hinzufügen und SSH konfigurieren.

Einrichten der VPC und des Subnetzes

1. Erstellen Sie eine Amazon VPC mit einem einzelnen öffentlichen Subnetz. Weitere Informationen finden Sie unter Schritt 1: Die VPC erstellen im Handbuch für die ersten Schritte mit Amazon VPC.

   > **Important**
   >
   > Wenn Sie einen Microsoft Active-Directory-Domain-Controller verwenden, wählen Sie einen CIDR-Block für den EMR-Cluster, sodass alle IPv4-Adressen kürzer als neun Zeichen sind (z. B. 10.0.0.0/16). Dies liegt daran, dass die DNS-Namen von Clustercomputern verwendet werden, wenn die Computer dem Active-Directory-Verzeichnis beitreten. AWS weist DNS-Hostnamen auf der Grundlage der IPv4-Adresse so zu, dass längere IP-Adressen zu DNS-Namen mit mehr als 15 Zeichen führen können. Für Active Directory gilt ein Limit von 15 Zeichen für die Registrierung der Namen der hinzugefügten Computer, und es kürzt längere Namen, was zu unvorhersehbaren Fehlern führen kann.

2. Entfernen Sie die Standard-DHCP-Optionsmenge, die der VPC zugeordnet ist. Weitere Informationen finden Sie unter Ändern der VPC, um keine DHCP-Optionen zu verwenden. Später fügen Sie eine neue hinzu, die den Active-Directory-Domain-Controller als DNS-Server spezifiziert.
3. Vergewissern Sie sich, dass DNS-Support für die VPC aktiviert ist, dass DNS-Hostnamen und DNS-Auflösung beide aktiviert sind. Standardmäßig sind sie aktiviert. Weitere Informationen finden Sie unter Aktualisieren der DNS-Unterstützung für Ihre VPC.
4. Vergewissern Sie sich, dass Ihrer VPC ein Internet-Gateway zugeordnet ist. Dies ist die Standardeinstellung. Weitere Informationen finden Sie unter Erstellen und Anfügen eines Internet-Gateways.

   > **Note**
   >
   > In diesem Beispiel wird ein Internet-Gateway verwendet, weil Sie einen neuen Domain-Controller für den VPC einrichten. Für Ihre Anwendung ist möglicherweise kein Internet-Gateway erforderlich. Die einzige Voraussetzung ist, dass das Cluster-spezifische KDC auf den Active-Directory-Domain-Controller zugreifen kann.

5. Erstellen Sie eine benutzerdefinierte Routing-Tabelle, fügen Sie eine Route zum Internet-Gateway hinzu, und ordnen Sie ihn dann Ihrem Subnetz zu. Weitere Informationen finden Sie unter Erstellen einer benutzerdefinierten Routing-Tabelle.
6. Wenn Sie die EC2-Instance für den Domain-Controller starten, benötigt er eine statische öffentliche IPv4-Adresse, damit Sie eine Verbindung über RDP zu ihm einrichten können. Die einfachste Möglichkeit ist die Konfiguration Ihres Subnetzes, um automatisch öffentliche IPv4-Adressen zuzuweisen. Dies ist nicht die Standardeinstellung, wenn ein Subnetz erstellt wird. Weitere Informationen finden Sie unter Ändern des öffentlichen IPv4-Adressierungsattributs Ihres Subnetzes. Optional können Sie die Adresse zuweisen, wenn Sie die Instance starten. Weitere Informationen finden Sie unter Zuweisen einer öffentlichen IPv4-Adresse beim Starten einer Instance.
7. Wenn Sie fertig sind, notieren Sie die VPC und die Subnetz-IDs. Sie benötigen sie später, wenn Sie den Active-Directory-Domain-Controller und den Cluster starten.

Schritt 2: Den Active-Directory-Domain-Controller starten und installieren

1. So starten Sie eine EC2-Instance basierend auf der Microsoft Windows Server 2016 Basis-AMI. Wir empfehlen einen m4.xlarge oder einen besseren Instance-Typ. Weitere Informationen finden Sie unter Starten einer AWS Marketplace Instance im Benutzerhandbuch zu Amazon EC2 für Linux-Instances.
2. Notieren Sie sich die Gruppen-ID der Sicherheitsgruppe, die der EC2-Instance zugeordnet ist. Sie benötigen sie für Schritt 6: Starten eines von Kerberos geschützten EMR Clusters. Wir verwenden *sg-012xrlmdomain345*. Alternativ können Sie verschiedene Sicherheitsgruppen für den EMR-Cluster und diese Instance angeben, die den Datenverkehr zwischen ihnen zulässt. Weitere Informationen finden Sie unter Amazon-EC2-Sicherheitsgruppen für Linux-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.
3. Stellen Sie unter Verwendung von RDP eine Verbindung mit der EC2-Instance her. Weitere Informationen finden Sie unter Herstellen einer Verbindung mit Ihrer Windows-Instance im Amazon-EC2-Benutzerhandbuch für Windows-Instances.
4. Starten Sie Server Manager, um die Domain-Services-Rolle von Active Directory auf dem Server zu installieren und zu konfigurieren. Machen Sie den Server zu einem Domain-Controller und weisen Sie einen Domain-Namen zu (wir verwenden in diesem Beispiel hier *ad.domain.com*). Notieren Sie den Domain-Namen, da Sie ihn später benötigen, wenn Sie die EMR-Sicherheitskonfiguration und den Cluster erstellen. Wenn Sie noch keine Erfahrung mit der

Einrichtung von Active Directory haben, können Sie den Anweisungen in So richten Sie Active Directory (AD) in Windows Server 2016 ein folgen.

Die Instance startet neu, wenn Sie fertig sind.

Schritt 3: Konten zu der Domain für den EMR-Cluster hinzufügen

RDP zum Active-Directory-Domain-Controller zum Erstellen von Benutzerkonten in Active-Directory-Benutzern und -Computern für jeden Cluster-Benutzer. Weitere Informationen finden Sie unter Erstellen eines Benutzerkontos in Active-Directory-Benutzern und -Computern auf der Website Microsoft Learn. Notieren Sie den Wert für User logon name (Benutzeranmeldename) jedes Benutzers. Sie benötigen diese später, wenn Sie den Cluster konfigurieren.

Darüber hinaus erstellen Sie ein Konto mit ausreichenden Berechtigungen, um der Domain Computer hinzuzufügen. Sie geben dieses Konto an, wenn Sie einen Cluster erstellen. Amazon EMR verwendet es, um der Domain Cluster-Instances hinzuzufügen. Sie geben dieses Konto und sein Passwort in Schritt 6: Starten eines von Kerberos geschützten EMR Clusters an. Für die Delegation von Join-Berechtigungen des Computers an das Konto empfehlen wir das Erstellen einer Gruppe mit Join-Berechtigungen und die anschließende Zuweisung des Benutzers zu der Gruppe. Weitere Informationen finden Sie unter Delegieren von Berechtigungen für den Verzeichniszugang im AWS Directory Service-Administratorhandbuch.

Schritt 4: Eine eingehende Vertrauensstellung auf dem Active-Directory-Domain-Controller konfigurieren

Die folgenden Beispielbefehle erstellen ein Vertrauensverhältnis in Active Directory. Dabei handelt es sich um eine unidirektionale eingehende, nicht transitive, Bereichsvertrauensstellung mit dem Cluster-spezifischen KDC. Das Beispiel, das wir für den Bereich des Clusters verwenden, ist *`EC2.INTERNAL`*. Ersetzen Sie den *`KDC-FQDN`* durch den Namen der Öffentlichen DNS, der für den Amazon-EMR-Primärknoten aufgelistet ist, der das KDC hostet. Der Parameter `passwordt` gibt das cross-realm principal password (Passwort des bereichsübergreifenden Prinzipals) an, das Sie beim Erstellen eines Clusters zusammen mit dem realm (Bereich) des Clusters angeben. Der Bereichsname wird von dem Standard-Domain-Namen `us-east-1` für den Cluster abgeleitet. Die `Domain` ist die Active-Directory-Domain, in der Sie die Vertrauensstellung erstellen. Sie wird gemäß Konvention in Kleinbuchstaben angegeben. Im Beispiel wird *`ad.domain.com`* verwendet.

Öffnen Sie die Windows-Eingabeaufforderung mit Administrator-Berechtigungen und geben Sie die folgenden Befehle zum Erstellen der Vertrauensstellung auf dem Active-Directory-Domain-Controller ein:

```
C:\Users\Administrator> ksetup /addkdc EC2.INTERNAL KDC-FQDN
C:\Users\Administrator> netdom trust EC2.INTERNAL /Domain:ad.domain.com /add /realm /
passwordt:MyVeryStrongPassword
C:\Users\Administrator> ksetup /SetEncTypeAttr EC2.INTERNAL AES256-CTS-HMAC-SHA1-96
```

Schritt 5: DHCP-Optionsmenge verwenden, um den Active-Directory-Domain-Controller zu einem VPC-DNS-Server zu machen

Nachdem der Active-Directory-Domain-Controller konfiguriert ist, müssen Sie die VPC so konfigurieren, dass er als Domain-Namenserver für die Namensauflösung in Ihrer VPC verwendet wird. Dazu ordnen Sie eine DHCP-Optionsmenge zu. Geben Sie einen Wert in Domainname als Domainnamen für Ihren Cluster ein, z. B. `ec2.internal`, wenn sich Ihr Cluster in us-east-1 befindet, oder *`region`*`.compute.internal` für andere Regionen. In Domain name servers (Domain-Namenserver) müssen Sie als ersten Eintrag die IP-Adresse des Active-Directory-Domain-Controllers angeben (der vom Cluster aus erreichbar sein muss), gefolgt von AmazonProvidedDNS (z. B. ***`xx.xx.xx.xx`***,AmazonProvidedDNS). Weitere Informationen finden Sie unter Ändern von DHCP-Optionssätzen.

Schritt 6: Starten eines von Kerberos geschützten EMR Clusters

1. Erstellen Sie in Amazon EMR eine Sicherheitskonfiguration, die den Active-Directory-Domain-Controller angibt, den Sie in den vorherigen Schritten erstellt haben. Ein Beispielbefehl ist nachfolgend gezeigt. Ersetzen Sie die Domain *`ad.domain.com`* durch den Namen der Domain, die Sie in Schritt 2: Den Active-Directory-Domain-Controller starten und installieren angegeben haben.

   ```
   aws emr create-security-configuration --name MyKerberosConfig \
   --security-configuration '{
     "AuthenticationConfiguration": {
       "KerberosConfiguration": {
         "Provider": "ClusterDedicatedKdc",
         "ClusterDedicatedKdcConfiguration": {
           "TicketLifetimeInHours": 24,
           "CrossRealmTrustConfiguration": {
             "Realm": "AD.DOMAIN.COM",
             "Domain": "ad.domain.com",
             "AdminServer": "ad.domain.com",
             "KdcServer": "ad.domain.com"
           }
         }
   ```

```
    }
  }
}'
```

2. Erstellen Sie den Cluster mit den folgenden Attributen:

   - Verwenden Sie die `--security-configuration`-Option, um die Sicherheitskonfiguration anzugeben, die Sie erstellt haben. Im Beispiel wird *`MyKerberosConfig`* verwendet.
   - Verwenden Sie die `SubnetId`-Eigenschaft der `--ec2-attributes option`, um das Subnetz anzugeben, das Sie in Schritt 1: Die VPC und das Subnetz einrichten erstellt haben. Im Beispiel verwenden wir *`step1-subnet`* .
   - Verwenden Sie die `AdditionalMasterSecurityGroups` und `AdditionalSlaveSecurityGroups` der `--ec2-attributes`-Option, um anzugeben, dass die Sicherheitsgruppe, die dem AD-Domain-Controller von Schritt 2: Den Active-Directory-Domain-Controller starten und installieren zugeordnet ist, dem Cluster-Primärknoten sowie dem Core- und dem Aufgabenknoten zugeordnet ist. Wir verwenden im Beispiel *`sg-012xrlmdomain345`* .

   Verwenden Sie `--kerberos-attributes`, um die folgenden Cluster-spezifischen Kerberos-Attribute anzugeben:

   - Den Bereich für den Cluster, den Sie bei der Einrichtung des Active-Directory-Domain-Controllers angegeben haben.
   - Das Prinzipal-Passwort der bereichsübergreifenden Vertrauensstellung, das Sie als `passwordt` in Schritt 4: Eine eingehende Vertrauensstellung auf dem Active-Directory-Domain-Controller konfigurieren angegeben haben.
   - Ein `KdcAdminPassword`, das Sie für die Verwaltung des Cluster-spezifischen KDC verwenden können.
   - Der Benutzeranmeldename und das Passwort des Active Directory-Kontos mit Computer-Join-Berechtigungen, die Sie in Schritt 3: Konten zu der Domain für den EMR-Cluster hinzufügen erstellt haben.

   Das folgende Beispiel startet einen Cluster mit Schutz durch Kerberos.

```
aws emr create-cluster --name "MyKerberosCluster" \
--release-label emr-5.10.0 \
--instance-type m5.xlarge \
--instance-count 3 \
--ec2-attributes InstanceProfile=EMR_EC2_DefaultRole,KeyName=MyEC2KeyPair,\
```

```
SubnetId=step1-subnet, AdditionalMasterSecurityGroups=sg-012xrlmdomain345,
AdditionalSlaveSecurityGroups=sg-012xrlmdomain345\
--service-role EMR_DefaultRole \
--security-configuration MyKerberosConfig \
--applications Name=Hadoop Name=Hive Name=Oozie Name=Hue Name=HCatalog Name=Spark \
--kerberos-attributes Realm=EC2.INTERNAL,\
KdcAdminPassword=MyClusterKDCAdminPwd,\
ADDomainJoinUser=ADUserLogonName,ADDomainJoinPassword=ADUserPassword,\
CrossRealmTrustPrincipalPassword=MatchADTrustPwd
```

Schritt 7: HDFS-Benutzer erstellen und Berechtigungen für Active-Directory-Benutzerkonten in dem Cluster festlegen

Wenn Sie eine Vertrauensstellung mit Active Directory einrichten, erstellt Amazon EMR Linux-Benutzer auf dem Cluster für jedes Active Directory-Konto. Beispielsweise hat der Benutzeranmeldename `LiJuan` in Active Directory ein Linux-Benutzerkonto von `lijuan`. Active Directory-Benutzernamen können Großbuchstaben, aber Linux ignoriert die Groß-/Kleinschreibung von Active Directory.

Um Ihren Benutzern zu ermöglichen, sich beim Cluster anzumelden, um Hadoop-Jobs auszuführen, müssen Sie HDFS-Benutzerverzeichnisse für ihre Linux-Konten hinzufügen und jedem Benutzer das Eigentum an ihrem Verzeichnis erteilen. Zu diesem Zweck empfehlen wir, dass Sie ein Skript ausführen, das Sie in Amazon S3 als Cluster-Schritt gespeichert haben. Alternativ können Sie die Befehle aus dem folgenden Skript von der Befehlszeile auf dem Primärknoten aus ausführen. Verwenden Sie das EC2-Schlüsselpaar, das Sie beim Erstellen des Clusters angegeben haben, um eine Verbindung mit dem Primärknoten über SSH als Hadoop-Benutzer einzurichten. Weitere Informationen finden Sie unter Verwenden eines EC2-Schlüsselpaars für SSH-Anmeldeinformationen.

Führen Sie den folgenden Befehl aus, um dem Cluster einen Schritt hinzuzufügen, der das Skript *AddHDFSUsers.sh* ausführt.

```
aws emr add-steps --cluster-id <j-2AL4XXXXXX5T9> \
--steps Type=CUSTOM_JAR,Name=CustomJAR,ActionOnFailure=CONTINUE,\
Jar=s3://region.elasticmapreduce/libs/script-runner/script-runner.jar,Args=["s3://DOC-EXAMPLE-BUCKET/AddHDFSUsers.sh"]
```

Der Inhalt der Datei *AddHDFSUsers.sh* wird im Folgenden gezeigt.

```
#!/bin/bash
```

```
# AddHDFSUsers.sh script

# Initialize an array of user names from AD or Linux users and KDC principals created
 manually on the cluster
ADUSERS=("lijuan" "marymajor" "richardroe" "myusername")

# For each user listed, create an HDFS user directory
# and change ownership to the user

for username in ${ADUSERS[@]}; do
     hdfs dfs -mkdir /user/$username
     hdfs dfs -chown $username:$username /user/$username
done
```

Hadoop-Gruppen zugeordnete Active-Directory-Gruppen

Amazon EMR verwendet den System Security Services Daemon (SSD), um Active Directory-Gruppen Hadoop-Gruppen zuzuordnen. Um die Gruppenzuordnungen nach der Anmeldung am Primärknoten zu bestätigen, wie in Verwenden von SSH zum Herstellen einer Verbindung mit durch Kerberos geschützten Clustern beschrieben, können Sie den Befehl `hdfs groups` ausführen, um zu bestätigen, dass Active Directory-Gruppen, zu denen Ihr Active Directory-Konto gehört, Hadoop-Gruppen für die entsprechenden Hadoop-Benutzer auf dem Cluster zugeordnet wurden. Sie können auch die Gruppenzuordnungen anderer Benutzer überprüfen, indem Sie einen oder mehrere Benutzernamen im Befehl angeben, z. B. `hdfs groups lijuan`. Weitere Informationen finden Sie unter Groups im Apache HDFS Commands Guide.

Active-Directory- oder LDAP-Server für die Authentifizierung mit Amazon EMR verwenden

Mit Amazon EMR Versionen 6.12.0 und höher können Sie auch das LDAP-over-SSL-Protokoll (LDAPS) verwenden, um einen Cluster zu starten, der sich nativ in Ihren Corporate-Identity-Server integriert. LDAP (Lightweight Directory Access Protocol) ist ein offenes, herstellerneutrales Anwendungsprotokoll, das auf Daten zugreift und diese verwaltet. LDAP wird häufig für die Benutzerauthentifizierung gegen Unternehmensidentitätsserver verwendet, die auf Anwendungen wie Active Directory (AD) und OpenLDAP gehostet werden. Mit dieser nativen Integration können Sie Ihren LDAP-Server verwenden, um Benutzer auf Amazon EMR zu authentifizieren.

Zu den Highlights der Amazon EMR LDAP-Integration gehören:

- Amazon EMR konfiguriert die unterstützten Anwendungen so, dass sie sich in Ihrem Namen mit der LDAP-Authentifizierung authentifizieren.
- Amazon EMR konfiguriert und verwaltet die Sicherheit für die unterstützten Anwendungen mit dem Kerberos-Protokoll. Sie müssen keine Befehle oder Skripte eingeben.
- Sie erhalten eine detaillierte Zugriffskontrolle (FGAC) durch die Apache Ranger-Autorisierung für die Hive-Metastore-Datenbank und -Tabellen. Weitere Informationen finden Sie unter Integrieren Sie Amazon EMR mit Apache Ranger.
- Wenn Sie LDAP-Anmeldeinformationen für den Zugriff auf einen Cluster benötigen, erhalten Sie eine detaillierte Zugriffskontrolle (FGAC) darüber, wer über SSH auf Ihre EMR-Cluster zugreifen kann.

Die folgenden Seiten bieten einen konzeptionellen Überblick, die Voraussetzungen und die Schritte zum Starten eines EMR-Clusters mit der Amazon EMR LDAP-Integration.

Themen

- Übersicht über LDAP mit Amazon EMR
- LDAP-Komponenten für Amazon EMR
- Anwendungsunterstützung und Überlegungen zu LDAP für Amazon EMR
- Konfiguration und Start eines EMR-Clusters mit LDAP
- Beispiele für die Verwendung von LDAP mit Amazon EMR

Übersicht über LDAP mit Amazon EMR

Das Lightweight Directory Access Protocol (LDAP) ist ein Softwareprotokoll, mit dem Netzwerkadministratoren den Zugriff auf Daten verwalten und kontrollieren, indem sie Benutzer im Netzwerk eines Unternehmens authentifizieren. Das LDAP-Protokoll speichert Informationen in einer hierarchischen Verzeichnisstruktur. Weitere Informationen finden Sie unter Basiskonzepte für LDAP auf LDAP.com.

Innerhalb eines Unternehmensnetzwerks verwenden viele Anwendungen möglicherweise das LDAP-Protokoll, um Benutzer zu authentifizieren. Mit der Amazon EMR LDAP-Integration können EMR-Cluster nativ dasselbe LDAP-Protokoll mit einer zusätzlichen Sicherheitskonfiguration verwenden.

Es gibt zwei Hauptimplementierungen des LDAP-Protokolls, die Amazon EMR unterstützt: Active Directory und OpenLDAP. Andere Implementierungen sind zwar möglich, aber die meisten passen zu den gleichen Authentifizierungsprotokollen wie Active Directory oder OpenLDAP.

Active Directory (AD)

Active Directory (AD) ist ein Verzeichnisservice von Microsoft für Windows-Domainnetzwerke. AD ist in den meisten Windows Server-Betriebssystemen enthalten und kann mit Clients über die Protokolle LDAP und LDAPS kommunizieren. Zur Authentifizierung versucht Amazon EMR, eine Benutzerbindung mit Ihrer AD-Instance mit dem User Principal Name (UPN – Benutzer-Prinzipal-Name) als definiertem Namen und Passwort herzustellen. Der UPN verwendet das Standardformat `username@domain_name`.

OpenLDAP

OpenLDAP ist eine kostenlose Open-Source-Implementierung des LDAP-Protokolls. Zur Authentifizierung versucht Amazon EMR, eine Benutzerbindung mit Ihrer AD-Instance mit dem User Principal Name (UPN – Benutzer-Prinzipal-Name) als definiertem Namen und Passwort herzustellen. Der FQDN verwendet das Standardformat `username_attribute=username,LDAP_user_search_base`. In der Regel lautet der `username_attribute` Wert `uid`, und der `LDAP_user_search_base` Wert enthält die Attribute des Baums, der zum Benutzer führt. Zum Beispiel `ou=People,dc=example,dc=com`.

Andere kostenlose Open-Source-Implementierungen des LDAP-Protokolls folgen in der Regel einem ähnlichen FQDN wie OpenLDAP für die eindeutigen Namen ihrer Benutzer.

LDAP-Komponenten für Amazon EMR

Sie können Ihren LDAP-Server verwenden, um sich mit Amazon EMR und allen Anwendungen, die der Benutzer direkt auf dem EMR-Cluster verwendet, über die folgenden Komponenten zu authentifizieren.

Secret Agent

Der Secret Agent ist ein Cluster-Prozess, der alle Benutzeranfragen authentifiziert. Der Secret Agent erstellt die Benutzerbindung an Ihren LDAP-Server im Namen der unterstützten Anwendungen auf dem EMR-Cluster. Der Secret-Agent wird unter Benutzer `emrsecretagent` ausgeführt und schreibt Protokolle in das Verzeichnis `/emr/secretagent/log`. Diese Protokolle enthalten Details zum Status der Authentifizierungsanfrage jedes Benutzers und zu allen Fehlern, die bei der Benutzerauthentifizierung auftreten können.

System Security Services Daemon (SSSD)

SSSD ist ein Daemon, der auf jedem Knoten eines LDAP-fähigen EMR-Clusters läuft. SSSD erstellt und verwaltet einen UNIX-Benutzer, um Ihre Remote-Unternehmensidentität mit jedem

Knoten zu synchronisieren. Yarn-basierte Anwendungen wie Hive und Spark erfordern, dass auf jedem Knoten, der eine Abfrage für einen Benutzer ausführt, ein lokaler UNIX-Benutzer vorhanden ist.

Anwendungsunterstützung und Überlegungen zu LDAP für Amazon EMR

Unterstützte Anwendungen mit LDAP für Amazon EMR

> **Important**
>
> Die auf dieser Seite aufgeführten Anwendungen sind die einzigen Anwendungen, die Amazon EMR für LDAP unterstützt. Um die Clustersicherheit zu gewährleisten, können Sie nur LDAP-kompatible Anwendungen einbeziehen, wenn Sie einen EMR-Cluster mit aktiviertem LDAP erstellen. Wenn Sie versuchen, andere, nicht unterstützte Anwendungen zu installieren, lehnt Amazon EMR Ihre Anfrage für einen neuen Cluster ab.

Die Amazon-EMR-Versionen 6.12 und höher unterstützen die LDAP-Integration mit den folgenden Anwendungen:

- Apache Livy
- Apache Hive über HiveServer2 (HS2)
- Trino
- Presto
- Hue

Sie können auch die folgenden Anwendungen auf einem EMR-Cluster installieren und sie so konfigurieren, dass sie Ihren Sicherheitsanforderungen entsprechen:

- Apache Spark
- Apache Hadoop

Unterstützte Features mit LDAP für Amazon EMR

Mit der LDAP-Integration können Sie die folgenden Amazon-EMR-Feature verwenden:

> **Note**
>
> Um die Sicherheit der LDAP-Anmeldeinformationen zu gewährleisten, müssen Sie die Verschlüsselung während der Übertragung verwenden, um den Datenfluss innerhalb und außerhalb des Clusters zu sichern. Weitere Informationen über Verschlüsselung während der Übertragung finden Sie unter Verschlüsseln von Daten im Ruhezustand und im Transit.

- Verschlüsselung während der Übertragung (erforderlich) und im Ruhestand
- Instance-Gruppen, Instance-Flotten und Spot Instances
- Neukonfiguration von Anwendungen auf einem laufenden Cluster
- Serverseitige Verschlüsselung (SSE) von EMRFS

Nicht unterstützte Funktionen

Berücksichtigen Sie die folgenden Einschränkungen, wenn Sie die Amazon- EMR-LDAP-Integration verwenden:

- Amazon EMR deaktiviert Schritte für Cluster mit aktiviertem LDAP.
- Amazon EMR unterstützt keine Laufzeit-Rollen und AWS Lake Formation-Integrationen für Cluster mit aktiviertem LDAP.
- Amazon EMR unterstützt LDAP mit StartTLS nicht.
- Amazon EMR unterstützt keinen Hochverfügbarkeitsmodus (Cluster mit mehreren Primärknoten) für Cluster mit aktiviertem LDAP.
- Sie können Bind-Anmeldeinformationen oder Zertifikate für Cluster mit aktiviertem LDAP nicht rotieren. Wenn eines dieser Felder rotiert wurde, empfehlen wir, einen neuen Cluster mit den aktualisierten Bindungsanmeldeinformationen oder Zertifikaten zu starten.
- Bei LDAP müssen Sie exakte Suchbasen verwenden. Die LDAP-Benutzer- und Gruppensuchbasis unterstützt keine LDAP-Suchfilter.

Konfiguration und Start eines EMR-Clusters mit LDAP

In diesem Abschnitt wird beschrieben, wie Sie Amazon EMR für die Verwendung mit der LDAP-Authentifizierung konfigurieren können.

Themen

- AWS Secrets Manager-Berechtigungen zur Amazon-EMR-Instance-Rolle hinzufügen
- Erstellen Sie die Amazon-EMR-Sicherheitskonfiguration für die LDAP-Integration
- Starten Sie einen EMR-Cluster, der sich mit LDAP authentifiziert

AWS Secrets Manager-Berechtigungen zur Amazon-EMR-Instance-Rolle hinzufügen

Amazon EMR verwendet eine IAM-Servicerolle, um in Ihrem Namen Aktionen zur Bereitstellung und Verwaltung von Clustern durchzuführen. Die Servicerolle für EC2-Instance-Cluster (auch als EC2-Instance-Profil für Amazon EMR bezeichnet) ist eine spezielle Art von Servicerolle, die jeder EC2-Instance in einem Amazon-EMR-Cluster zugewiesen wird, wenn die Instance startet.

Um die Berechtigungen für einen EMR-Cluster für die Interaktion mit Amazon-S3-Daten und anderen AWS-Services zu definieren, definieren Sie ein benutzerdefiniertes Amazon EC2-Instance-Profil und nicht `EMR_EC2_DefaultRole`, wenn Sie Ihren Cluster starten. Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil) und IAM-Rollen anpassen.

Fügen Sie dem standardmäßigen EC2-Instance-Profil die folgenden Anweisungen hinzu, damit Amazon-EMR-Sitzungen taggen und auf die AWS Secrets Manager zuzugreifen, in denen LDAP-Zertifikate gespeichert sind.

```
    {
      "Sid": "AllowAssumeOfRolesAndTagging",
      "Effect": "Allow",
      "Action": ["sts:TagSession", "sts:AssumeRole"],
      "Resource": [
        "arn:aws:iam::111122223333:role/LDAP_DATA_ACCESS_ROLE_NAME",
        "arn:aws:iam::111122223333:role/LDAP_USER_ACCESS_ROLE_NAME"
      ]
    },
    {
        "Sid": "AllowSecretsRetrieval",
        "Effect": "Allow",
        "Action": "secretsmanager:GetSecretValue",
        "Resource": [
            "arn:aws:secretsmanager:us-east-1:111122223333:secret:LDAP_SECRET_NAME*",
            "arn:aws:secretsmanager:us-
east-1:111122223333:secret:ADMIN_LDAP_SECRET_NAME*"
        ]
    }
```

> **Note**
>
> Ihre Cluster-Anfragen schlagen fehl, wenn Sie bei der Festlegung von Secrets Manager-Berechtigungen das *-Platzhalterzeichen am Ende des geheimen Namens vergessen. Der Platzhalter steht für die geheimen Versionen.
> Sie sollten den Geltungsbereich der AWS Secrets Manager-Richtlinie auch auf die Zertifikate beschränken, die Ihr Cluster für die Bereitstellung von Instances benötigt.

Erstellen Sie die Amazon-EMR-Sicherheitskonfiguration für die LDAP-Integration

Bevor Sie einen EMR-Cluster mit LDAP-Integration starten können, verwenden Sie die Schritte unter Eine Sicherheitskonfiguration erstellen, um eine Amazon-EMR-Sicherheitskonfiguration für den Cluster zu erstellen. Füllen Sie die folgenden Konfigurationen im `LDAPConfiguration` Block unter `AuthenticationConfiguration` oder in den entsprechenden Feldern im Abschnitt Sicherheitskonfigurationen der Amazon-EMR-Konsole aus:

`EnableLDAPAuthentication`

Konsolenoption: Authentifizierungsprotokoll: LDAP

Um die LDAP-Integration zu verwenden, setzen Sie diese Option auf `true` oder wählen Sie sie als Authentifizierungsprotokoll aus, wenn Sie einen Cluster in der Konsole erstellen. Standardmäßig ist `EnableLDAPAuthentication` `true` wenn Sie eine Sicherheitskonfiguration in der Amazon-EMR-Konsole erstellen.

`LDAPServerURL`

Konsolenoption: Standort des LDAP-Servers

Der Speicherort des LDAP-Servers einschließlich des Präfix: `ldaps://`*`location_of_server`*.

`BindCertificateARN`

Konsolenoption: LDAP-SSL-Zertifikat

Der AWS Secrets Manager-ARN, der das Zertifikat zum Signieren des SSL-Zertifikats enthält, das der LDAP-Server verwendet. Wenn Ihr LDAP-Server von einer öffentlichen Zertifizierungsstelle (CA) signiert ist, können Sie einen AWS Secrets Manager-ARN mit einer leeren Datei bereitstellen. Weitere Informationen zum Speichern Ihres Zertifikats in Secrets Manager finden Sie unter Speichern Sie TLS-Zertifikate in AWS Secrets Manager.

`BindCredentialsARN`

Konsolenoption: Anmeldeinformationen: LDAP-Serverbindung

Ein AWS Secrets Manager-ARN, der die Bindungsanmeldeinformationen für den LDAP-Administratorbenutzer enthält. Die Anmeldeinformationen werden als JSON-Objekt gespeichert. In diesem Geheimnis gibt es nur ein Schlüssel-Wert-Paar. Der Schlüssel in dem Paar ist der Benutzername und der Wert ist das Passwort. Zum Beispiel `{"uid=admin,cn=People,dc=example,dc=com": "AdminPassword1"}`. Dies ist ein optionales Feld, es sei denn, Sie aktivieren die SSH-Anmeldung für Ihren EMR-Cluster. In vielen Konfigurationen benötigen Active-Directory-Instances Bindungsanmeldeinformationen, damit SSSD Benutzer synchronisieren kann.

`LDAPAccessFilter`

Konsolenoption: LDAP-Zugriffsfilter

Gibt die Teilmenge der Objekte auf Ihrem LDAP-Server an, die sich authentifizieren können. Wenn Sie beispielsweise allen Benutzern mit der `posixAccount` Objektklasse auf Ihrem LDAP-Server Zugriff gewähren möchten, definieren Sie den Zugriffsfilter als `(objectClass=posixAccount)`.

`LDAPUserSearchBase`

Konsolenoption: LDAP-Benutzersuchbasis

Die Suchbasis, zu der Ihre Benutzer innerhalb Ihres LDAP-Servers gehören. Zum Beispiel `cn=People,dc=example,dc=com`.

`LDAPGroupSearchBase`

Konsolenoption: LDAP-Gruppensuchbasis

Die Suchbasis, zu der Ihre Benutzer innerhalb Ihres LDAP-Servers gehören. Zum Beispiel `cn=Groups,dc=example,dc=com`.

`EnableSSHLogin`

Konsolenoption: SSH-Anmeldung

Gibt an, ob die Kennwortauthentifizierung mit LDAP-Anmeldeinformationen zulässig ist oder nicht. Wir empfehlen nicht, dass Sie diese Option aktiviert lassen. Schlüsselpaare sind eine

sicherere Route, um den Zugriff auf EMR-Cluster zu ermöglichen. Dieses Feld ist optional und standardmäßig auf `false` gesetzt.

`LDAPServerType`

Konsolenoption: LDAP-Servertyp

Gibt den Typ des LDAP-Servers an, mit dem Amazon EMR eine Verbindung herstellt. Unterstützte Optionen sind Active Directory und OpenLDAP. Andere LDAP-Servertypen funktionieren möglicherweise, aber Amazon EMR unterstützt offiziell keine anderen Servertypen. Weitere Informationen finden Sie unter LDAP-Komponenten für Amazon EMR.

`ActiveDirectoryConfigurations`

Ein erforderlicher Unterblock für Sicherheitskonfigurationen, die den Active-Directory-Servertyp verwenden.

`ADDomain`

Konsolenoption: Active-Directory-Domain

Der Domainname, der zur Erstellung des Benutzerprinzipalnamens (UPN) für die Benutzerauthentifizierung mit Sicherheitskonfigurationen verwendet wurde, die den Active-Directory-Servertyp verwenden.

Überlegungen zu Sicherheitskonfigurationen mit LDAP und Amazon EMR

- Um eine Sicherheitskonfiguration mit Amazon-EMR-LDAP-Integration zu erstellen, müssen Sie die Verschlüsselung während der Übertragung verwenden. Informationen zur Verschlüsselung der Daten während der Übertragung finden Sie unter Verschlüsseln von Daten im Ruhezustand und im Transit.
- Sie können die Kerberos-Konfiguration nicht in derselben Sicherheitskonfiguration definieren. Amazon EMR stellt ein KDC bereit, das automatisch für dieses KDC reserviert ist, und verwaltet das Administratorkennwort für dieses KDC. Benutzer können nicht auf dieses Admin-Passwort zugreifen.
- Sie können keine IAM-Laufzeitrollen und AWS Lake Formation in derselben Sicherheitskonfiguration definieren.
- Die `LDAPServerURL` muss das `ldaps://`-Protokoll in ihrem Wert enthalten.
- Der `LDAPAccessFilter` darf nicht leer sein.

Verwenden Sie LDAP mit der Apache-Ranger-Integration für Amazon EMR

Mit der LDAP-Integration für Amazon EMR können Sie die Integration mit Apache Ranger weiter ausbauen. Wenn Sie Ihre LDAP-Benutzer in Ranger abrufen, können Sie diese Benutzer dann einem Apache-Ranger-Richtlinien-Server zuordnen, um sie in Amazon EMR und andere Anwendungen zu integrieren. Definieren Sie dazu das `RangerConfiguration`-Feld in `AuthorizationConfiguration` der Sicherheitskonfiguration, das Sie mit Ihrem LDAP-Cluster verwenden. Weitere Informationen zum Festlegen der Sicherheitskonfiguration finden Sie unter Erstellen einer EMR-Sicherheitskonfiguration.

Wenn Sie LDAP mit Amazon EMR verwenden, müssen Sie `KerberosConfiguration` mit Amazon EMR keine Integration für Apache Ranger bereitstellen.

Starten Sie einen EMR-Cluster, der sich mit LDAP authentifiziert

Führen Sie die folgenden Schritte aus, um einen EMR-Cluster mit LDAP oder Active Directory zu starten.

1. Einrichten Ihrer Umgebung:

   - Stellen Sie sicher, dass die Knoten in Ihrem EMR-Cluster mit Amazon S3 und AWS Secrets Manager kommunizieren können. Weitere Informationen dazu, wie Sie Ihre EC2-Instance-Profilrolle ändern können, um mit diesen Services zu kommunizieren, finden Sie unter AWS Secrets Manager-Berechtigungen zur Amazon-EMR-Instance-Rolle hinzufügen.
   - Wenn Sie Ihren EMR-Cluster in einem privaten Subnetz ausführen möchten, sollten Sie AWS PrivateLink und Amazon-VPC-Endpunkte oder Network Address Transalation (NAT) verwenden, um die VPC für die Kommunikation mit S3 und Secrets Manager zu konfigurieren. Weitere Informationen finden Sie unter AWS PrivateLink und VPC-Endpoints und NAT-Instances im Handbuch für die ersten Schritte mit Amazon VPC.
   - Stellen Sie sicher, dass zwischen Ihrem EMR-Cluster und dem LDAP-Server eine Netzwerkverbindung besteht. Ihre EMR-Cluster müssen über das Netzwerk auf Ihren LDAP-Server zugreifen. Die Primär-, Kern- und Aufgabenknoten für den Cluster kommunizieren mit dem LDAP-Server, um Benutzerdaten zu synchronisieren. Wenn Ihr LDAP-Server auf Amazon EC2 läuft, aktualisieren Sie die EC2-Sicherheitsgruppe, um Datenverkehr vom EMR-Cluster zu akzeptieren. Weitere Informationen finden Sie unter AWS Secrets Manager-Berechtigungen zur Amazon-EMR-Instance-Rolle hinzufügen.

2. Erstellen Sie eine Amazon-EMR-Sicherheitskonfiguration für die LDAP-Integration. Weitere Informationen finden Sie unter Erstellen Sie die Amazon-EMR-Sicherheitskonfiguration für die LDAP-Integration.
3. Nachdem Sie nun eingerichtet sind, gehen Sie wie unter Starten eines Amazon-EMR-Clusters beschrieben vor, um Ihren Cluster mit den folgenden Konfigurationen zu starten:
   - Wählen Sie Amazon EMR Version 6.12. oder höher aus. Es wird empfohlen, ein Upgrade auf die neueste Amazon-EMR-Version durchzuführen.
   - Geben Sie für Ihren Cluster nur Anwendungen an oder wählen Sie sie aus, die LDAP unterstützen. Eine Liste der LDAP-unterstützten Anwendungen mit Amazon EMR finden Sie unter Anwendungsunterstützung und Überlegungen zu LDAP für Amazon EMR.
   - Verwenden Sie die Sicherheitskonfiguration, die Sie im vorherigen Schritt erstellt haben.

Beispiele für die Verwendung von LDAP mit Amazon EMR

Sobald Sie einen EMR-Cluster bereitgestellt haben, der die LDAP-Integration verwendet, können Sie Ihre LDAP-Anmeldeinformationen über den integrierten Authentifizierungsmechanismus für Benutzernamen und Passwörter für jede unterstützte Anwendung bereitstellen. Diese Seite zeigt einige Beispiele.

Verwendung der LDAP-Authentifizierung mit Apache Hive

Example – Apache Hive

Der folgende Beispielbefehl startet eine Apache Hive-Sitzung über HiveServer2 und Beeline:

```
beeline -u "jdbc:hive2://$HOSTNAME:10000/default;ssl=true;sslTrustStore=
$TRUSTSTORE_PATH;trustStorePassword=$TRUSTSTORE_PASS"  -n LDAP_USERNAME -
p LDAP_PASSWORD
```

Verwendung der LDAP-Authentifizierung mit Apache Hive

Example – Apache Livy

Der folgende Beispielbefehl startet eine Livy-Sitzung über cURL. Ersetzen Sie *ENCODED-KEYPAIR* durch eine Base64-kodierte Zeichenfolge für `username:password`.

```
curl -X POST --data '{"proxyUser":"LDAP_USERNAME","kind": "pyspark"}' -H "Content-Type:
 application/json" -H "Authorization: Basic ENCODED-KEYPAIR" DNS_OF_PRIMARY_NODE:8998/
sessions
```

Verwenden der LDAP-Authentifizierung mit Presto

Example – Presto

Der folgende Beispielbefehl startet eine Presto-Sitzung über die Presto-CLI:

```
presto-cli --user "LDAP_USERNAME" --password --catalog hive
```

Nachdem Sie diesen Befehl ausgeführt haben, geben Sie das LDAP-Passwort an der Eingabeaufforderung ein.

Verwenden der LDAP-Authentifizierung mit Trino

Example – Trino

Der folgende Beispielbefehl startet eine Presto-Sitzung über die Presto-CLI:

```
trino-cli --user "LDAP_USERNAME" --password --catalog hive
```

Nachdem Sie diesen Befehl ausgeführt haben, geben Sie das LDAP-Passwort an der Eingabeaufforderung ein.

Verwenden der LDAP-Authentifizierung mit Hue

Sie können über einen SSH-Tunnel, den Sie auf dem Cluster erstellen, auf die Hue-Benutzeroberfläche zugreifen, oder Sie können einen Proxy-Server einrichten, der die Verbindung öffentlich an Hue überträgt. Da Hue standardmäßig nicht im HTTPS-Modus läuft, empfehlen wir die Verwendung einer zusätzlichen Verschlüsselungsebene, um sicherzustellen, dass die Kommunikation zwischen den Clients und der Hue-Benutzeroberfläche mit HTTPS verschlüsselt ist. Dadurch wird die Wahrscheinlichkeit verringert, dass Sie versehentlich Benutzeranmeldeinformationen im Klartext preisgeben.

Um die Hue-Benutzeroberfläche zu verwenden, öffnen Sie die Hue-Benutzeroberfläche in Ihrem Browser und geben Sie Ihren LDAP-Benutzernamen und das Passwort ein, um sich anzumelden. Wenn die Anmeldeinformationen korrekt sind, meldet Hue Sie an und verwendet Ihre Identität, um Sie bei allen unterstützten Anwendungen zu authentifizieren.

Verwendung von SSH für die Passwortauthentifizierung und Kerberos-Tickets für andere Anwendungen

> **Important**
>
> Wir empfehlen nicht, die Passwortauthentifizierung für SSH in einen EMR-Cluster zu verwenden.

Sie können Ihre LDAP-Anmeldeinformationen verwenden, um eine SSH-Verbindung zu einem EMR-Cluster herzustellen. Stellen Sie dazu die `EnableSSHLogin`-Konfiguration in der Amazon-EMR-Sicherheitskonfiguration, die Sie zum Starten des Clusters verwenden, auf `true` ein. Verwenden Sie dann den folgenden Befehl, um per SSH auf den Cluster zuzugreifen, sobald dieser gestartet wurde:

```
ssh username@EMR_PRIMARY_DNS_NAME
```

Nachdem Sie diesen Befehl ausgeführt haben, geben Sie das LDAP-Passwort an der Eingabeaufforderung ein.

Amazon EMR enthält ein Cluster-Skript, das es Benutzern ermöglicht, eine Kerberos-Keytab-Datei und ein Ticket für die Verwendung mit unterstützten Anwendungen zu generieren, die LDAP-Anmeldeinformationen nicht direkt akzeptieren. Einige dieser Anwendungen umfassen `spark-submit`, Spark SQL und PySpark.

Führen Sie `ldap-kinit` aus und befolgen Sie die Eingabeaufforderungen. Wenn die Authentifizierung erfolgreich ist, wird die Kerberos-Keytab-Datei mit einem gültigen Kerberos-Ticket in Ihrem Home-Verzeichnis angezeigt. Verwenden Sie das Kerberos-Ticket, um Anwendungen wie in jeder Kerberized-Umgebung auszuführen.

Integrieren Sie Amazon EMR mit AWS Lake Formation

AWS Lake Formation ist ein verwalteter Service, der Sie dabei unterstützt, Daten in einem Amazon Simple Storage Service (S3) Data Lake zu entdecken, zu katalogisieren, zu bereinigen und zu sichern. Lake Formation bietet differenzierten Zugriff auf Spaltenebene für Datenbanken und Tabellen im AWS Glue-Datenkatalog. Weitere Informationen finden Sie unter Was ist AWS Lake Formation?

Mit Amazon-EMR-Version 6.7.0 und höher können Sie die auf Lake Formation basierende Zugriffskontrolle auf Spark-, Hive- und Presto-Jobs anwenden, die Sie an Amazon-EMR-Cluster senden. Für die Integration mit Lake Formation müssen Sie einen EMR-Cluster mit einer Laufzeit-

Rolle erstellen. Eine Laufzeit-Rolle ist eine AWS Identity and Access Management (IAM)-Rolle, der Sie Amazon-EMR-Aufträge oder Abfragen zuordnen. Amazon EMR verwendet diese Rolle dann für den Zugriff auf AWS-Ressourcen. Weitere Informationen finden Sie unter Schritte für Laufzeit-Rollen für Amazon EMR.

Wie Amazon EMR mit Lake Formation funktioniert

Nachdem Sie Amazon EMR mit Lake Formation integriert haben, können Sie Abfragen an Amazon-EMR-Cluster mit der `Step`-API oder mit SageMaker Studio ausführen. Anschließend bietet Lake Formation über temporäre Anmeldeinformationen für Amazon EMR Zugriff auf Daten. Dieser Prozess wird als Anmeldeinformationsvergabe bezeichnet. Weitere Informationen finden Sie unter Was ist AWS Lake Formation?

Nachfolgend finden Sie einen allgemeinen Überblick darüber, wie Amazon EMR Zugriff auf Daten erhält, die durch Sicherheitsrichtlinien von Lake Formation geschützt sind.

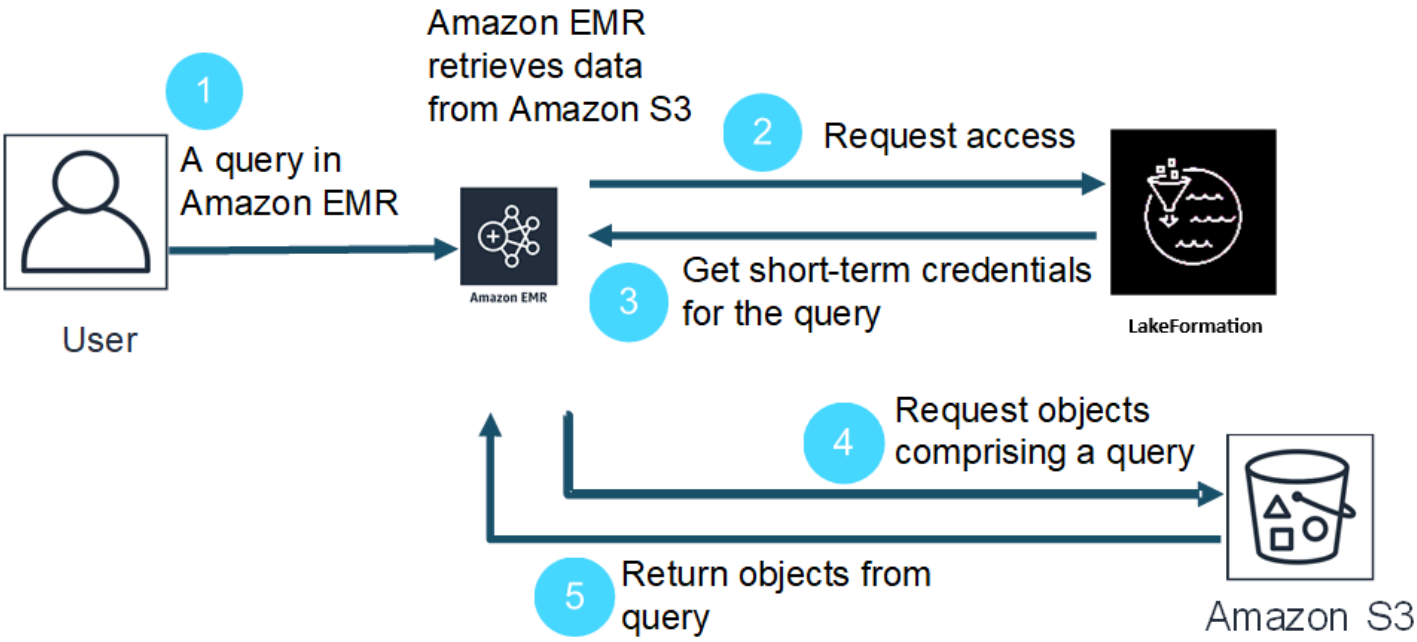

1. Ein Benutzer sendet eine Amazon-EMR-Abfrage für Daten in Lake Formation.
2. Amazon EMR fordert temporäre Anmeldeinformationen von Lake Formation an, um den Benutzerdaten Zugriff zu gewähren.
3. Lake Formation gibt temporäre Anmeldeinformationen zurück.
4. Amazon EMR sendet die Abfrageanfrage zum Abrufen von Daten aus Amazon S3.
5. Amazon EMR empfängt die Daten von Amazon S3, filtert sie und gibt Ergebnisse zurück, die auf den Benutzerberechtigungen basieren, die der Benutzer in Lake Formation definiert hat.

Weitere Informationen zum Hinzufügen von Benutzern und Gruppen zu Lake Formation-Richtlinien finden Sie unter Erteilen von Datenkatalogberechtigungen.

Voraussetzungen

Sie müssen die folgenden Anforderungen erfüllen, bevor Sie Amazon EMR und Lake Formation integrieren können:

- Aktivieren Sie die Laufzeit-Rollenautorisierung in Ihrem Amazon-EMR-Cluster.
- Der AWS Glue-Datenkatalog wird als Metadatenspeicher verwendet.
- Definieren und verwalten Sie Berechtigungen in Lake Formation, um auf Datenbanken, Tabellen und Spalten in AWS Glue Data Catalog zuzugreifen. Weitere Informationen finden Sie unter Was ist AWS Lake Formation?

Themen

- Wie Amazon EMR mit Lake Formation funktioniert
- Apache Hudi und Lake Formation
- Überlegungen

Wie Amazon EMR mit Lake Formation funktioniert

In diesem Abschnitt erfahren Sie, wie Sie eine Sicherheitskonfiguration erstellen und Lake Formation so einrichten, dass es mit Amazon EMR funktioniert. Wir gehen auch darauf ein, wie Sie einen Cluster mit der Sicherheitskonfiguration starten, die Sie für Lake Formation erstellt haben.

Schritt 1: Eine Laufzeit-Rolle für Ihren EMR-Cluster einrichten

Um die Laufzeit-Rolle für Ihren Cluster einzurichten, erstellen Sie eine Sicherheitskonfiguration. Mit einer Sicherheitskonfiguration können Sie konsistente Sicherheits-, Autorisierungs- und Authentifizierungsoptionen für alle Ihre Cluster anwenden.

1. Erstellen Sie eine Datei mit dem Namen `lf-runtime-roles-sec-cfg.json` und den folgenden Inhalten.

```
{
    "AuthorizationConfiguration":{
        "IAMConfiguration":{
            "EnableApplicationScopedIAMRole":true,
```

```
            "ApplicationScopedIAMRoleConfiguration":{
                "PropagateSourceIdentity":true
            }
        },
        "LakeFormationConfiguration":{
            "AuthorizedSessionTagValue":"Amazon EMR"
        },
  "EncryptionConfiguration": {
            "EnableInTransitEncryption": true,
            "InTransitEncryptionConfiguration": {
            "TLSCertificateConfiguration": {<Certificate-configuration>}
        }
    }
}
```

2. Um als Nächstes sicherzustellen, dass das Sitzungs-Tag Lake Formation autorisieren kann, setzen Sie die `LakeFormationConfiguration/AuthorizedSessionTagValue`-Eigenschaft auf `Amazon EMR`.
3. Verwenden Sie den folgenden Befehl, um die Amazon EMR-Sicherheitskonfiguration zu erstellen.

```
aws emr create-security-configuration \
--name 'iamconfig-with-iam-lf' \
--security-configuration file://lf-runtime-roles-sec-cfg.json
```

Alternativ können Sie die Amazon-EMR-Konsole verwenden, um eine Sicherheitskonfiguration mit benutzerdefinierten Einstellungen zu erstellen.

Schritt 2: Starten eines Amazon-EMR-Clusters

Jetzt sind Sie bereit, einen EMR-Cluster mit der Sicherheitskonfiguration zu starten, die Sie im vorherigen Schritt erstellt haben. Weitere Informationen zum Erstellen einer Sicherheitskonfiguration finden Sie unter Sicherheitskonfigurationen zum Einrichten der Cluster-Sicherheit verwenden und Schritte für Laufzeit-Rollen für Amazon EMR.

Schritt 4: Die auf Lake Formation basierende Zugriffskontrolle mit Amazon-EMR-Laufzeit-Rollen einrichten

Um Berechtigungen auf Tabellen- und Spaltenebene mit Lake Formation anzuwenden, muss der Data-Lake-Administrator für Lake Formation `Amazon EMR` als Wert für die Sitzungs-Tag-

Konfiguration `AuthorizedSessionTagValue` festlegen. Lake Formation verwendet dieses Sitzungs-Tag, um Anrufer zu autorisieren und Zugriff auf den Data Lake zu gewähren. Sie können dieses Sitzungs-Tag im Abschnitt Externe Datenfilterung der Lake-Formation-Konsole festlegen. Ersetzen Sie *123456789012* durch Ihre eigene AWS-Konto-ID.

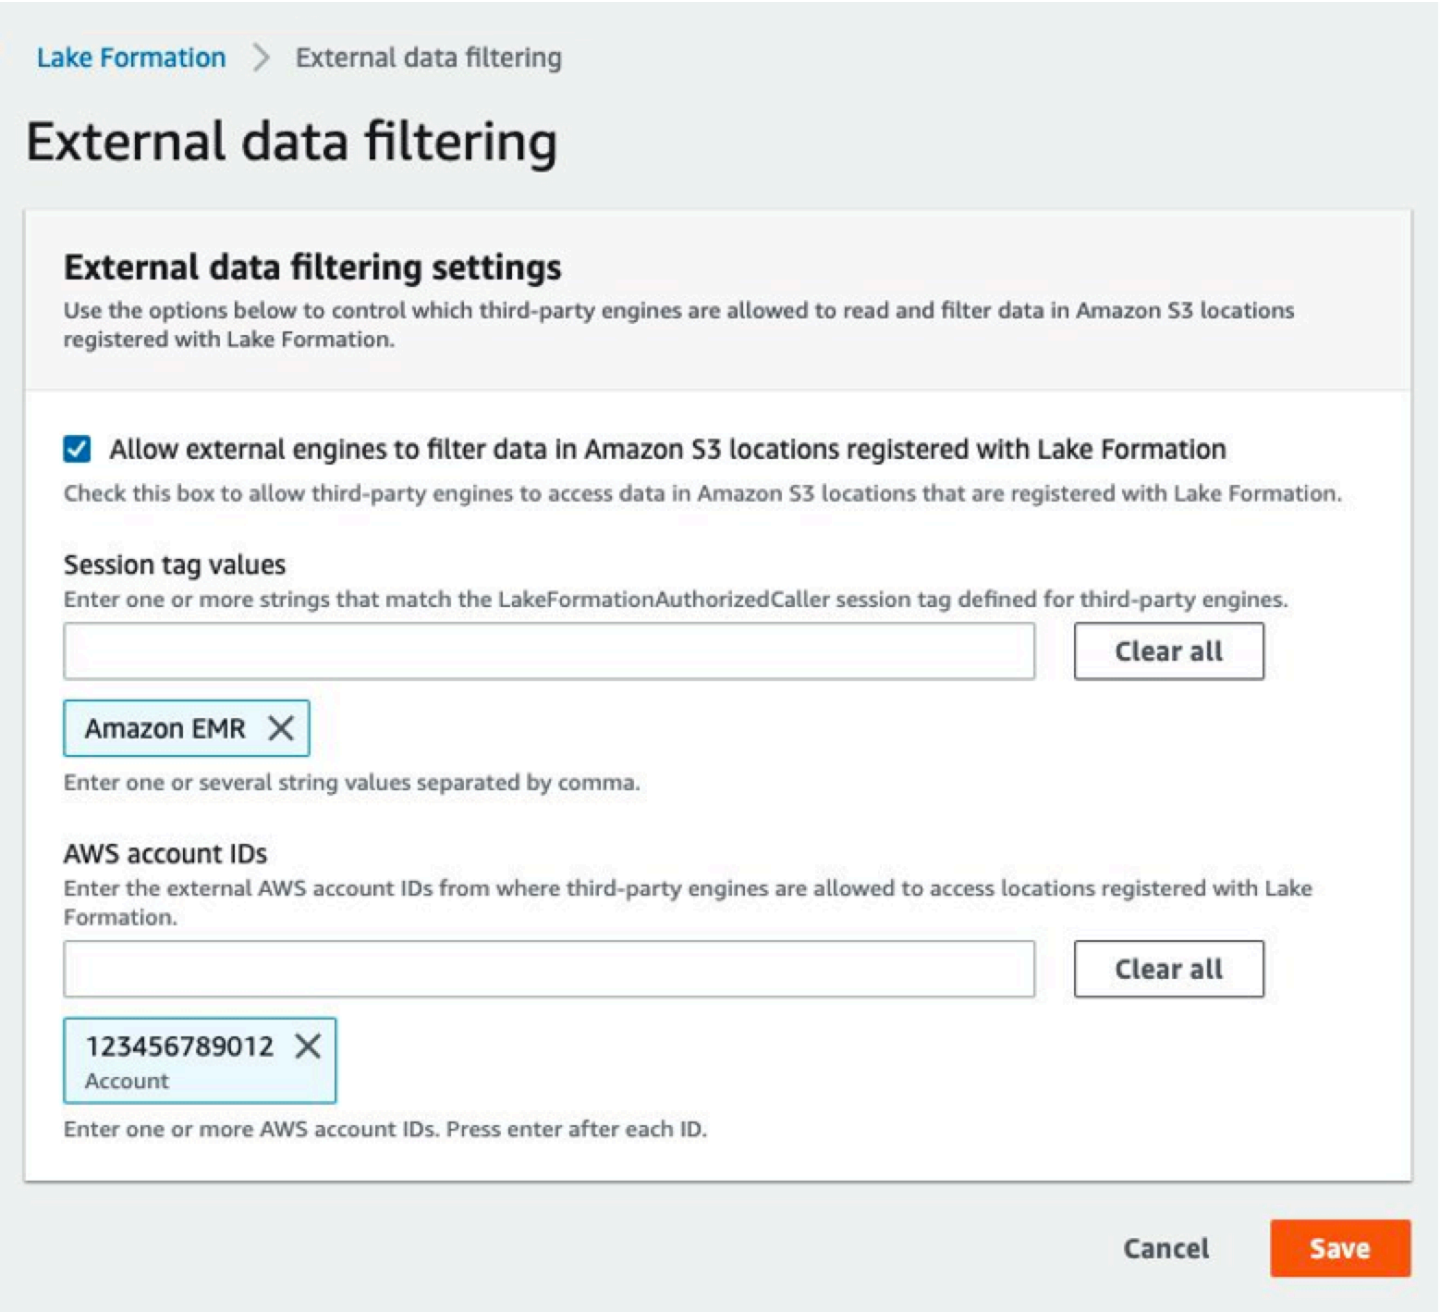

Um mit der Einrichtung der auf Lake Formation basierenden Zugriffskontrolle mit Amazon-EMR-Runtime-Rollen fortzufahren, müssen Sie AWS-Glue- und Lake-Formation-Grants für Amazon-EMR-Laufzeit-Rollen konfigurieren. Damit Ihre IAM-Laufzeitrollen mit Lake Formation interagieren können, gewähren Sie ihnen Zugriff mit `lakeformation:GetDataAccess` und `glue:Get*`.

Lake-Formation-Berechtigungen kontrollieren den Zugriff auf Ressourcen von AWS Glue Data Catalog, Amazon-S3-Standorte und die zugrunde liegenden Daten an diesen Standorten. IAM-Berechtigungen steuern den Zugriff auf die APIs und AWS-Ressourcen von Lake Formation und Glue. Obwohl Sie möglicherweise über die Lake-Formation-Berechtigung verfügen, auf eine Tabelle im Datenkatalog (SELECT) zuzugreifen, schlägt Ihr Vorgang fehl, wenn Sie nicht über die IAM-Berechtigung für die `glue:Get*`-API verfügen. Weitere Informationen zur Zugriffskontrolle für Lake Formation finden Sie unter Übersicht über die Zugriffskontrolle für Lake Formation.

1. Erstellen Sie die Datei `emr-runtime-roles-lake-formation-policy.json` mit folgendem Inhalt.

```
{
    "Version": "2012-10-17",
    "Statement": {
        "Sid": "LakeFormationManagedAccess",
        "Effect": "Allow",
        "Action": [
            "lakeformation:GetDataAccess",
            "glue:Get*",
            "glue:Create*",
            "glue:Update*"
        ],
        "Resource": "*"
    }
}
```

2. Erstellen Sie die zugehörige IAM-Richtlinie.

```
aws iam create-policy \
--policy-name emr-runtime-roles-lake-formation-policy \
--policy-document file://emr-runtime-roles-lake-formation-policy.json
```

3. Um diese Richtlinie Ihren IAM-Laufzeit-Rollen zuzuweisen, folgen Sie den Schritten unter Verwalten von AWS Lake Formation-Berechtigungen.

Sie können jetzt Laufzeit-Rollen und Lake Formation verwenden, um Berechtigungen auf Tabellen- und Spaltenebene anzuwenden. Sie können auch eine Quellidentität verwenden, um Aktionen zu steuern und Vorgänge mit AWS CloudTrail zu überwachen. Ein ausführliches durchgehendes Beispiel finden Sie unter Einführung von Laufzeit-Rollen für Amazon-EMR-Schritte.

Apache Hudi und Lake Formation

Amazon-EMR-Version 6.9.0 und höher bietet eingeschränkte Unterstützung für die auf Lake Formation basierende Zugriffskontrolle mit Apache Hudi beim Lesen von Daten mit Spark SQL. Amazon EMR unterstützt SELECT-Abfragen mit Spark SQL und ist auf die Zugriffskontrolle auf Spaltenebene beschränkt. Ab diesem Feature können Sie jetzt Folgendes ausführen:

- Snapshot-Abfragen von Copy-on-Write-Tabellen, um den neuesten Snapshot der Tabelle zu einem bestimmten Commit- oder Komprimierungszeitpunkt abzufragen.
- Leseoptimierte Abfragen für Merge-on-Read-Tabellen, um die neuesten komprimierten Daten abzufragen, die möglicherweise nicht die neuesten Aktualisierungen in den Protokolldateien enthalten, die noch nicht komprimiert wurden.

Die folgende Unterstützungsmatrix listet einige Kernfeatures von Apache Hudi mit Lake Formation auf:

	Kopieren Sie beim Schreiben	Beim Lesen zusammenführen (MoR)
Snapshot-Abfragen – Spark SQL	Y	N
Optimierte Abfragen lesen – Spark SQL	Nicht zutreffend	Y
Inkrementelle Abfrage	N	N
Zeitreiseabfragen	N	N
Spark-Datenquellenabfragen	N	N
Spark Datenquellenschreiben	N	N
DML/DDL	N	N
Tabellenmetadaten	N	N

Abfragen von Hudi-Tabellen

In diesem Abschnitt wird gezeigt, wie Sie die oben beschriebenen unterstützten Abfragen auf einem Lake-Formation-fähigen Cluster ausführen können. Bei der Tabelle sollte es sich um eine registrierte Katalogtabelle handeln.

In diesem Abschnitt wird gezeigt, wie die Abfragen ausgeführt werden, die auf einem Lake-Formation-Cluster unterstützt werden, wie zuvor angegeben

1. Verwenden Sie die folgenden Befehle, um die Spark-Shell zu starten.

```
spark-shell  --jars /usr/lib/hudi/hudi-spark-bundle.jar \
--conf 'spark.serializer=org.apache.spark.serializer.KryoSerializer'
```

```
spark-sql  --jars /usr/lib/hudi/hudi-spark-bundle.jar \
--conf 'spark.serializer=org.apache.spark.serializer.KryoSerializer'
```

2. Verwenden Sie die folgenden Befehle, um den neuesten Snapshot von Copy-on-Write-Tabellen abzufragen.

```
select * from <my_hudi_cow_table>
```

```
spark.read.table("<my_hudi_cow_table>")
```

3. Um die neuesten komprimierten Daten von MOR-Tabellen abzufragen, können Sie die leseoptimierte Tabelle mit dem Suffix _ro abfragen:

```
SELECT * from <my_hudi_mor_table>_ro
```

```
spark.read.table("<my_hudi_mor_table>_ro")
```

> **Note**
>
> Die Leistung von Lesevorgängen auf Lake Formation-Clustern kann aufgrund von Optimierungen, die nicht unterstützt werden, langsamer sein. Zu diesen Features gehören das Auflisten von Dateien auf der Grundlage von Hudi-Metadaten und das Überspringen von

Daten. Wir empfehlen Ihnen, die Leistung Ihrer Anwendung zu testen, um sicherzustellen, dass sie Ihrem SLA entspricht.

Überlegungen

Beachten Sie Folgendes, wenn Sie Amazon EMR mit AWS Lake Formation verwenden.

- Benutzer mit Zugriff auf eine Tabelle können auf alle Eigenschaften dieser Tabelle zugreifen. Wenn Sie eine auf Lake Formation basierende Zugriffskontrolle für eine Tabelle haben, überprüfen Sie die Tabelle, um sicherzustellen, dass die Eigenschaften keine vertraulichen Daten oder Informationen enthalten.
- Amazon-EMR-Cluster mit Lake Formation unterstützen den Fallback von Spark auf HDFS nicht, wenn Spark Tabellenstatistiken sammelt. Dies trägt normalerweise zur Optimierung der Abfrageleistung bei.
- Zu den Vorgängen, die Zugriffskontrollen auf der Grundlage von Lake Formation mit nicht verwalteten Apache Spark- und Apache Hive-Tabellen (ab Amazon EMR 6.10.0 und höher) unterstützen, gehören `insert into` und `insert overwrite`.
- Zu den Vorgängen, die auf Lake Formation mit Apache Spark und Apache Hive basierende Zugriffskontrollen unterstützen `select`, `describe`, `show database`, `show table`, `show column` und `show partition`.
- Amazon EMR unterstützt keinen kontrollierten Zugriff auf die folgenden auf Lake Formation basierenden Operationen:
  - Schreibt in geregelte Tabellen
  - Der Datenfilter für Lake Formation
  - DDL-Anweisungen wie CREATE oder ALTER table
- Es gibt Leistungsunterschiede zwischen derselben Abfrage mit und ohne Lake-Formation-basierte Zugriffskontrolle.

Integrieren Sie Amazon EMR mit Apache Ranger

Mit Amazon EMR 5.32.0 können Sie einen Cluster starten, der nativ in Apache Ranger integriert ist. Apache Ranger ist ein Open-Source-Framework zur Aktivierung, Überwachung und Verwaltung einer umfassenden Datensicherheit auf der gesamten Hadoop-Plattform. Weitere Informationen finden

Sie unter Apache Ranger. Dank der nativen Integration können Sie Ihren eigenen Apache Ranger verwenden, um eine detaillierte Datenzugriffskontrolle auf Amazon EMR durchzusetzen.

Dieser Abschnitt bietet eine konzeptionelle Übersicht über die Amazon-EMR-Integration in Apache Ranger. Außerdem werden die Voraussetzungen und Schritte zum Starten eines in Apache Ranger integrierten Amazon-EMR-Clusters beschrieben.

Die native Integration von Amazon EMR mit Apache Ranger bietet die folgenden Hauptvorteile:

- Präzise Zugriffskontrolle für Hive Metastore-Datenbanken und -Tabellen, mit der Sie Datenfilterungsrichtlinien auf Datenbank-, Tabellen- und Spaltenebene für Apache Spark- und Apache Hive-Anwendungen definieren können. Filterung und Datenmaskierung auf Zeilenebene werden von Hive-Anwendungen unterstützt.
- Die Möglichkeit, Ihre bestehenden Hive-Richtlinien direkt mit Amazon EMR for Hive-Anwendungen zu verwenden.
- Zugriffskontrolle auf Amazon S3-Daten auf Präfix- und Objektebene, sodass Sie Datenfilterrichtlinien für den Zugriff auf S3-Daten mithilfe des EMR-Dateisystems definieren können.
- Die Möglichkeit, CloudWatch Logs für zentralisierte Prüfungen zu verwenden.
- Amazon EMR installiert und verwaltet die Apache Ranger-Plugin Ihrem Namen.

Apache Ranger

Apache Ranger ist ein Framework zur Aktivierung, Überwachung und Verwaltung einer umfassenden Datensicherheit auf der gesamten Hadoop-Plattform.

Apache Ranger bietet folgende Features:

- Zentralisierte Sicherheitsadministration zur Verwaltung aller sicherheitsrelevanten Aufgaben in einer zentralen Benutzeroberfläche oder mithilfe von REST-APIs.
- Detaillierte Autorisierung zur Durchführung einer bestimmten Aktion oder Operation mit einer Hadoop-Komponente oder einem Hadoop-Tool, die über ein zentrales Administrationstool verwaltet wird.
- Eine standardisierte Autorisierungsmethode für alle Hadoop-Komponenten.
- Verbesserte Unterstützung für verschiedene Autorisierungsmethoden.
- Zentralisierte Prüfung des Benutzerzugriffs und der administrativen Aktionen (sicherheitsbezogen) innerhalb aller Komponenten von Hadoop.

Apache Ranger verwendet zwei Schlüsselkomponenten für die Autorisierung:

- Apache-Ranger-Richtlinien-Admin-Server – Mit diesem Server können Sie die Autorisierungsrichtlinien für Hadoop-Anwendungen definieren. Bei der Integration mit Amazon EMR können Sie Richtlinien für Apache Spark und Hive für den Zugriff auf Hive Metastore und für den Zugriff auf Amazon-S3-Daten im EMR File System (EMRFS) definieren und durchsetzen. Sie können einen neuen Apache-Ranger-Richtlinien-Admin-Server einrichten oder einen vorhandenen Apache-Ranger-Richtlinien-Admin-Server für die Integration mit Amazon EMR verwenden.
- Apache-Ranger-Plugin – Dieses Plugin validiert den Zugriff eines Benutzers anhand der Autorisierungsrichtlinien, die im Apache-Ranger-Richtlinien-Admin-Server definiert sind. Amazon EMR installiert und konfiguriert das Apache-Ranger-Plugin automatisch für jede Hadoop-Anwendung, die in der Apache-Ranger-Konfiguration ausgewählt wurde.

Themen

- Architektur der Amazon-EMR-Integration mit Apache Ranger
- Komponenten für Amazon EMR

Architektur der Amazon-EMR-Integration mit Apache Ranger

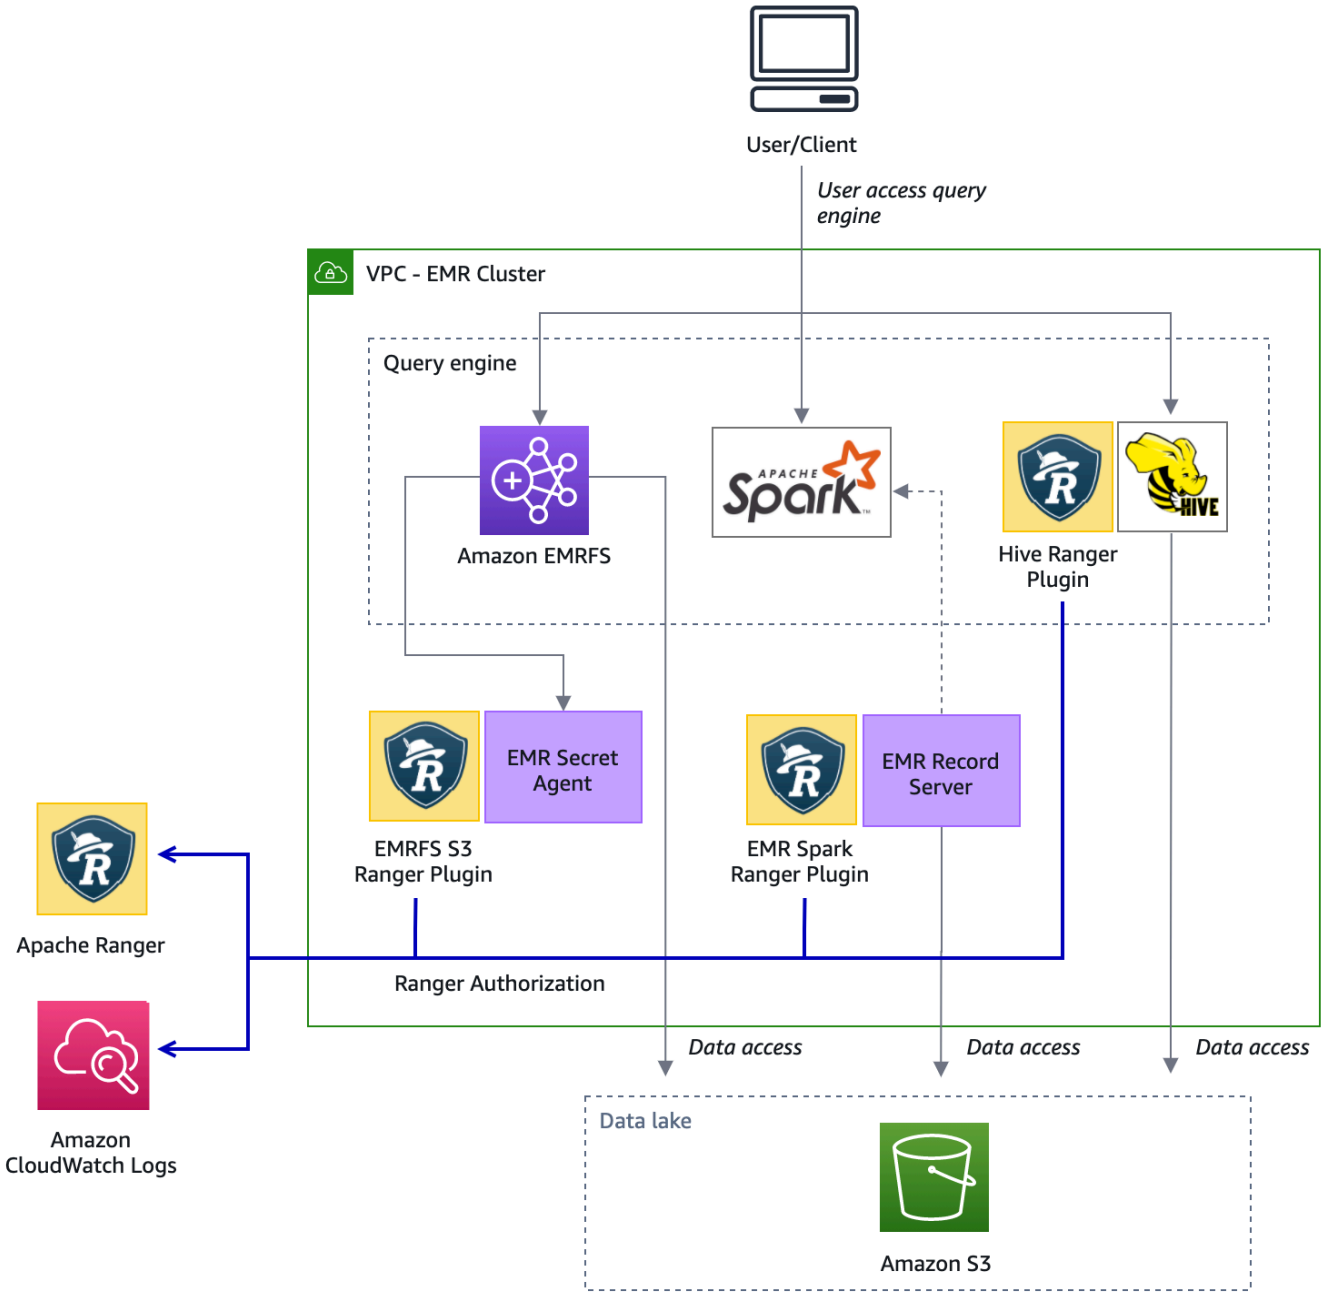

Komponenten für Amazon EMR

Amazon EMR ermöglicht eine differenzierte Zugriffskontrolle mit Apache Ranger über die folgenden Komponenten. Im Architekturdiagramm finden Sie eine visuelle Darstellung dieser Amazon-EMR-Komponenten mit den Apache-Ranger-Plugins.

Secret-Agent – Der Secret-Agent speichert geheime Daten sicher und verteilt sie an andere Amazon-EMR-Komponenten oder Anwendungen. Bei diesen geheimen Daten („Secrets“) kann es sich beispielsweise um temporäre Anmeldeinformationen von Benutzern, um Verschlüsselungsschlüssel oder um Kerberos-Tickets handeln. Der Secret Agent läuft auf jedem Knoten im Cluster und fängt Aufrufe an den Instance Metadata Service ab. Für Anfragen an die Rollenanmeldedaten des Instance-Profils vergibt der Secret Agent je nach dem anfragenden Benutzer und den angeforderten Ressourcen Anmeldeinformationen, nachdem er die Anfrage mit dem EMRFS-S3-Ranger-Plugin autorisiert hat. Der Secret-Agent wird unter Benutzer *`emrsecretagent`* ausgeführt und schreibt Protokolle in das Verzeichnis /emr/secretagent/log directory. Der Prozess benötigt eine bestimmte Zusammenstellung von `iptables`-Regeln, um zu funktionieren. Es ist wichtig sicherzustellen, dass `iptables` nicht deaktiviert ist. Wenn Sie die `iptables`-Konfiguration anpassen, müssen die NAT-Tabellenregeln beibehalten und unverändert bleiben.

EMR Datensatzserver – Der Datensatzserver empfängt Anforderungen für den Zugriff auf Daten von Spark. Anschließend autorisiert es Anfragen, indem es die angeforderten Ressourcen an das Spark-Ranger-Plugin für Amazon EMR weiterleitet. Der Datensatzserver liest Daten von Amazon S3 und gibt gefilterte Daten zurück, auf die der Benutzer gemäß der Ranger-Richtlinie zugreifen darf. Der Datensatzserver läuft auf jedem Knoten im Cluster als Benutzer emr_record_server und schreibt Protokolle in das Verzeichnis /var/log/emr-record-server.

Anwendungsunterstützung und Einschränkungen

Unterstützte Anwendungen

Die Integration zwischen Amazon EMR und Apache Ranger, in der EMR Ranger-Plugins installiert, unterstützt derzeit die folgenden Anwendungen:

- Apache Spark (verfügbar mit EMR 5.32+ und EMR 6.3+)
- Apache Spark (verfügbar mit EMR 5.32+ und EMR 6.3+)
- S3-Zugriff über EMRFS (verfügbar mit EMR 5.32+ und EMR 6.3+)

Sie können auch die folgenden Anwendungen auf einem EMR-Cluster installieren und sie so konfigurieren, dass sie Ihren Sicherheitsanforderungen entsprechen:

- Apache Hadoop (verfügbar mit EMR 5.32+ und EMR 6.3+ einschließlich YARN und HDFS)
- Apache Livy (verfügbar mit EMR 5.32+ und EMR 6.3+)
- Apache Zeppelin (verfügbar mit EMR 5.32+ und EMR 6.3+)

- Apache Hue (verfügbar mit EMR 5.32+ und EMR 6.3+)
- Ganglia (verfügbar mit EMR 5.32+ und EMR 6.3+)
- HCatalog (verfügbar mit EMR 5.32+ und EMR 6.3+)
- Mahout (verfügbar mit EMR 5.32+ und EMR 6.3+)
- MXNet (verfügbar mit EMR 5.32+ und EMR 6.3+)
- TensorFlow(verfügbar mit EMR 5.32+ und EMR 6.3+)
- Tez (Verfügbar mit EMR 5.32+ und EMR 6.3+)
- Trino (Verfügbar mit EMR 6.7+)
- ZooKeeper (verfügbar mit EMR 5.32+ und EMR 6.3+)

> **Important**
>
> Die oben aufgeführten Anwendungen sind die einzigen Anwendungen, die derzeit unterstützt werden. Um die Clustersicherheit zu gewährleisten, dürfen Sie einen EMR-Cluster nur mit den Anwendungen in der obigen Liste erstellen, wenn Apache Ranger aktiviert ist.
> Andere Anwendungen werden derzeit nicht unterstützt. Um die Sicherheit Ihres Clusters zu gewährleisten, führt der Versuch, andere Anwendungen zu installieren, zur Ablehnung Ihres Clusters.

Unterstützte Funktionen

Die folgenden Amazon-EMR-Features können mit Amazon EMR und Apache Ranger verwendet werden:

- Verschlüsselung bei Speicherung und Übertragung
- Kerberos-Authentifizierung (erforderlich)
- Instance-Gruppen, Instance-Flotten und Spot Instances
- Neukonfiguration von Anwendungen auf einem laufenden Cluster
- Serverseitige Verschlüsselung (SSE) von EMRFS

> **Note**
>
> Die Amazon-EMR-Verschlüsselungseinstellungen regeln SSE. Weitere Informationen finden Sie unter Verschlüsselungsoptionen.

Einschränkungen der Anwendung

Bei der Integration von Amazon EMR und Apache Ranger sind mehrere Einschränkungen zu beachten:

- Sie können die Konsole derzeit nicht zum Erstellen einer Sicherheitskonfiguration verwenden, die die AWS-Ranger-Integrationsoption in der AWS GovCloud (US) Region angibt. Die Sicherheitskonfiguration kann mit der CLI durchgeführt werden.
- Kerberos muss in Ihrem Cluster installiert sein.
- Anwendungs-UIs (Benutzeroberflächen) wie die YARN-Resource-Manager-UI, die HDFS-NameNode-UI und die Livy-Benutzeroberfläche sind standardmäßig nicht mit Authentifizierung ausgestattet.
- Die HDFS-Standardberechtigungen `umask` sind so konfiguriert, dass erstellte Objekte standardmäßig auf `world wide readable` eingestellt sind.
- Amazon EMR unterstützt den Hochverfügbarkeitsmodus (mehrere Primärtypen) mit Apache Ranger nicht.
- Weitere Einschränkungen finden Sie unter Einschränkungen für jede Anwendung.

> **Note**
>
> Die Amazon-EMR-Verschlüsselungseinstellungen regeln SSE. Weitere Informationen finden Sie unter Verschlüsselungsoptionen.

Einschränkungen des Plugins

Jedes Plugin hat spezifische Einschränkungen. Die Einschränkungen des Apache-Hive-Plugins finden Sie unter Einschränkungen des Apache-Hive-Plugins. Die Einschränkungen des Apache-Spark-Plugins finden Sie unter Einschränkungen des Apache-Spark-Plugins. Die Einschränkungen des EMRFS-S3-Plugins finden Sie unter Einschränkungen des EMRFS-S3-Plugins.

Amazon EMR für Apache Ranger einrichten

Bevor Sie Apache Ranger installieren, überprüfen Sie die Informationen in diesem Abschnitt, um sicherzustellen, dass Amazon EMR ordnungsgemäß konfiguriert ist.

Themen

- Richten Sie den Ranger-Admin-Server ein
- IAM-Rollen für die native Integration mit Apache Ranger
- Erstellen einer EMR-Sicherheitskonfiguration
- Speichern Sie TLS-Zertifikate in AWS Secrets Manager
- Einen EMR-Cluster starten
- Zeppelin für Apache-Ranger-fähige Amazon-EMR-Cluster konfigurieren
- Bekannte Probleme

Richten Sie den Ranger-Admin-Server ein

Für die Amazon-EMR-Integration müssen die Apache-Ranger-Anwendungs-Plugins über TLS/SSL mit dem Admin-Server kommunizieren.

Voraussetzung: SSL-Aktivierung des Ranger-Admin-Servers

Apache Ranger auf Amazon EMR erfordert bidirektionale SSL-Kommunikation zwischen Plugins und dem Ranger-Admin-Server. Um sicherzustellen, dass Plugins über SSL mit dem Apache-Ranger-Server kommunizieren, aktivieren Sie das folgende Attribut in ranger-admin-site.xml auf dem Ranger-Admin-Server.

```
<property>
    <name>ranger.service.https.attrib.ssl.enabled</name>
    <value>true</value>
</property>
```

Darüber hinaus sind die folgenden Konfigurationen erforderlich.

```
<property>
    <name>ranger.https.attrib.keystore.file</name>
    <value>_<PATH_TO_KEYSTORE>_</value>
```

```
</property>

<property>
    <name>ranger.service.https.attrib.keystore.file</name>
    <value>_<PATH_TO_KEYSTORE>_</value>
</property>

<property>
    <name>ranger.service.https.attrib.keystore.pass</name>
    <value>_<KEYSTORE_PASSWORD>_</value>
</property>

<property>
    <name>ranger.service.https.attrib.keystore.keyalias</name>
    <value><PRIVATE_CERTIFICATE_KEY_ALIAS></value>
</property>

<property>
    <name>ranger.service.https.attrib.clientAuth</name>
    <value>want</value>
</property>

<property>
    <name>ranger.service.https.port</name>
    <value>6182</value>
</property>
```

TLS-Zertifikate

Die Apache-Ranger-Integration mit Amazon EMR erfordert, dass der Datenverkehr von Amazon-EMR-Knoten zum Ranger-Admin-Server mit TLS verschlüsselt wird und dass Ranger-Plugins sich beim Apache-Ranger-Server mithilfe der wechselseitigen TLS-Authentifizierung authentifizieren. Der Amazon-EMR-Service benötigt das öffentliche Zertifikat Ihres Ranger- Admin-Servers (wie im vorherigen Beispiel angegeben) und das private Zertifikat.

Zertifikate für das Apache-Ranger-Plugin

Öffentliche TLS-Zertifikate für das Apache Ranger-Plugin müssen für den Apache-Ranger-Admin-Server zugänglich sein, um zu überprüfen, wann die Plugins eine Verbindung herstellen. Es gibt drei verschiedene Methoden, dies zu tun.

Methode 1: Konfigurieren Sie einen Truststore auf dem Apache-Ranger-Admin-Server

Füllen Sie die folgenden Konfigurationen in ranger-admin-site.xml aus, um einen Truststore zu konfigurieren.

```
<property>
    <name>ranger.truststore.file</name>
    <value><LOCATION TO TRUSTSTORE></value>
</property>

<property>
    <name>ranger.truststore.password</name>
    <value><PASSWORD FOR TRUSTSTORE></value>
</property>
```

Methode 2: Laden Sie das Zertifikat in den Truststore von Java cacerts

Wenn Ihr Ranger- Admin-Server in seinen JVM-Optionen keinen Truststore angibt, können Sie die öffentlichen Plugin-Zertifikate im Standard-Cacerts-Speicher ablegen.

Methode 3: Erstellen Sie einen Truststore und geben Sie ihn als Teil der JVM-Optionen an

Ändern Sie die `{RANGER_HOME_DIRECTORY}/ews/ranger-admin-services.sh` innerhalb von `JAVA_OPTS`, dass sie "`-Djavax.net.ssl.trustStore=<TRUSTSTORE_LOCATION>`" und "`-Djavax.net.ssl.trustStorePassword=<TRUSTSTORE_PASSWORD>`" einschließt. Fügen Sie beispielsweise die folgende Zeile nach dem vorhandenen JAVA_OPTS hinzu.

```
JAVA_OPTS=" ${JAVA_OPTS} -Djavax.net.ssl.trustStore=${RANGER_HOME}/truststore/
truststore.jck -Djavax.net.ssl.trustStorePassword=changeit"
```

> **Note**
>
> Diese Spezifikation kann das Truststore-Passwort offenlegen, wenn sich ein Benutzer beim Apache- Ranger Admin-Server anmelden und laufende Prozesse sehen kann, z. B. wenn er den `ps`-Befehl verwendet.

Verwenden selbstsignierter Zertifikate

Selbstsignierte Zertifikate werden als Zertifikate nicht empfohlen. Selbstsignierte Zertifikate können nicht gesperrt werden, und selbstsignierte Zertifikate entsprechen möglicherweise nicht den internen Sicherheitsanforderungen.

Installation der Servicedefinition

Eine Servicedefinition wird vom Ranger-Admin-Server verwendet, um die Attribute von Richtlinien für eine Anwendung zu beschreiben. Die Richtlinien werden dann in einem Richtlinien-Repository gespeichert, sodass die Clients sie herunterladen können.

Um Servicedefinitionen konfigurieren zu können, müssen REST-Aufrufe an den Ranger-Admin-Server getätigt werden. Informationen zu den erforderlichen APIs finden Sie im folgenden Abschnitt unter Apache Ranger PublicApisV2.

Installation der Servicedefinition von Apache Spark

Informationen zur Installation der Servicedefinition von Apache Spark finden Sie unter Apache Spark Plugin.

Installation der EMRFS-Servicedefinition

Informationen zur Installation der S3-Servicedefinition für Amazon EMR finden Sie unter EMRFS-S3-Plugin.

Verwenden der Hive-Servicedefinition

Apache Hive kann die bestehende Ranger-Servicedefinition verwenden, die im Lieferumfang von Apache Ranger 2.0 und höher enthalten ist. Weitere Informationen finden Sie unter Apache- Hive-Plugin.

Regeln für den Netzwerkverkehr

Wenn Apache Ranger in Ihren EMR-Cluster integriert ist, muss der Cluster mit zusätzlichen Servern und AWS kommunizieren.

Alle Amazon-EMR-Knoten, einschließlich Core- und Aufgabenknoten, müssen in der Lage sein, mit den Apache-Ranger-Admin-Servern zu kommunizieren, um Richtlinien herunterzuladen. Wenn Ihr Apache-Ranger-Admin auf Amazon EC2 läuft, müssen Sie die Sicherheitsgruppe aktualisieren, um Datenverkehr vom EMR-Cluster entgegennehmen zu können.

Zusätzlich zur Kommunikation mit dem Ranger-Admin-Server müssen alle Knoten in der Lage sein, mit den folgenden AWS-Services zu kommunizieren:

- Amazon S3
- AWS KMS (bei Verwendung von EMRFS SSE-KMS)
- Amazon CloudWatch

- AWS STS

Wenn Sie planen, Ihren EMR-Cluster in einem privaten Subnetz auszuführen, konfigurieren Sie die VPC so, dass sie mit diesen Services entweder über AWS PrivateLink und VPC-Endpunkte im Amazon-VPC-Benutzerhandbuch oder mithilfe der Network Address Translation (NAT)-Instance im Amazon-VPC-Benutzerhandbuch kommunizieren kann.

IAM-Rollen für die native Integration mit Apache Ranger

Die Integration zwischen Amazon EMR und Apache Ranger basiert auf drei Schlüsselrollen, die Sie erstellen sollten, bevor Sie Ihren Cluster starten:

- Ein benutzerdefiniertes Amazon-EC2-Instance-Profil für Amazon EMR
- Eine IAM-Rolle für Apache Ranger Engines
- Die IAM-Rolle für andere AWS-Services

Dieser Abschnitt bietet eine Übersicht über diese Rollen und die Richtlinien, die Sie für jede dieser IAM-Rollen einschließen müssen. Informationen zum Erstellen dieser Rollen finden Sie unter Richten Sie den Ranger-Admin-Server ein.

EC2 instance profile (EC2-Instance-Profile)

Amazon EMR verwendet eine IAM-Servicerolle, um in Ihrem Namen Aktionen zur Bereitstellung und Verwaltung von Clustern durchzuführen. Die Servicerolle für EC2-Instance-Cluster (auch als EC2-Instance-Profil für Amazon EMR bezeichnet) ist eine spezielle Art von Servicerolle, die jeder EC2-Instance in einem Amazon-EMR-Cluster zugewiesen wird, wenn die Instance startet.

Um Berechtigungen für die EMR-Cluster-Interaktion mit Amazon S3-Daten und mit dem durch Apache Ranger und andere AWS Dienste geschützten Hive-Metastore zu definieren, definieren Sie ein benutzerdefiniertes EC2-Instance-Profil, das anstelle von `EMR_EC2_DefaultRole` beim Starten Ihres Clusters verwendet werden soll.

Weitere Informationen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil) und IAM-Rollen anpassen.

Fügen Sie dem standardmäßigen EC2-Instance-Profil die folgenden Anweisungen hinzu, damit Amazon-EMR-Sitzungen taggen und auf die AWS Secrets Manager zuzugreifen, in denen LDAP-Zertifikate gespeichert sind.

```
    {
      "Sid": "AllowAssumeOfRolesAndTagging",
      "Effect": "Allow",
      "Action": ["sts:TagSession", "sts:AssumeRole"],
      "Resource": [
        "arn:aws:iam::<AWS_ACCOUNT_ID>:role/<RANGER_ENGINE-
PLUGIN_DATA_ACCESS_ROLE_NAME>",
        "arn:aws:iam::<AWS_ACCOUNT_ID>:role/<RANGER_USER_ACCESS_ROLE_NAME>"
      ]
    },
    {
        "Sid": "AllowSecretsRetrieval",
        "Effect": "Allow",
        "Action": "secretsmanager:GetSecretValue",
        "Resource": [

 "arn:aws:secretsmanager:<REGION>:<AWS_ACCOUNT_ID>:secret:<PLUGIN_TLS_SECRET_NAME>*",

 "arn:aws:secretsmanager:<REGION>:<AWS_ACCOUNT_ID>:secret:<ADMIN_RANGER_SERVER_TLS_SECRET_NAME>
        ]
    }
```

> **Note**
>
> Vergessen Sie bei den Secrets- Manager-Berechtigungen nicht den Platzhalter („*“) am Ende des geheimen Namens, da Ihre Anfragen sonst fehlschlagen. Der Platzhalter gilt für geheime Versionen.

> **Note**
>
> Beschränken Sie den Geltungsbereich der AWS Secrets Manager-Richtlinie auf die Zertifikate, die für die Bereitstellung erforderlich sind.

IAM-Rolle für Apache Ranger

Diese Rolle stellt Anmeldeinformationen für vertrauenswürdige Ausführungs-Engines wie Apache Hive und Amazon EMR Record Server bereit, um auf Amazon-S3-Daten zuzugreifen. Verwenden Sie

nur diese Rolle, um auf Amazon-S3-Daten, einschließlich aller KMS-Schlüssel, zuzugreifen, wenn Sie S3 SSE-KMS verwenden.

Diese Rolle muss mit der im folgenden Beispiel angegebenen Mindestrichtlinie erstellt werden.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "CloudwatchLogsPermissions",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Effect": "Allow",
      "Resource": [

 "arn:aws:logs:<REGION>:<AWS_ACCOUNT_ID>:<CLOUDWATCH_LOG_GROUP_NAME_IN_SECURITY_CONFIGURATION>:
      ]
    },
    {
      "Sid": "BucketPermissionsInS3Buckets",
      "Action": [
        "s3:CreateBucket",
        "s3:DeleteBucket",
        "s3:ListAllMyBuckets",
        "s3:ListBucket"
      ],
      "Effect": "Allow",
      "Resource": [
*"arn:aws:s3:::bucket1",
        "arn:aws:s3:::bucket2"*
        ]
    },
    {
      "Sid": "ObjectPermissionsInS3Objects",
      "Action": [
        "s3:GetObject",
        "s3:DeleteObject",
        "s3:PutObject"
      ],
      "Effect": "Allow",
      "Resource": [
```

```
 *"arn:aws:s3:::bucket1/*",
          "arn:aws:s3:::bucket2/*"
*        ]
    }
  ]
}
```

> **Important**
>
> Das Sternchen „*“ am Ende der CloudWatch-Protokollressource muss enthalten sein, um Schreibberechtigungen für die Protokollstreams zu erteilen.

> **Note**
>
> Wenn Sie die EMRFS-Konsistenzansicht oder die S3-SSE-Verschlüsselung verwenden, fügen Sie den DynamoDB-Tabellen und KMS-Schlüsseln Berechtigungen hinzu, damit die Ausführungsmodule mit diesen Engines interagieren können.

Die IAM-Rolle für Apache Ranger wird von der EC2-Instance-Profilrolle übernommen. Verwenden Sie das folgende Beispiel, um eine Vertrauensrichtlinie zu erstellen, die es ermöglicht, dass die IAM-Rolle für Apache Ranger von der EC2-Instance-Profilrolle übernommen wird.

```
   {
     "Sid": "",
     "Effect": "Allow",
     "Principal": {
       "AWS": "arn:aws:iam::<AWS_ACCOUNT_ID>:role/<EC2 INSTANCE PROFILE ROLE NAME eg.
EMR_EC2_DefaultRole>"
     },
     "Action": ["sts:AssumeRole", "sts:TagSession"]
   }
```

Die IAM-Rolle für andere AWS-Services

Mit dieser Rolle erhalten Benutzer, die keine vertrauenswürdigen Ausführungs-Engines sind, bei Bedarf Anmeldeinformationen für die Interaktion mit AWS-Services. Verwenden Sie diese IAM-Rolle nicht, um Zugriff auf Amazon-S3-Daten zu gewähren, es sei denn, es handelt sich um Daten, auf die alle Benutzer zugreifen können sollten.

Diese Rolle wird von der EC2-Instance-Profilrolle übernommen. Verwenden Sie das folgende Beispiel, um eine Vertrauensrichtlinie zu erstellen, die es ermöglicht, dass die IAM-Rolle für Apache Ranger von der EC2-Instance-Profilrolle übernommen wird.

```
   {
     "Sid": "",
     "Effect": "Allow",
     "Principal": {
       "AWS": "arn:aws:iam::<AWS_ACCOUNT_ID>:role/<EC2 INSTANCE PROFILE ROLE NAME eg.
EMR_EC2_DefaultRole>"
     },
     "Action": ["sts:AssumeRole", "sts:TagSession"]
   }
```

Validieren Ihrer Berechtigungen

Anweisungen zum Überprüfen von Berechtigungen finden Sie unter Fehlerbehebung für Apache Ranger.

Erstellen einer EMR-Sicherheitskonfiguration

Eine Amazon-EMR-Sicherheitskonfiguration für Apache Ranger erstellen

Bevor Sie einen in Apache Ranger integrierten Amazon-EMR-Cluster starten, erstellen Sie eine Sicherheitskonfiguration.

Console

So erstellen Sie eine Sicherheitskonfiguration, die die AWS-Ranger-Integrationsoption angibt

1. Wählen Sie in der Amazon-EMR-Konsole die Optionen Sicherheitskonfigurationen und dann Erstellen aus.
2. Geben Sie in Name (Name) einen Namen für die Sicherheitskonfiguration ein. Verwenden Sie diesen Namen zum Angeben der Sicherheitskonfiguration, wenn Sie einen Cluster erstellen.
3. Wählen Sie unter AWS-Ranger-Integration die Option Aktivieren einer von Apache Ranger verwalteten feinkörnigen Zugriffskontrolle.
4. Wählen Sie Ihre IAM-Rolle für die Apache Ranger, die angewendet werden soll. Weitere Informationen finden Sie unter IAM-Rollen für die native Integration mit Apache Ranger.
5. Wählen Sie eine IAM-Rolle für andere AWS-Services aus, die angewendet werden soll.

6. Konfigurieren Sie die Plugins so, dass sie eine Verbindung zum Ranger Admin-Server herstellen, indem Sie den Secret-Manager-ARN für den Admin-Server und die Adresse eingeben.
7. Wählen Sie die Anwendungen aus, um Ranger-Plugins zu konfigurieren. Geben Sie den Secret-Manager-ARN ein, der das private TLS-Zertifikat für das Plugin enthält.

   Wenn Sie Apache Spark oder Apache Hive nicht konfigurieren und diese als Anwendung für Ihren Cluster ausgewählt wurden, schlägt die Anfrage fehl.
8. Richten Sie weitere Sicherheitskonfigurationsoptionen ein wie erforderlich. Wählen Sie Create (Erstellen) aus. Sie müssen die Kerberos-Authentifizierung mit dem Cluster-spezifischen oder externen KDC aktivieren.

> **Note**
>
> Sie können die Konsole derzeit nicht zum Erstellen einer Sicherheitskonfiguration verwenden, die die AWS-Ranger-Integrationsoption in der AWS GovCloud (US) Region angibt. Die Sicherheitskonfiguration kann mit der CLI durchgeführt werden.

CLI

Wie Sie eine Sicherheitskonfiguration für die Apache Ranger-Integration erstellen

1. Ersetzen Sie *<ACCOUNT ID>* durch Ihre AWS-Konto-ID.
2. Ersetzen Sie *<REGION>* durch die Region, in der sich die Ressource befindet.
3. Geben Sie einen Wert für `TicketLifetimeInHours` an, um den Zeitraum zu anzugeben, für den ein vom KDC ausgestelltes Kerberos-Ticket gültig ist.
4. Geben Sie die Adresse des Ranger-Admin-Servers für `AdminServerURL` an.

```
{
    "AuthenticationConfiguration": {
        "KerberosConfiguration": {
            "Provider": "ClusterDedicatedKdc",
            "ClusterDedicatedKdcConfiguration": {
                "TicketLifetimeInHours": 24
            }
        }
```

```
   },
   "AuthorizationConfiguration":{
     "RangerConfiguration":{
        "AdminServerURL":"https://_<RANGER ADMIN SERVER IP>_:6182",
        "RoleForRangerPluginsARN":"arn:aws:iam::_<ACCOUNT ID>_:role/_<RANGER PLUGIN
DATA ACCESS ROLE NAME>_",
        "RoleForOtherAWSServicesARN":"arn:aws:iam::_<ACCOUNT ID>_:role/_<USER
ACCESS ROLE NAME>_",
        "AdminServerSecretARN":"arn:aws:secretsmanager:_<REGION>_:_<ACCOUNT
ID>_:secret:_<SECRET NAME THAT PROVIDES ADMIN SERVERS PUBLIC TLS CERTIFICATE
WITHOUT VERSION>_",
        "RangerPluginConfigurations":[
           {
              "App":"Spark",
              "ClientSecretARN":"arn:aws:secretsmanager:_<REGION>_:_<ACCOUNT
ID>_:secret:_<SECRET NAME THAT PROVIDES SPARK PLUGIN PRIVATE TLS CERTIFICATE
WITHOUT VERSION>_",
              "PolicyRepositoryName":"<SPARK SERVICE NAME eg. amazon-emr-spark>"
           },
           {
              "App":"Hive",
              "ClientSecretARN":"arn:aws:secretsmanager:_<REGION>_:_<ACCOUNT
ID>_:secret:_<SECRET NAME THAT PROVIDES Hive PLUGIN PRIVATE TLS CERTIFICATE WITHOUT
VERSION>_",
              "PolicyRepositoryName":"<HIVE SERVICE NAME eg. Hivedev>"
           },
           {
              "App":"EMRFS-S3",
              "ClientSecretARN":"arn:aws:secretsmanager:_<REGION>_:_<ACCOUNT
ID>_:secret:_<SECRET NAME THAT PROVIDES EMRFS S3 PLUGIN PRIVATE TLS CERTIFICATE
WITHOUT VERSION>_",
              "PolicyRepositoryName":"<EMRFS S3 SERVICE NAME eg amazon-emr-emrfs>"
           },
      {
              "App":"Trino",
              "ClientSecretARN":"arn:aws:secretsmanager:_<REGION>_:_<ACCOUNT
ID>_:secret:_<SECRET NAME THAT PROVIDES TRINO PLUGIN PRIVATE TLS CERTIFICATE
WITHOUT VERSION>_",
              "PolicyRepositoryName":"<TRINO SERVICE NAME eg amazon-emr-trino>"
           }
        ],
        "AuditConfiguration":{
           "Destinations":{
              "AmazonCloudWatchLogs":{
```

```
                    "CloudWatchLogGroup":"arn:aws:logs:<REGION>:_<ACCOUNT ID>_:log-
group:_<LOG GROUP NAME FOR AUDIT EVENTS>_"
                }
            }
        }
    }
}
```

Die PolicyRespositoryNames sind die Servicenamen, die in Ihrem Apache-Ranger-Admin angegeben sind.

Erstellen Sie eine Amazon-EMR-Datei für die Sicherheitskonfiguration mit dem folgenden Befehl. Ersetzen Sie Sicherheitskonfiguration durch einen beliebigen Namen. Wählen Sie diese Konfiguration beim Erstellen Ihres Clusters nach Namen aus.

```
aws emr create-security-configuration \
--security-configuration file://./security-configuration.json \
--name security-configuration
```

Konfigurieren von zusätzlichen Sicherheits-Features

Um sicherzustellen, dass Amazon EMR sicher in Apache Ranger integriert ist, konfigurieren Sie die folgenden EMR-Sicherheits-Features:

- Aktivieren Sie die Kerberos-Authentifizierung über den Cluster-spezifischen oder externen KDC. Detaillierte Anweisungen finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR.
- (Optional) Aktivieren Sie die Verschlüsselung von Daten während der Übertragung oder im Ruhezustand. Weitere Informationen finden Sie unter Verschlüsselungsoptionen.

Weitere Informationen finden Sie unter Sicherheit in Amazon EMR.

Speichern Sie TLS-Zertifikate in AWS Secrets Manager

Die auf einem Amazon-EMR-Cluster installierten Ranger-Plugins und der Ranger- Admin-Server müssen über TLS kommunizieren, um sicherzustellen, dass Richtliniendaten und andere gesendete Informationen nicht gelesen werden können, wenn sie abgefangen werden. EMR schreibt außerdem vor, dass sich die Plugins beim Ranger-Admin-Server authentifizieren, indem sie ein eigenes TLS-

Zertifikat bereitstellen und eine bidirektionale TLS-Authentifizierung durchführen. Für dieses Setup mussten vier Zertifikate erstellt werden: zwei Paare von privaten und öffentlichen TLS-Zertifikaten. Anweisungen zur Installation des Zertifikats auf Ihrem Ranger Admin-Server finden Sie unter Richten Sie den Ranger-Admin-Server ein. Um die Einrichtung abzuschließen, benötigen die auf dem EMR-Cluster installierten Ranger-Plugins zwei Zertifikate: das öffentliche TLS-Zertifikat Ihres Admin-Servers und das private Zertifikat, das das Plugin zur Authentifizierung gegenüber dem Ranger-Admin-Server verwendet. Um diese TLS-Zertifikate bereitstellen zu können, müssen sie in der AWS Secrets Manager und in einer EMR-Sicherheitskonfiguration bereitgestellt werden.

> **Note**
>
> Es wird dringend empfohlen, aber nicht vorgeschrieben, für jede Ihrer Anwendungen ein Zertifikatspaar zu erstellen, um die Auswirkungen zu begrenzen, falls eines der Plugin-Zertifikate kompromittiert wird.

> **Note**
>
> Sie müssen Zertifikate vor ihrem Ablaufdatum nachverfolgen und rotieren.

Zertifikatformat

Das Importieren der Zertifikate in das AWS Secrets Manager ist identisch, unabhängig davon, ob es sich um das private Plugin-Zertifikat oder das öffentliche Ranger-Administratorzertifikat handelt. Vor dem Import der TLS-Zertifikate müssen die Zertifikate im 509x PEM-Format vorliegen.

Ein Beispiel für ein öffentliches Zertifikat hat das folgende Format:

```
-----BEGIN CERTIFICATE-----
...Certificate Body...
-----END CERTIFICATE-----
```

Ein Beispiel für ein privates Zertifikat hat das folgende Format:

```
-----BEGIN PRIVATE KEY-----
...Private Certificate Body...
-----END PRIVATE KEY-----
-----BEGIN CERTIFICATE-----
```

```
...Trust Certificate Body...
-----END CERTIFICATE-----
```

Das private Zertifikat sollte auch ein Vertrauenszertifikat enthalten.

Mit folgendem Befehl können Sie prüfen, ob die Zertifikate das richtige Format haben:

```
openssl x509 -in <PEM FILE> -text
```

Ein Zertifikat in AWS Secrets Manager importieren

Wenn Sie Ihr Geheimnis im Secrets Manager erstellen, wählen Sie Andere Art von Geheimnissen unter Geheimnistyp und fügen Sie Ihr PEM-codiertes Zertifikat in das Klartext-Feld ein.

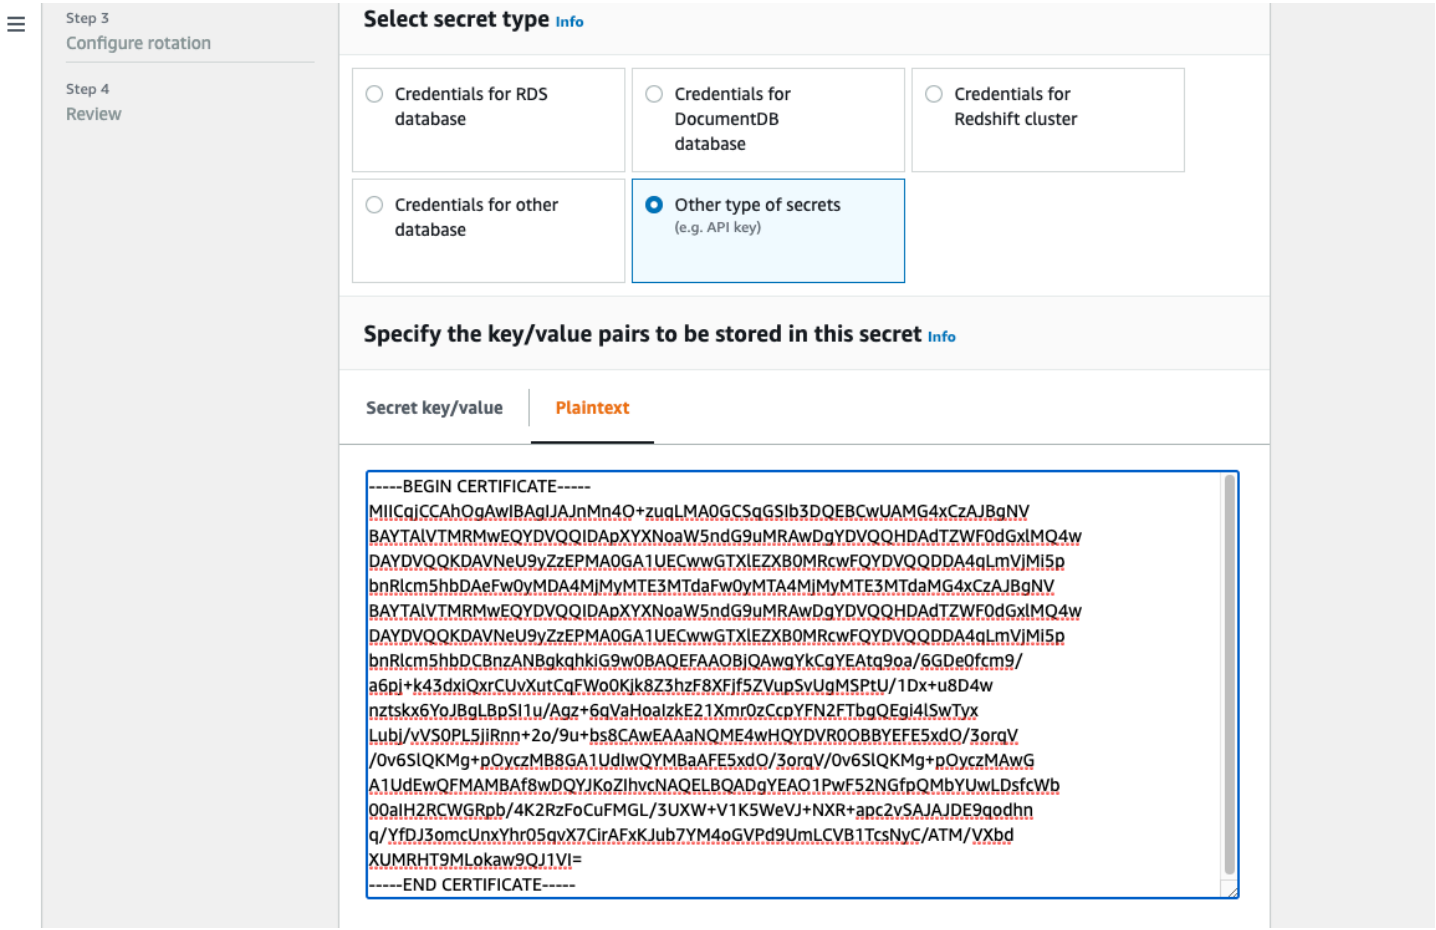

Einen EMR-Cluster starten

Bevor Sie einen Amazon-EMR-Cluster mit Apache Ranger starten, stellen Sie sicher, dass jede Komponente die folgenden Mindestanforderungen an die Version erfüllt:

- Amazon EMR 5.32.0 oder höher oder 6.3.0 oder höher. Es wird empfohlen, die neueste Amazon-EMR-Release-Version zu verwenden.
- Apache Ranger Admin-Server 2.x.

Führen Sie folgende Schritte aus.

- Installieren Sie Apache Ranger, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter Installation von Apache Ranger 0.5.0.
- Stellen Sie sicher, dass zwischen Ihrem Amazon-EMR-Cluster und dem Apache-Ranger-Admin-Server eine Netzwerkverbindung besteht. Siehe Richten Sie den Ranger-Admin-Server ein
- Erstellen Sie die erforderlichen IAM-Rollen. Siehe IAM-Rollen für die native Integration mit Apache Ranger.
- Erstellen Sie eine EMR-Sicherheitskonfiguration für die Apache-Ranger-Installation. Weitere Informationen finden Sie unter Erstellen einer EMR-Sicherheitskonfiguration.

Zeppelin für Apache-Ranger-fähige Amazon-EMR-Cluster konfigurieren

Das Thema behandelt die Konfiguration von Apache Zeppelin für einen Apache-Ranger-fähigen Amazon-EMR-Cluster, sodass Sie Zeppelin als Notizbuch für die interaktive Datenexploration verwenden können. Zeppelin ist in Amazon-EMR-Versionen 5.0.0 und höher enthalten. Frühere Versionen enthalten Zeppelin als Sandbox-Anwendung. Weitere Informationen finden Sie unter Informationen zu Amazon-EMR–4.x-Versionen in den Amazon-EMR-Versionshinweisen.

Standardmäßig ist Zeppelin mit einem Standard-Login und Passwort konfiguriert, was in einer Umgebung mit mehreren Mandanten nicht sicher ist.

Führen Sie für die Konfiguration von Zeppelin die folgenden Schritte aus.

1. Verändern Sie den Authentifizierungsmechanismus.

   Ändern Sie die `shiro.ini`-Datei, um Ihren bevorzugten Authentifizierungsmechanismus zu implementieren. Zeppelin unterstützt Active Directory, LDAP, PAM und Knox SSO. Weitere Informationen finden Sie unter Apache-Shiro-Authentifizierung für Apache Zeppelin.
2. Konfigurieren Sie Zeppelin so, dass es sich als Endbenutzer ausgibt

Wenn Sie Zeppelin erlauben, sich als Endbenutzer auszugeben, können von Zeppelin eingereichte Aufträge als dieser Endbenutzer ausgeführt werden. Fügen Sie die folgende Konfiguration zu `core-site.xml` hinzu:

```
[
  {
    "Classification": "core-site",
    "Properties": {
      "hadoop.proxyuser.zeppelin.hosts": "*",
      "hadoop.proxyuser.zeppelin.groups": "*"
    },
    "Configurations": [
    ]
  }
]
```

Fügen Sie als Nächstes die folgende Konfiguration zu `hadoop-kms-site.xml` in `/etc/hadoop/conf` hinzu:

```
[
  {
    "Classification": "hadoop-kms-site",
    "Properties": {
      "hadoop.kms.proxyuser.zeppelin.hosts": "*",
      "hadoop.kms.proxyuser.zeppelin.groups": "*"
    },
    "Configurations": [
    ]
  }
]
```

Sie können diese Konfigurationen auch mithilfe der Konsole zu Ihrem Amazon-EMR-Cluster hinzufügen, indem Sie die Schritte unter Instancegruppe in der Konsole neu konfigurieren befolgen.

3. Erlauben Sie Zeppelin, als Endbenutzer sudo auszuführen

   Erstellen Sie eine Datei `/etc/sudoers.d/90-zeppelin-user`, die folgendes enthält:

   ```
   zeppelin ALL=(ALL) NOPASSWD:ALL
   ```

4. Ändern Sie die Einstellungen der Interpreter, um Benutzeraufträge in ihren eigenen Prozessen auszuführen.

   Konfigurieren Sie alle Interpreter so, dass sie die Interpreter „pro Benutzer“ in „isolierten“ Prozessen instanziieren.

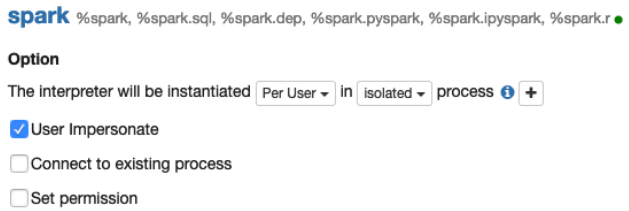

5. Modifizieren Sie **`zeppelin-env.sh`**

   Fügen Sie Folgendes zu `zeppelin-env.sh` hinzu, damit Zeppelin die Interpreter als Endbenutzer startet:

```
ZEPPELIN_IMPERSONATE_USER=`echo ${ZEPPELIN_IMPERSONATE_USER} | cut -d @ -f1`
export ZEPPELIN_IMPERSONATE_CMD='sudo -H -u ${ZEPPELIN_IMPERSONATE_USER} bash -c'
```

   Fügen Sie Folgendes zu `zeppelin-env.sh` hinzu, um die standardmäßigen Notebookberechtigungen für den Ersteller auf Schreibgeschützt zu ändern:

```
export ZEPPELIN_NOTEBOOK_PUBLIC="false"
```

   Fügen Sie abschließend Folgendes hinzu `zeppelin-env.sh` um den EMR-RecordServer-Klassenpfad nach der ersten `CLASSPATH`-Anweisung einzubeziehen:

```
export CLASSPATH="$CLASSPATH:/usr/share/aws/emr/record-server/lib/aws-emr-record-
server-connector-common.jar:/usr/share/aws/emr/record-server/lib/aws-emr-record-
server-spark-connector.jar:/usr/share/aws/emr/record-server/lib/aws-emr-record-
server-client.jar:/usr/share/aws/emr/record-server/lib/aws-emr-record-server-
common.jar:/usr/share/aws/emr/record-server/lib/jars/secret-agent-interface.jar"
```

6. Starten Sie Zeppelin neu.

   Führen Sie für den folgenden Befehle aus, um Zeppelin neu zu starten:

```
sudo systemctl restart zeppelin
```

Bekannte Probleme

Bekannte Probleme

Es gibt ein bekanntes Problem in Amazon-EMR-Version 5.32, bei dem die Berechtigungen für `hive-site.xml` geändert wurden, sodass nur privilegierte Benutzer es lesen können, da möglicherweise Anmeldeinformationen darin gespeichert sind. Dies könnte Hue am Lesen von `hive-site.xml` hindern und dazu führen, dass Webseiten ständig neu geladen werden. Wenn dieses Problem auftritt, fügen Sie die folgende Konfiguration hinzu, um das Problem zu beheben:

```
[
  {
    "Classification": "hue-ini",
    "Properties": {},
    "Configurations": [
      {
        "Classification": "desktop",
        "Properties": {
          "server_group":"hive_site_reader"
         },
        "Configurations":[
        ]
      }
    ]
  }
]
```

Es gibt ein bekanntes Problem, dass das EMRFS-S3-Plugin für Apache Ranger das Security-Zone-Feature von Apache Ranger derzeit nicht unterstützt. Einschränkungen der Zugriffskontrolle, die mit demr Sicherheitszone-Feature definiert wurden, gelten nicht für Ihre Amazon-EMR-Cluster.

Anwendungs-Benutzeroberflächen

Standardmäßig führen Benutzeroberflächen von Anwendungen keine Authentifizierung durch. Dazu gehören unter anderem die ResourceManager-Benutzeroberfläche, die NodeManager-Benutzeroberfläche und die Livy-Benutzeroberfläche. Darüber hinaus kann jeder Benutzer, der auf die Benutzeroberflächen zugreifen kann, Informationen zu den Aufträgen aller anderen Benutzer einsehen.

Wenn dieses Verhalten nicht erwünscht ist, sollten Sie sicherstellen, dass eine Sicherheitsgruppe verwendet wird, um den Zugriff der Benutzer auf die Benutzeroberflächen der Anwendung einzuschränken.

HDFS-Standardberechtigungen

Standardmäßig erhalten die Objekte, die Benutzer in HDFS erstellen, weltweit lesbare Berechtigungen. Dies kann möglicherweise dazu führen, dass Daten von Benutzern gelesen werden, die keinen Zugriff darauf haben sollten. Gehen Sie wie folgt vor, um dieses Verhalten so zu ändern, dass die standardmäßigen Dateiberechtigungen nur vom Ersteller des Auftrags auf Lese- und Schreibzugriff festgelegt werden.

Geben Sie bei der Erstellung Ihres EMR-Clusters die folgende Konfiguration an:

```
[
  {
    "Classification": "hdfs-site",
    "Properties": {
      "dfs.namenode.acls.enabled": "true",
      "fs.permissions.umask-mode": "077",
      "dfs.permissions.superusergroup": "hdfsadmingroup"
    }
  }
]
```

Führen Sie außerdem die folgende Bootstrap-Aktion aus:

```
--bootstrap-actions Name='HDFS UMask Setup',Path=s3://elasticmapreduce/hdfs/umask/
umask-main.sh
```

Apache-Ranger-Plugins

Apache-Ranger-Plugin – Dieses Plugin validiert den Zugriff eines Benutzers anhand der Autorisierungsrichtlinien, die im Apache-Ranger-Richtlinien-Admin-Server definiert sind.

Themen

- Apache- Hive-Plugin
- Apache Spark Plugin
- EMRFS-S3-Plugin

- Trino-Plugin

Apache- Hive-Plugin

Apache Hive ist eine beliebte Ausführungs-Engine innerhalb des Hadoop-Ökosystems. Amazon EMR bietet ein Apache-Ranger-Plugin, um detaillierte Zugriffskontrollen für Hive bereitstellen zu können. Das Plugin ist mit Admin-Server-Version von Open-Source-Apache-Ranger 2.0 und höher kompatibel.

Themen

- Unterstützte Features
- Installation der Servicekonfiguration
- Überlegungen
- Einschränkungen

Unterstützte Features

Das Apache Ranger-Plugin für Hive on EMR unterstützt alle Funktionen des Open-Source-Plugins, einschließlich Zugriffskontrollen auf Datenbank-, Tabellen- und Spaltenebene sowie Zeilenfilterung und Datenmaskierung. Eine Tabelle mit Hive-Befehlen und den zugehörigen Ranger-Berechtigungen finden Sie unter Zuordnung von Hive-Befehlen zu Ranger-Berechtigungen.

Installation der Servicekonfiguration

Das Apache Hive-Plug-in ist mit der vorhandenen Hive-Servicedefinition in Apache Hive Hadoop SQL kompatibel.

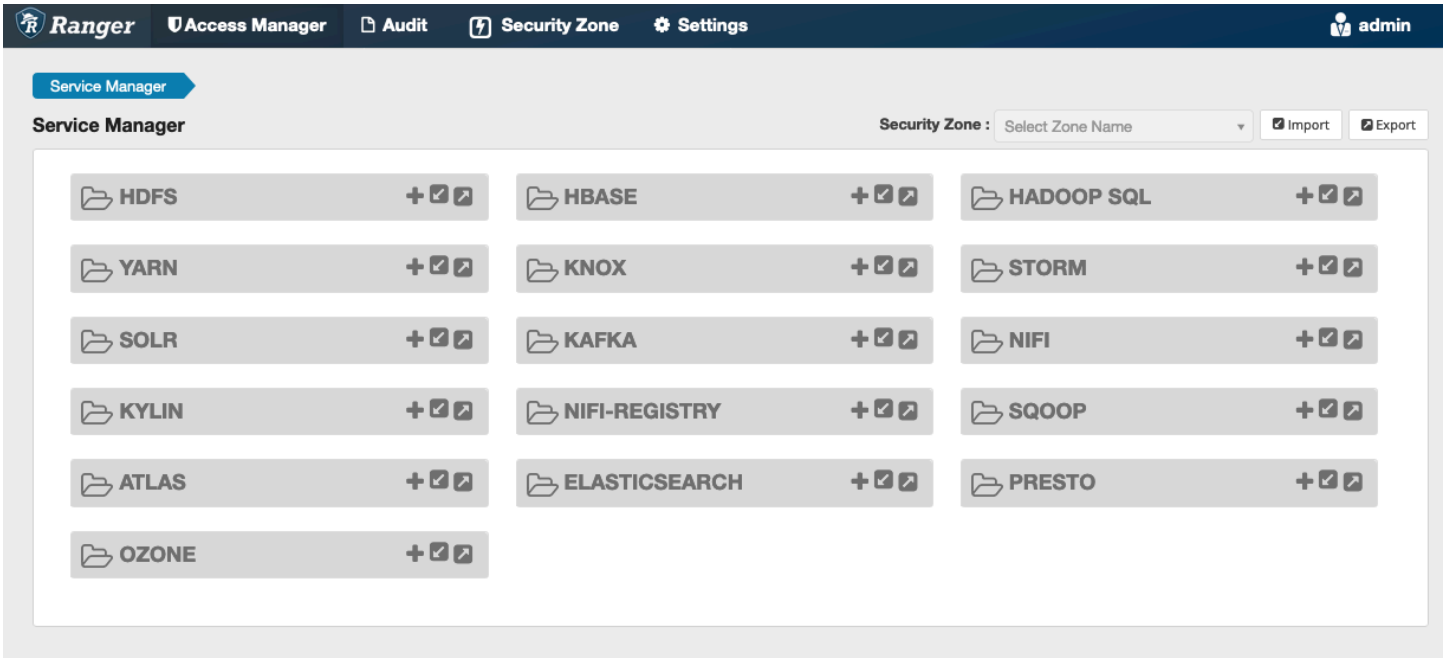

Wenn Sie keine Instance des Services unter Hadoop SQL haben, wie oben gezeigt, können Sie eine erstellen. Klicken Sie auf das + neben Hadoop SQL.

1. Servicename (falls angezeigt): Geben Sie den Servicenamen ein. Der vorgeschlagene Wert ist **`amazonemrhive`**. Notieren Sie sich diesen Servicenamen – er wird benötigt, wenn Sie eine EMR-Sicherheitskonfiguration erstellen.
2. Anzeigename: Der Name, der für diesen Service angezeigt wird. Der vorgeschlagene Wert ist **`amazonemrhive`**.

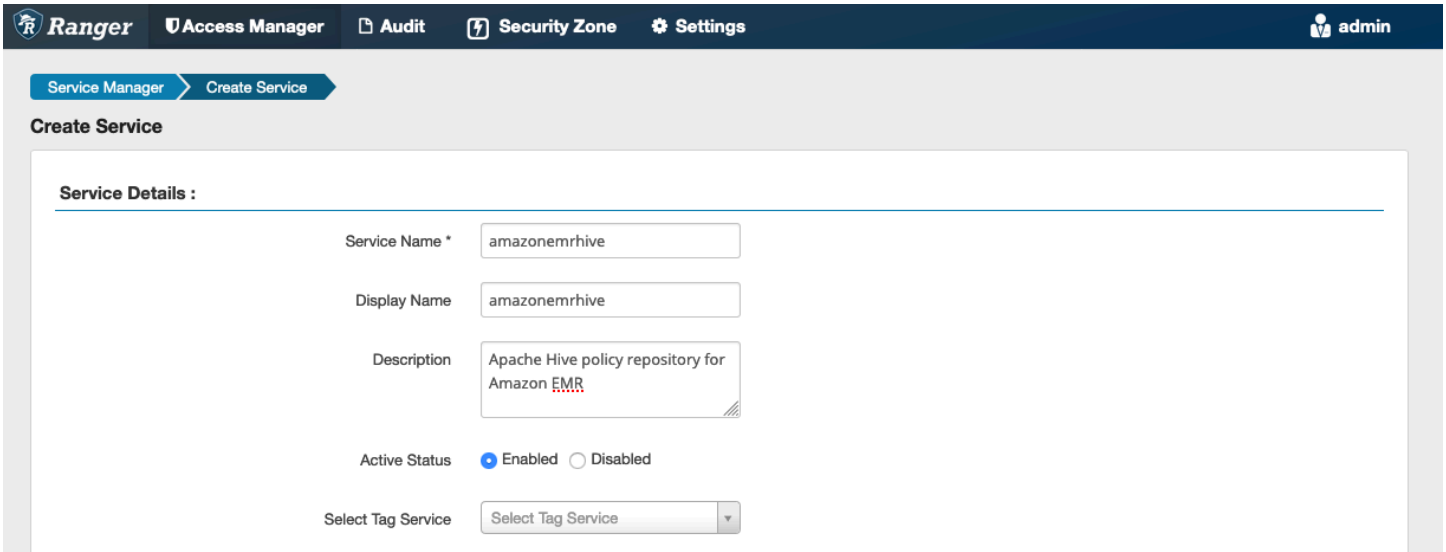

Die Apache-Hive-Konfigurationseigenschaften werden verwendet, um eine Verbindung zu Ihrem Apache-Ranger-Admin-Server mit einem HiveServer2 herzustellen, um die Auto-Vervollständigung bei der Erstellung von Richtlinien zu implementieren. Die folgenden Eigenschaften müssen nicht korrekt sein, wenn Sie nicht über einen persistenten HiveServer2-Prozess verfügen, und sie können mit beliebigen Informationen gefüllt werden.

- Benutzername: Geben Sie einen Benutzernamen für die JDBC-Verbindung zu einer Instance einer HiveServer2-Instance ein.
- Passwort: Geben Sie das Passwort für den obigen Benutzernamen ein.
- jdbc.Driver.ClassName: Geben Sie den Klassennamen der JDBC-Klasse für die Apache Hive-Konnektivität ein. Sie können den Standardwert verwenden.
- jdbc.url: Geben Sie die JDBC-Verbindungszeichenfolge ein, die für die Verbindung mit HiveServer2 verwendet werden soll.
- Allgemeiner Name für das Zertifikat: Das CN-Feld innerhalb des Zertifikats, das verwendet wird, um von einem Client-Plugin aus eine Verbindung zum Admin-Server herzustellen. Dieser Wert muss mit dem CN-Feld in Ihrem TLS-Zertifikat übereinstimmen, das für das Plugin erstellt wurde.

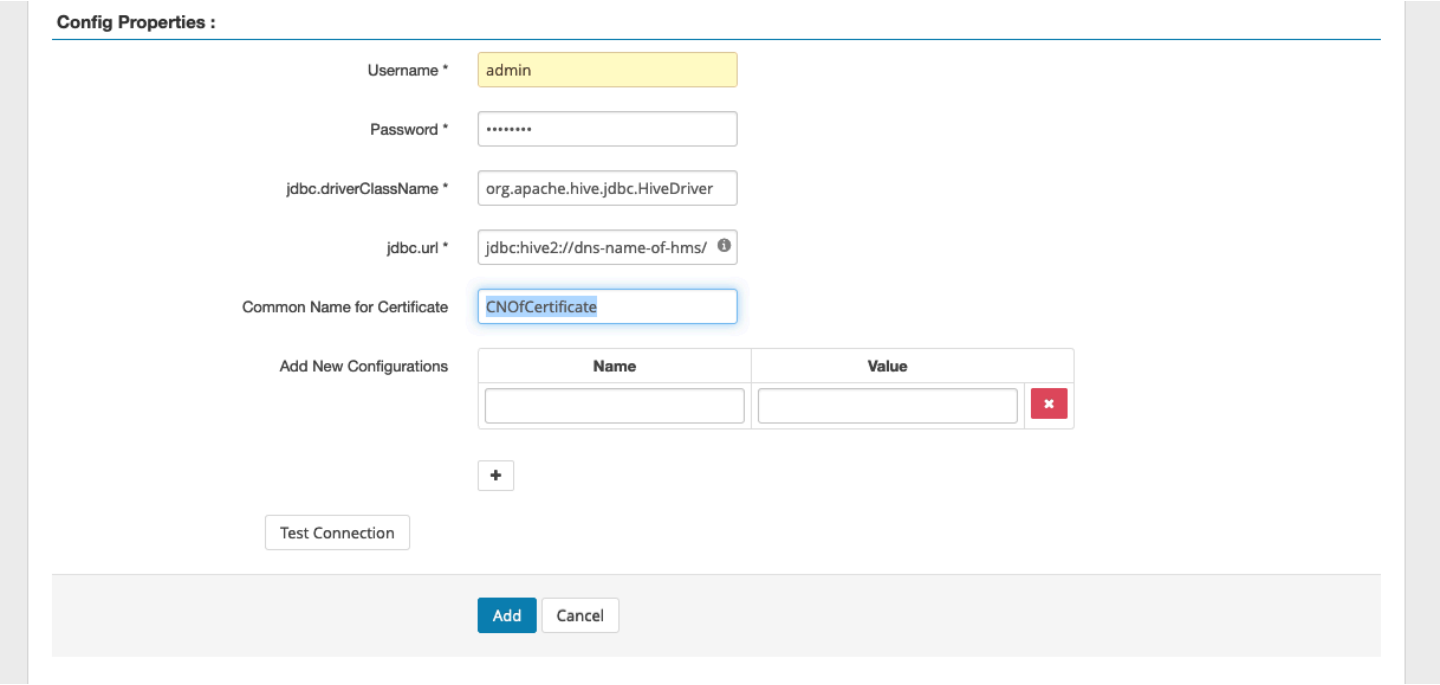

Mit der Schaltfläche Verbindung testen wird getestet, ob die obigen Werte verwendet werden können, um erfolgreich eine Verbindung zur HiveServer2-Instance herzustellen. Sobald der Service erfolgreich erstellt wurde, sollte der Service Manager wie folgt aussehen:

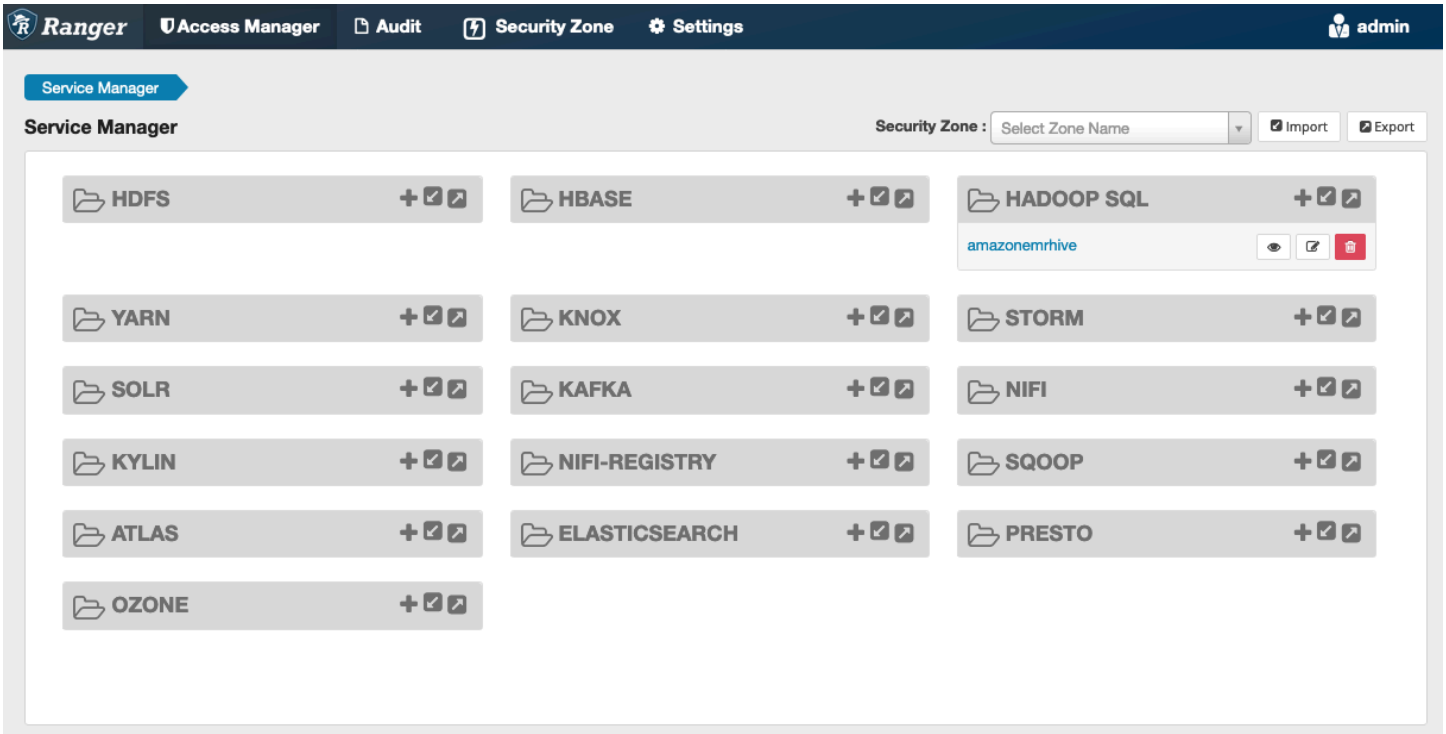

Überlegungen

Hive-Metadatenserver

Zum Schutz vor unbefugtem Zugriff können nur vertrauenswürdige Engines, insbesondere Hive und `emr_record_server`, auf den Hive-Metadatenserver zugreifen. Auf den Hive-Metadatenserver greifen auch alle Knoten im Cluster zu. Der erforderliche Port 9 083 ermöglicht allen Knoten den Zugriff auf den Hauptknoten.

Authentifizierung

Standardmäßig ist Apache Hive für die Authentifizierung mithilfe von Kerberos konfiguriert, wie in der EMR-Sicherheitskonfiguration konfiguriert. HiveServer2 kann so konfiguriert werden, dass Benutzer auch über LDAP authentifiziert werden. Weitere Informationen finden Sie unter Implementieren der LDAP-Authentifizierung für Hive auf einem Amazon-EMR-Cluster mit mehreren Mandanten.

Einschränkungen

Die folgenden Einschränkungen gelten derzeit für das Apache Hive-Plugin auf Amazon EMR 5.x:

- Hive-Rollen werden derzeit nicht unterstützt. Die Anweisungen „Grant“ und „Revoke“ werden nicht unterstützt.

- Die Hive-CLI wird nicht unterstützt. JDBC/Beeline ist die einzige autorisierte Methode, Hive zu verbinden.
- Die `hive.server2.builtin.udf.blacklist`-Konfiguration sollte mit UDFs gefüllt sein, die Sie für unsicher halten.

Apache Spark Plugin

Amazon EMR hat EMR RecordServer integriert, um eine differenzierte Zugriffskontrolle für SparkSQL zu bieten. RecordServer von EMR ist ein privilegierter Prozess, der auf allen Knoten eines Apache-Ranger-fähigen Clusters ausgeführt wird. Wenn ein Spark-Treiber oder -Executor eine SparkSQL-Anweisung ausführt, werden alle Metadaten und Datenanforderungen über den RecordServer geleitet. Weitere Informationen zu EMR RecordServer finden Sie auf der Komponenten für Amazon EMR- Seite.

Themen

- Unterstützte Features
- Stellen Sie die Servicedefinition erneut bereit, um INSERT-, ALTER- oder DDL-Anweisungen zu verwenden
- Installation der Servicedefinition
- Erstellen von SparkSQL-Richtlinien
- Überlegungen
- Einschränkungen

Unterstützte Features

SQL-Anweisung/Ranger-Aktion	STATUS	Unterstützte Versionen für Amazon EMR
SELECT	Unterstützt	Ab 5.32
SHOW DATABASES	Unterstützt	Ab 5.32
SHOW_COLUMNS	Unterstützt	Ab 5.32

SQL-Anweisung/Ranger-Aktion	STATUS	Unterstützte Versionen für Amazon EMR
SHOW TABLES	Unterstützt	Ab 5.32
ANZEIGEN DER TABELLENEINGENSCHAFTEN	Unterstützt	Ab 5.32
DESCRIBE TABLE	Unterstützt	Ab 5.32
INSERT OVERWRITE	Unterstützt	Ab 5.34 und 6.4
INSERT INTO	Unterstützt	Ab 5.34 und 6.4
ALTER TABLE	Unterstützt	Ab 6.4
CREATE TABLE	Unterstützt	Ab 5.35 und 6.7
CREATE DATABASE	Unterstützt	Ab 5.35 und 6.7
DROP TABLE	Unterstützt	Ab 5.35 und 6.7
DROP DATABASE	Unterstützt	Ab 5.35 und 6.7
DROP VIEW	Unterstützt	Ab 5.35 und 6.7
CREATE VIEW	Nicht unterstützt	

Die folgenden Feature werden bei der Verwendung von SparkSQL unterstützt:

- Eine detaillierte Zugriffskontrolle für Tabellen im Hive-Metastore und Richtlinien können auf Datenbank-, Tabellen- und Spaltenebene erstellt werden.

- Die Richtlinien von Apache Ranger können Richtlinien für die Gewährung und die Ablehnung von Benutzern und Gruppen beinhalten.
- Audit-Ereignisse werden an CloudWatch Logs gesendet.

Stellen Sie die Servicedefinition erneut bereit, um INSERT-, ALTER- oder DDL-Anweisungen zu verwenden

> **Note**
>
> Ab Amazon EMR 6.4 können Sie Spark SQL mit den folgenden Anweisungen verwenden: INSERT INTO, INSERT OVERWRITE oder ALTER TABLE. Ab Amazon EMR 6.7 können Sie Spark SQL verwenden, um Datenbanken und Tabellen zu erstellen oder zu löschen. Wenn Sie bereits über eine Installation auf dem Apache Ranger-Server mit bereitgestellten Apache Spark-Servicedefinitionen verfügen, verwenden Sie den folgenden Code, um die Servicedefinitionen erneut bereitzustellen.

```
# Get existing Spark service definition id calling Ranger REST API and JSON
 processor
curl --silent -f -u <admin_user_login>:<password_for_ranger_admin_user> \
-H "Accept: application/json" \
-H "Content-Type: application/json" \
-k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/v2/api/servicedef/
name/amazon-emr-spark' | jq .id

# Download the latest Service definition
wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/
version-2.0/ranger-servicedef-amazon-emr-spark.json

# Update the service definition using the Ranger REST API
curl -u <admin_user_login>:<password_for_ranger_admin_user> -X PUT -d @ranger-
servicedef-amazon-emr-spark.json \
-H "Accept: application/json" \
-H "Content-Type: application/json" \
-k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/v2/api/
servicedef/<Spark service definition id from step 1>'
```

Installation der Servicedefinition

Die Installation der Trino-Servicedefinition erfordert die Einrichtung des Ranger-Admin-Servers. Siehe Richten Sie den Ranger-Admin-Server ein.

Gehen Sie wie folgt vor, um die Apache-Spark-Servicedefinition zu installieren:

Schritt 1: SSH-Verbindung zum Apache-Ranger-Admin-Server herstellen

Beispiele:

```
ssh ec2-user@ip-xxx-xxx-xxx-xxx.ec2.internal
```

Schritt 2: Die Servicedefinition und das Apache-Ranger-Admin-Server-Plugin herunterladen

Laden Sie die Servicedefinition in einem temporären Verzeichnis herunter. Diese Servicedefinition wird von Ranger-2.x-Versionen unterstützt.

```
mkdir /tmp/emr-spark-plugin/
cd /tmp/emr-spark-plugin/

wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/version-2.0/
ranger-spark-plugin-2.x.jar
wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/version-2.0/
ranger-servicedef-amazon-emr-spark.json
```

Schritt 3: Das Apache-Spark-Plugin für Amazon EMR installieren

```
export RANGER_HOME=.. # Replace this Ranger Admin's home directory eg /usr/lib/ranger/
ranger-2.0.0-admin
mkdir $RANGER_HOME/ews/webapp/WEB-INF/classes/ranger-plugins/amazon-emr-spark
mv ranger-spark-plugin-2.x.jar $RANGER_HOME/ews/webapp/WEB-INF/classes/ranger-plugins/
amazon-emr-spark
```

Schritt 4: Die Apache-Spark-Servicedefinition für Amazon EMR registrieren

```
curl -u *<admin users login>*:*_<_**_password_ **_for_** _ranger admin user_**_>_* -X
 POST -d @ranger-servicedef-amazon-emr-spark.json \
-H "Accept: application/json" \
-H "Content-Type: application/json" \
```

```
-k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/v2/api/servicedef'
```

Wenn dieser Befehl erfolgreich ausgeführt wird, sehen Sie in der Ranger-Admin-Benutzeroberfläche einen neuen Servicenamens „AMAZON-EMR-SPARK", wie im folgenden Image gezeigt (Ranger-Version 2.0 wird angezeigt).

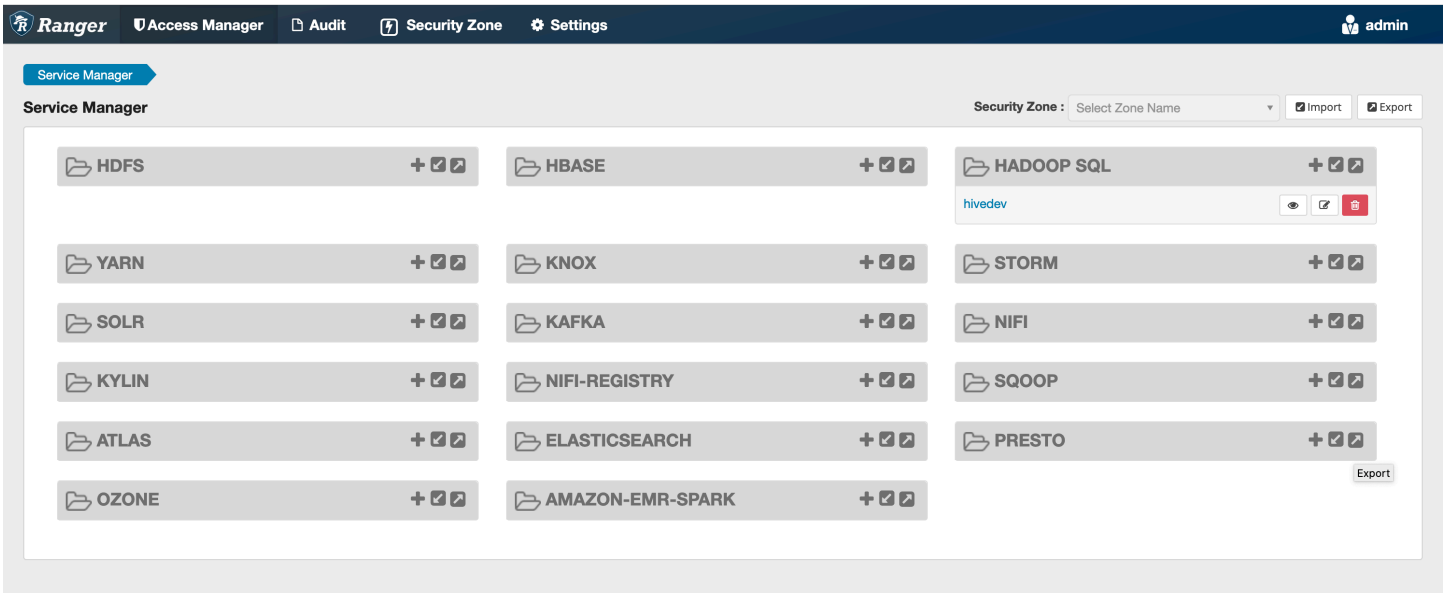

Schritt 5: Eine Instance der AMAZON-EMR-SPARK-Anwendung erstellen

Servicename (falls angezeigt): Der Servicename, der verwendet wird. Der vorgeschlagene Wert ist **`amazonemrspark`**. Notieren Sie sich diesen Servicenamen, da er für die Erstellung einer EMR-Sicherheitskonfiguration benötigt wird.

Anzeigename: Der Name, der für diese Instance angezeigt werden soll. Der vorgeschlagene Wert ist **`amazonemrspark`**.

Allgemeiner Name für das Zertifikat: Das CN-Feld innerhalb des Zertifikats, das verwendet wird, um von einem Client-Plugin aus eine Verbindung zum Admin-Server herzustellen. Dieser Wert muss mit dem CN-Feld in Ihrem TLS-Zertifikat übereinstimmen, das für das Plugin erstellt wurde.

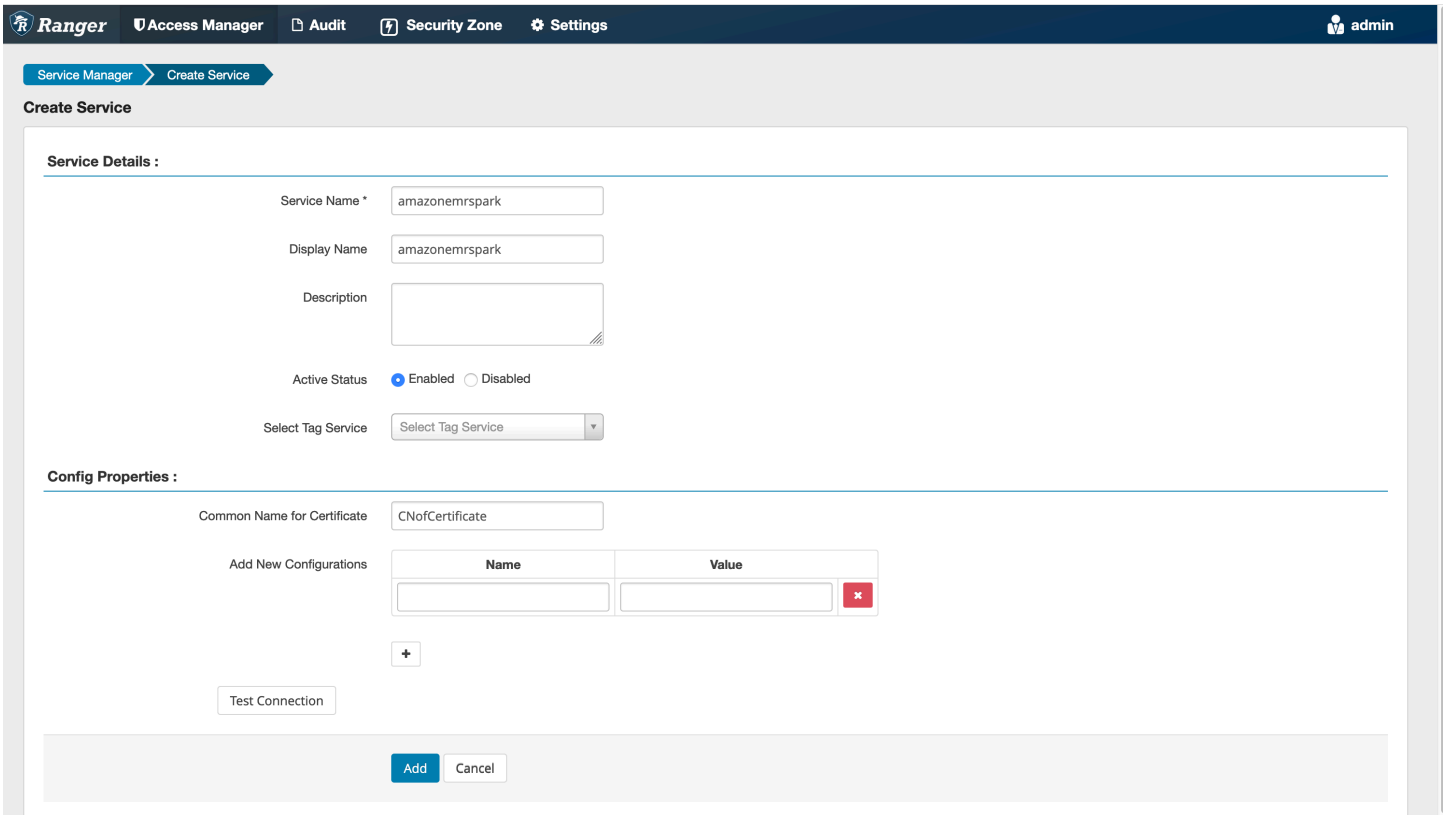

> **Note**
>
> Das TLS-Zertifikat für dieses Plugin sollte im Trust-Store auf dem Ranger-Admin-Server registriert worden sein. Weitere Details finden Sie unter TLS-Zertifikate.

Erstellen von SparkSQL-Richtlinien

Beim Erstellen einer neuen Richtlinie müssen folgende Felder ausgefüllt werden:

Richtlinienname: Der Name dieser Richtlinie.

Richtlinienbezeichnung: Eine Bezeichnung, die Sie dieser Richtlinie hinzufügen können.

Datenbank: Die Datenbank, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Tabellen.

Tabelle: Die Tabellen, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Tabellen.

EMR Spark-Spalte: Die Spalten, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Spalten.

Beschreibung: Eine Beschreibung dieser Richtlinie.

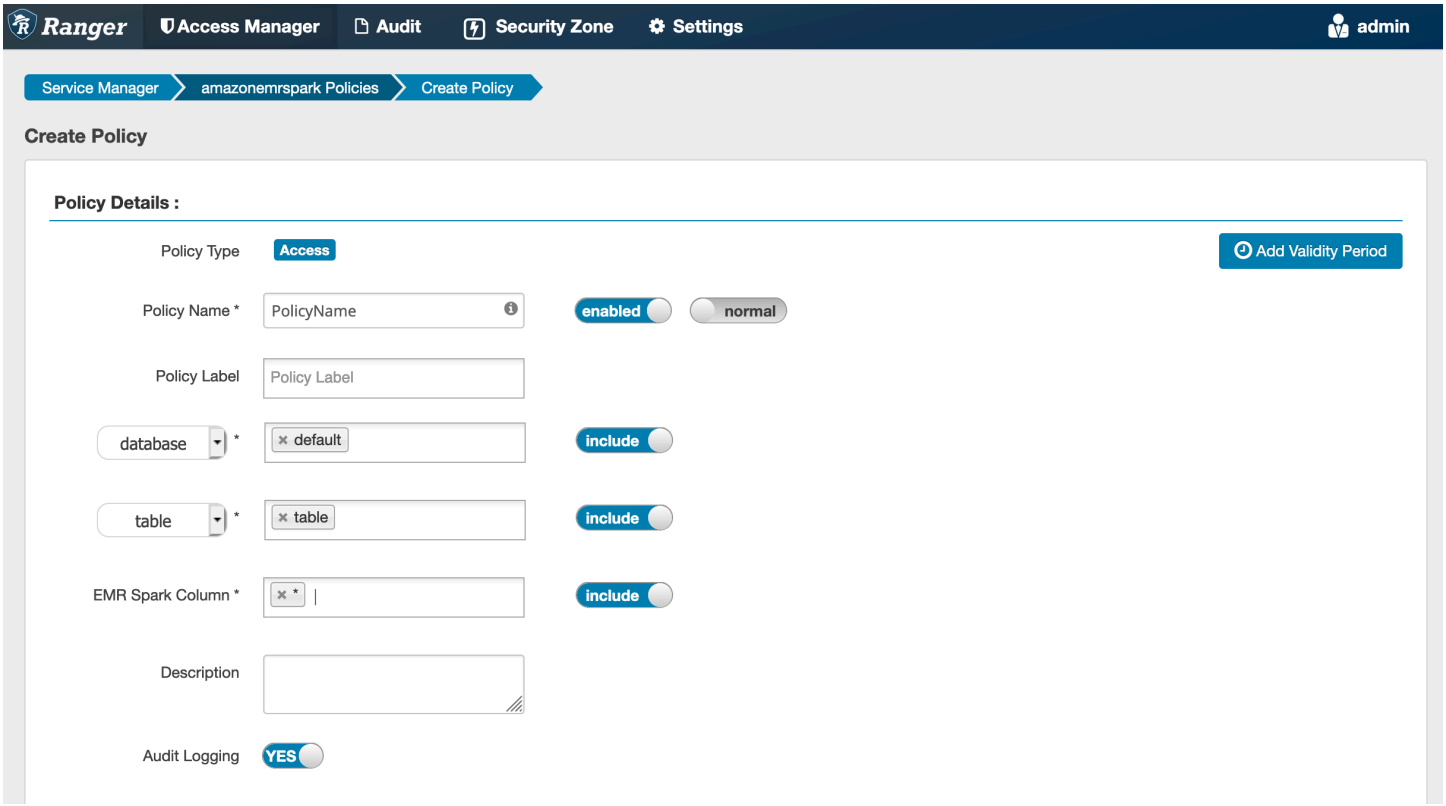

Um die Benutzer und Gruppen anzugeben, geben Sie die Benutzer und Gruppen unten ein, um Berechtigungen zu erteilen. Sie können auch Ausnahmen für die Bedingungen Zulassen und Verweigern angeben.

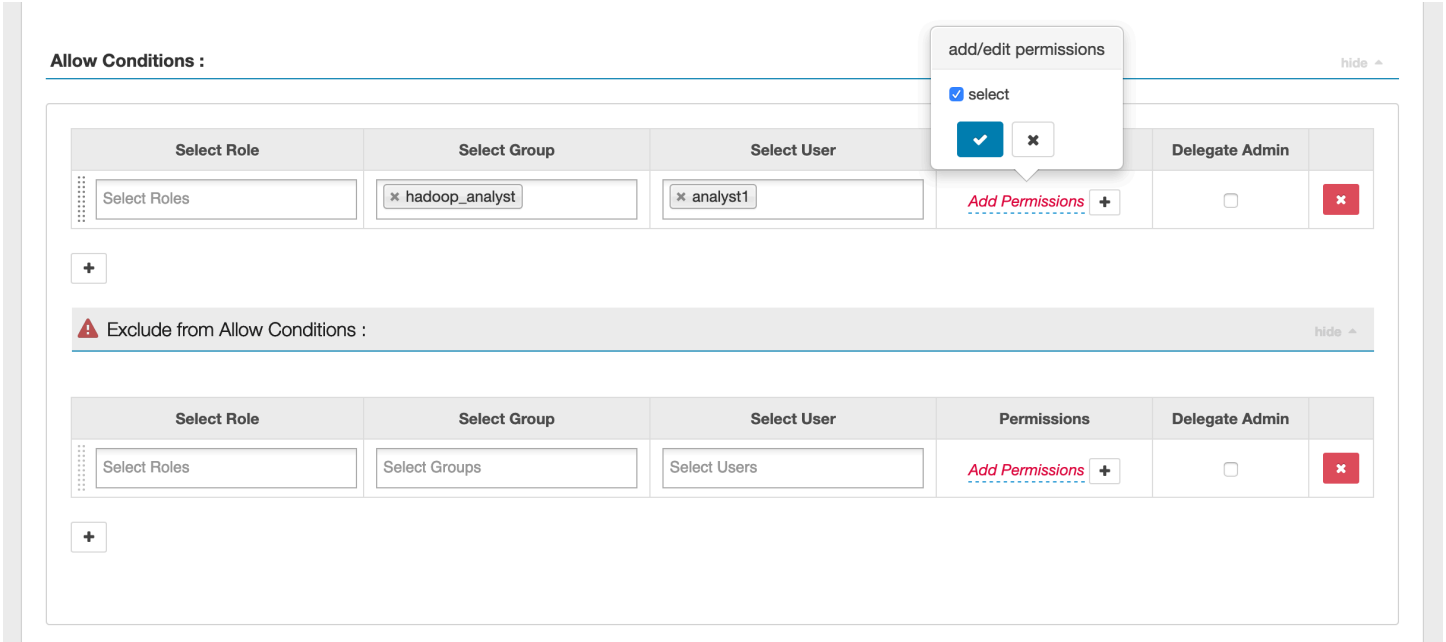

Nachdem Sie die Bedingungen für das Zulassen und Verweigern angegeben haben, klicken Sie auf Speichern.

Überlegungen

Jeder Knoten im EMR-Cluster muss eine Verbindung zum Hauptknoten an Port 9 083 herstellen können.

Einschränkungen

Die folgenden Einschränkungen gelten derzeit für das Apache-Spark-Plugin:

- Der Record-Server stellt immer eine Verbindung zu HMS her, das auf einem Amazon-EMR-Cluster läuft. Konfigurieren Sie HMS für die Verbindung zum Remote-Modus, falls erforderlich. Sie sollten keine Konfigurationswerte in die Apache-Spark-Konfigurationsdatei Hive-site.xml einfügen.
- Tabellen, die mit Spark-Datenquellen auf CSV oder Avro erstellt wurden, können mit EMR RecordServer nicht gelesen werden. Verwenden Sie Hive, um Daten zu erstellen und zu schreiben, und lesen Sie sie mit Record.
- Delta Lake- und Hudi-Tabellen werden nicht unterstützt.
- Benutzer müssen Zugriff auf die Standarddatenbank haben. Dies ist eine Voraussetzung für Apache Spark.
- Der Ranger-Admin-Server unterstützt die automatische Vervollständigung nicht.
- Das SparkSQL-Plugin für Amazon EMR unterstützt keine Zeilenfilter oder Datenmaskierung.
- Wenn Sie ALTER TABLE mit Spark SQL verwenden, muss ein Partitionsspeicherort das untergeordnete Verzeichnis eines Tabellenspeicherorts sein. Das Einfügen von Daten in eine Partition, deren Partitionsspeicherort sich von der Tabellenposition unterscheidet, wird nicht unterstützt.

EMRFS-S3-Plugin

Um die Bereitstellung von Zugriffskontrollen für Objekte in S3 auf einem Multi-Tenant-Cluster zu vereinfachen, bietet das EMRFS-S3-Plugin Zugriffskontrollen für die Daten in S3, wenn über EMRFS darauf zugegriffen wird. Sie können den Zugriff auf S3-Ressourcen auf Benutzer- und Gruppenebene zulassen.

Um dies zu erreichen, sendet EMRFS, wenn Ihre Anwendung versucht, auf Daten innerhalb von S3 zuzugreifen, eine Anfrage nach Anmeldeinformationen an den Secret-Agent-Prozess, wo die

Anfrage anhand eines Apache-Ranger-Plugins authentifiziert und autorisiert wird. Wenn die Anfrage autorisiert ist, übernimmt der Secret Agent die IAM-Rolle für Apache-Ranger-Engines mit einer eingeschränkten Richtlinie, um Anmeldeinformationen zu generieren, die nur Zugriff auf die Ranger-Richtlinie haben, die den Zugriff gewährt hat. Die Anmeldeinformationen werden dann an EMRFS zurückgegeben, um auf S3 zuzugreifen.

Themen

- Unterstützte Features
- Installation der Servicekonfiguration
- EMRFS-S3-Richtlinien erstellen
- Hinweise zur Verwendung von EMRFS-S3-Richtlinien
- Einschränkungen

Unterstützte Features

Das EMRFS-S3-Plugin ermöglicht die Autorisierung auf Speicherebene. Richtlinien können erstellt werden, um Benutzern und Gruppen Zugriff auf S3-Buckets und -Präfixe zu gewähren. Die Autorisierung erfolgt nur für EMRFS.

Installation der Servicekonfiguration

Die Installation der Trino-Servicedefinition erfordert die Einrichtung des Ranger-Admin-Servers. Informationen zum Einrichten des Ranger-Admin-Servers finden Sie unter Richten Sie den Ranger-Admin-Server ein.

Gehen Sie wie folgt vor, um die Apache-Spark-Servicedefinition zu installieren.

Schritt 1: Stellen Sie eine SSH-Verbindung zum Apache-Ranger-Admin-Server her.

Beispiele:

```
ssh ec2-user@ip-xxx-xxx-xxx-xxx.ec2.internal
```

Schritt 2: Laden Sie die Amazon-EMR-Serverdefinition und das Apache-Ranger-Admin-Server-Plugin herunter.

Laden Sie in einem temporären Verzeichnis die Amazon-EMR-Servicedefinition herunter. Diese Servicedefinition wird von Ranger-2.x-Versionen unterstützt.

```
mkdir /tmp/emr-emrfs-plugin/
cd /tmp/emr-emrfs-plugin/

wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/version-2.0/
ranger-servicedef-amazon-emr-emrfs.json
wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/version-2.0/
ranger-emr-emrfs-plugin-2.x.jar
```

Schritt 3: Installieren Sie das Apache-EMRFS-S3-Plugin für Amazon EMR.

```
export RANGER_HOME=.. # Replace this Ranger Admin's home directory eg /usr/lib/ranger/
ranger-2.0.0-admin
mkdir $RANGER_HOME/ews/webapp/WEB-INF/classes/ranger-plugins/amazon-emr-emrfs
mv ranger-emr-emrfs-plugin-2.x.jar $RANGER_HOME/ews/webapp/WEB-INF/classes/ranger-
plugins/amazon-emr-emrfs
```

Schritt 4: Registrieren Sie die EMRFS-S3-Servicedefinition.

```
curl -u *<admin users login>*:*_<_**_password_ **_for_** _ranger admin user_**_>_* -X
 POST -d @ranger-servicedef-amazon-emr-emrfs.json \
-H "Accept: application/json" \
-H "Content-Type: application/json" \
-k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/v2/api/servicedef'
```

Wenn dieser Befehl erfolgreich ausgeführt wird, sehen Sie in der Ranger-Admin-Benutzeroberfläche einen neuen Servicenamens „AMAZON-EMR-S3", wie im folgenden Image gezeigt (Ranger-Version 2.0 wird angezeigt).

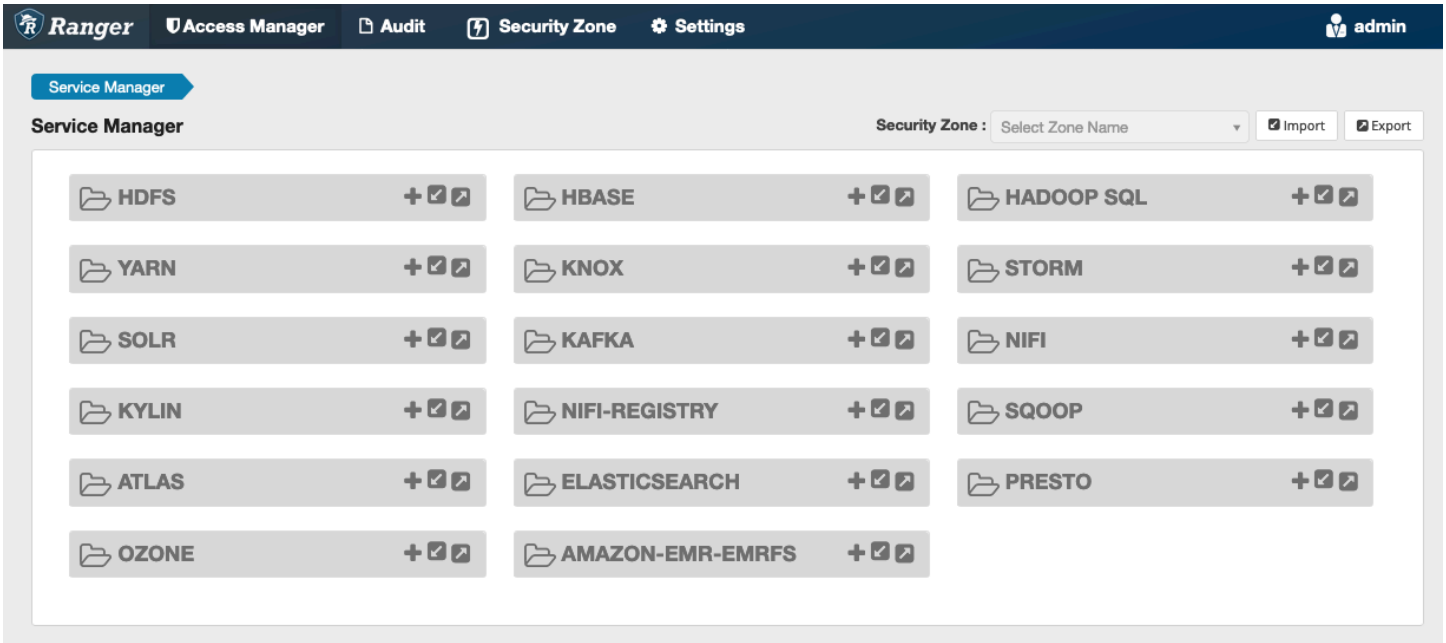

Schritt 5: Erstellen Sie eine Instance der AMAZON-EMR-EMRFS-Anwendung.

Erstellen Sie eine Instance der Servicedefinition.

- Klicken Sie auf das + neben AMAZON-EMR-EMRFS.

Füllen Sie die folgenden Felder aus:

Servicename (falls angezeigt): Der vorgeschlagene Wert ist **`amazonemrspark`**. Notieren Sie sich diesen Servicenamen, da er für die Erstellung einer EMR-Sicherheitskonfiguration benötigt wird.

Anzeigename: Der Name, der für diesen Service angezeigt wird. Der vorgeschlagene Wert ist **`amazonemrspark`**.

Allgemeiner Name für das Zertifikat: Das CN-Feld innerhalb des Zertifikats, das verwendet wird, um von einem Client-Plugin aus eine Verbindung zum Admin-Server herzustellen. Dieser Wert muss mit dem CN-Feld in Ihrem TLS-Zertifikat übereinstimmen, das für das Plugin erstellt wurde.

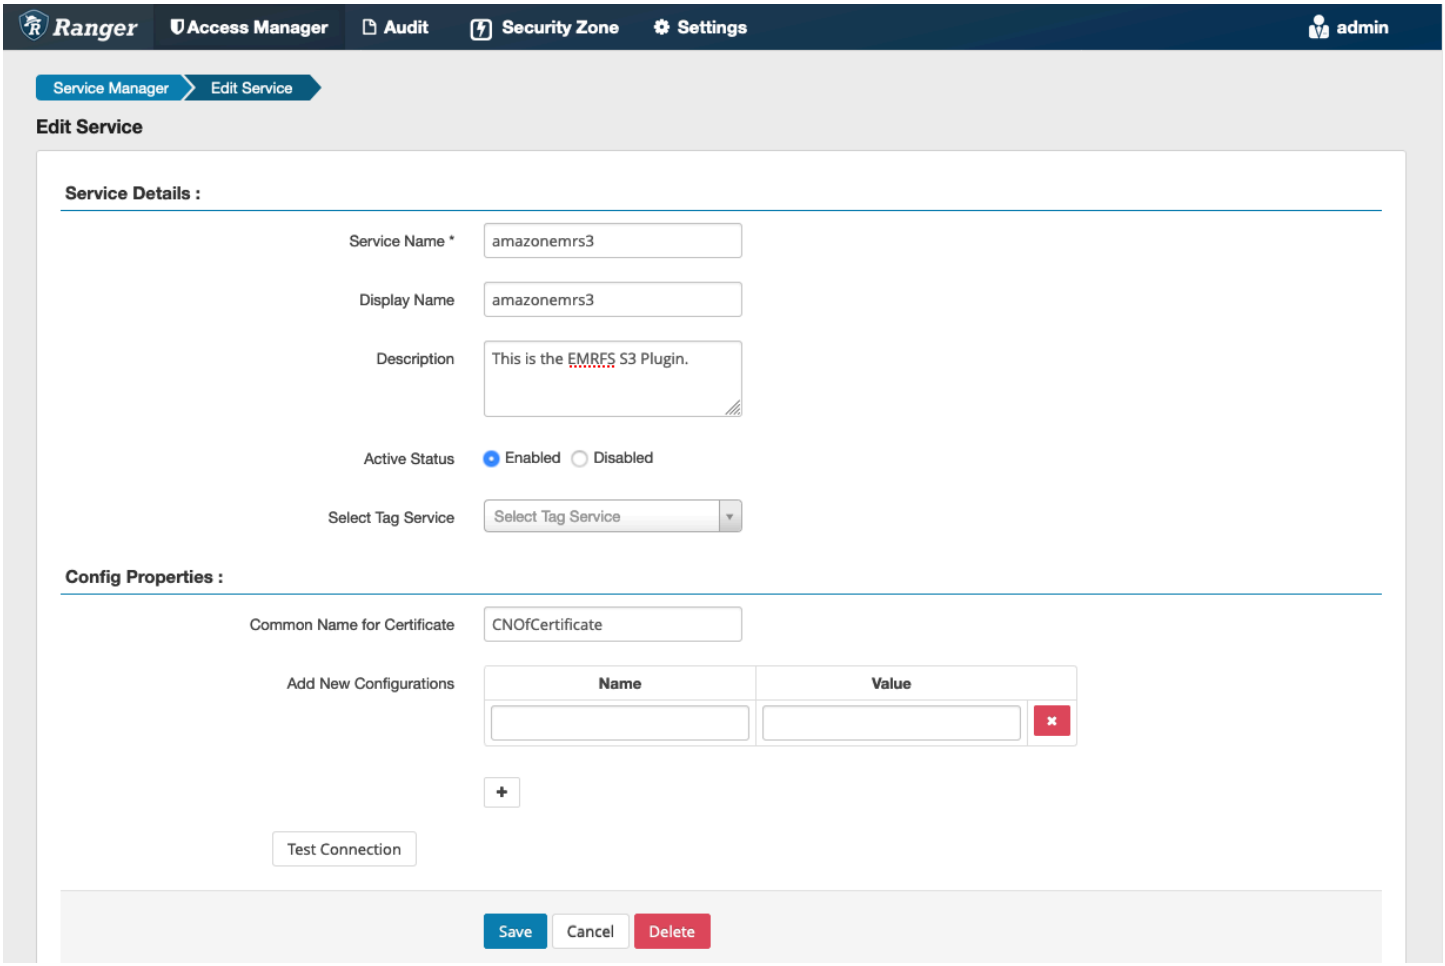

> **Note**
>
> Das TLS-Zertifikat für dieses Plugin sollte im Trust-Store auf dem Ranger-Admin-Server registriert worden sein. Weitere Details finden Sie unter TLS-Zertifikate.

Wenn der Service erstellt wird, enthält der Service Manager „AMAZON-EMR-EMRFS“, wie in der folgenden Abbildung dargestellt.

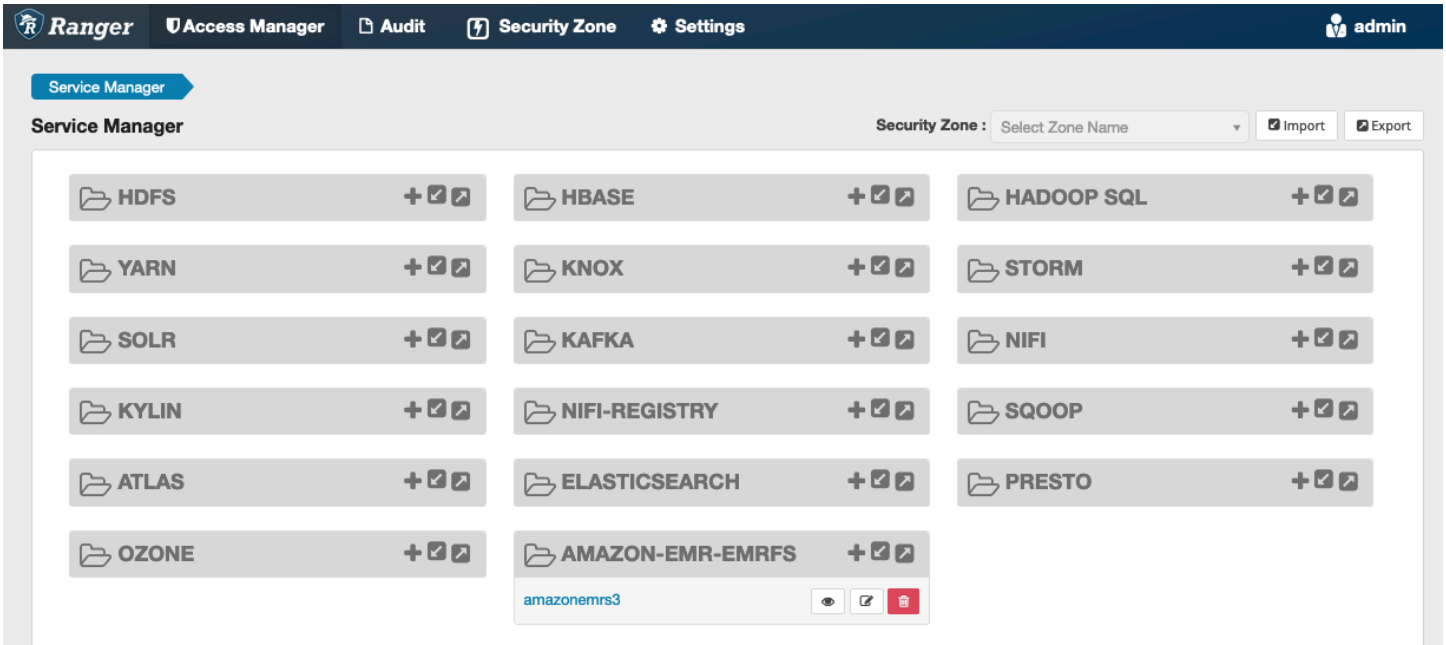

EMRFS-S3-Richtlinien erstellen

Füllen Sie die folgenden Felder aus, um auf der Seite Richtlinie erstellen des Service Managers eine neue Richtlinie zu erstellen.

Richtlinienname: Der Name dieser Richtlinie.

Richtlinienbezeichnung: Eine Bezeichnung, die Sie dieser Richtlinie hinzufügen können.

S3-Ressource: Eine Ressource, die mit dem Bucket und dem optionalen Präfix beginnt. Weitere Informationen finden Sie unter Bewährte Methoden für Hinweise zur Verwendung von EMRFS-S3-Richtlinien. Ressourcen auf dem Ranger-Admin-Server sollten nicht **`s3://`**, **`s3a://`** oder **`s3n://`** enthalten.

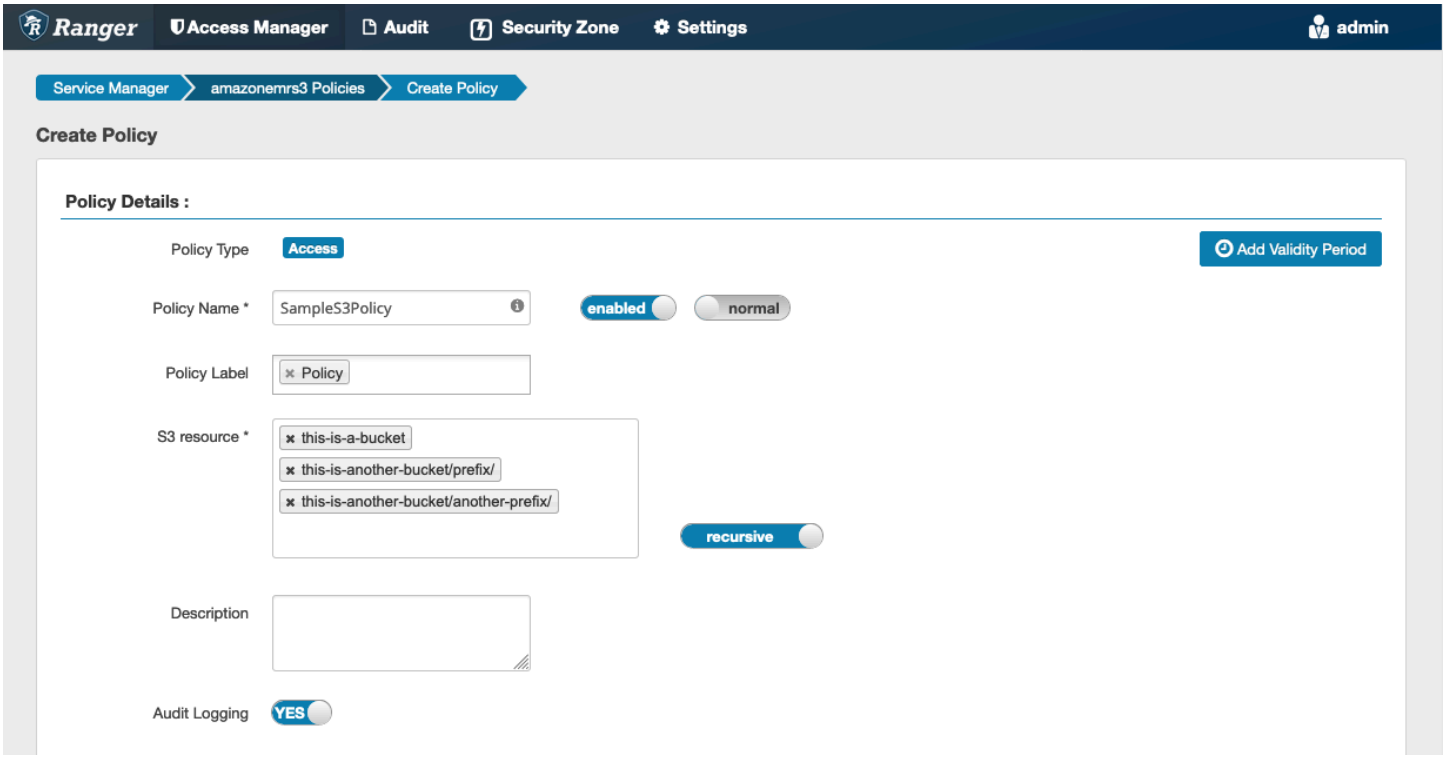

Sie können Benutzer und Gruppen angeben, denen Berechtigungen erteilt werden sollen. Sie können auch Ausnahmen für Zulassungsbedingungen und Verweigerungsbedingungen angeben.

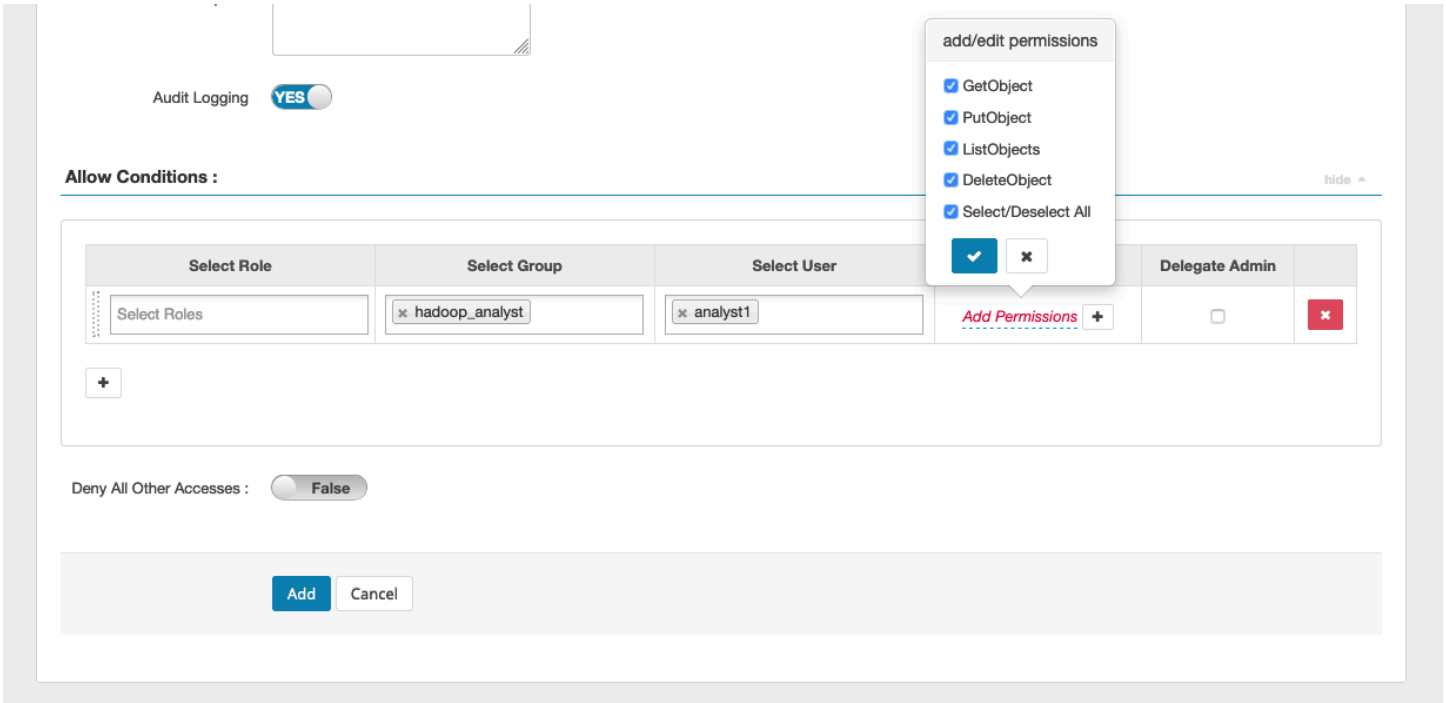

> **Note**
>
> Für jede Richtlinie sind maximal drei Ressourcen zulässig. Das Hinzufügen von mehr als drei Ressourcen kann zu einem Fehler führen, wenn diese Richtlinie auf einem EMR-Cluster verwendet wird. Beim Hinzufügen von mehr als drei Richtlinien wird eine Erinnerung an das Richtlinienlimit angezeigt.

Hinweise zur Verwendung von EMRFS-S3-Richtlinien

Bei der Erstellung von S3-Richtlinien in Apache Ranger sind einige Nutzungsaspekte zu beachten.

Berechtigungen für mehrere S3-Objekte

Sie können rekursive Richtlinien und Platzhalterausdrücke verwenden, um mehreren S3-Objekten mit gemeinsamen Präfixen Berechtigungen zu erteilen. Rekursive Richtlinien gewähren allen Objekten mit einem gemeinsamen Präfix Berechtigungen. Platzhalterausdrücke wählen mehrere Präfixe aus. Zusammen gewähren sie allen Objekten mit mehreren gemeinsamen Präfixen, wie in den folgenden Beispielen gezeigt.

Example Verwenden einer rekursiven Richtlinie

Angenommen, Sie benötigen Berechtigungen, um alle Parquet-Dateien in einem S3-Bucket aufzulisten, der wie folgt organisiert ist.

```
s3://sales-reports/americas/
    +- year=2000
    |      +- data-q1.parquet
    |      +- data-q2.parquet
    +- year=2019
    |      +- data-q1.json
    |      +- data-q2.json
    |      +- data-q3.json
    |      +- data-q4.json
    |
    +- year=2020
    |      +- data-q1.parquet
    |      +- data-q2.parquet
    |      +- data-q3.parquet
    |      +- data-q4.parquet
    |      +- annual-summary.parquet
```

```
    +- year=2021
```

Betrachten Sie zunächst die Parquet-Dateien mit dem Präfix `s3://sales-reports/americas/year=2000`. Sie können allen GetObject-Berechtigungen auf zwei Arten gewähren:

Verwenden von nichtrekursiven Richtlinien: Eine Option besteht darin, zwei separate nichtrekursive Richtlinien zu verwenden, eine für das Verzeichnis und die andere für die Dateien.

Die erste Richtlinie erteilt die Erlaubnis für das Präfix `s3://sales-reports/americas/year=2020` (es gibt keinen Trailing-/).

```
- S3 resource = "sales-reports/americas/year=2000"
- permission = "GetObject"
- user = "analyst"
```

Die zweite Richtlinie verwendet einen Platzhalterausdruck, um allen Dateien mit Präfix Berechtigungen zu erteilen `sales-reports/americas/year=2020/` (beachten Sie das Trailing-/).

```
- S3 resource = "sales-reports/americas/year=2020/*"
- permission = "GetObject"
- user = "analyst"
```

Verwendung einer rekursiven Richtlinie: Eine bequemere Alternative besteht darin, eine einzige rekursive Richtlinie zu verwenden und dem Präfix rekursive Berechtigungen zu erteilen.

```
 - S3 resource = "sales-reports/americas/year=2020"
 - permission = "GetObject"
 - user = "analyst"
 - is recursive = "True"
```

Bisher waren nur die Parquet-Dateien mit dem Präfix `s3://sales-reports/americas/year=2000` enthalten. Sie können jetzt auch die Parquet-Dateien mit einem anderen Präfix, `s3://sales-reports/americas/year=2020`, in dieselben rekursive Richtlinie aufnehmen, indem Sie einen Platzhalterausdruck wie folgt einfügen.

```
 - S3 resource = "sales-reports/americas/year=20?0"
 - permission = "GetObject"
 - user = "analyst"
 - is recursive = "True"
```

Richtlinien für PutObject- und DeleteObject-Berechtigungen

Das Schreiben von Richtlinien `PutObject` und `DeleteObject` Berechtigungen für Dateien auf EMRFS erfordert besondere Sorgfalt, da sie im Gegensatz zu GetObject-Berechtigungen zusätzliche rekursive Berechtigungen benötigen, die dem Präfix gewährt werden.

Example Richtlinien für PutObject- und DeleteObject-Berechtigungen

Zum Löschen der Datei `annual-summary.parquet` ist beispielsweise nicht nur eine DeleteObject-Berechtigung für die eigentliche Datei erforderlich.

```
- S3 resource = "sales-reports/americas/year=2020/annual-summary.parquet"
- permission = "DeleteObject"
- user = "analyst"
```

Außerdem ist eine Richtlinie erforderlich, die rekursive Rechte `GetObject` und `PutObject` Berechtigungen für das zugehörige Präfix gewährt.

In ähnlicher Weise erfordert das Ändern der Datei `annual-summary.parquet` nicht nur eine `PutObject`-Berechtigung für die eigentliche Datei.

```
- S3 resource = "sales-reports/americas/year=2020/annual-summary.parquet"
- permission = "PutObject"
- user = "analyst"
```

Außerdem ist eine Richtlinie erforderlich, die eine rekursive `GetObject`-Erlaubnis für ihr Präfix erteilt.

```
- S3 resource = "sales-reports/americas/year=2020"
- permission = "GetObject"
- user = "analyst"
- is recursive = "True"
```

Platzhalter in Richtlinien

Es gibt zwei Bereiche, in denen Platzhalter angegeben werden können. Bei der Angabe einer S3-Ressource können „*“ und „?“ verwendet werden. Das „*“ ermöglicht einen Abgleich mit einem S3-Pfad und entspricht allem, was hinter dem Präfix steht. Zum Beispiel die folgende Richtlinie.

```
S3 resource = "sales-reports/americas/*"
```

Dies entspricht den folgenden S3-Pfaden.

```
sales-reports/americas/year=2020/
sales-reports/americas/year=2019/
sales-reports/americas/year=2019/month=12/day=1/afile.parquet
sales-reports/americas/year=2018/month=6/day=1/afile.parquet
sales-reports/americas/year=2017/afile.parquet
```

Das Platzhalterzeichen „?“ entspricht nur einem einzelnen Zeichen. Beispielsweise für die Richtlinie.

```
S3 resource = "sales-reports/americas/year=201?/"
```

Dies entspricht den folgenden S3-Pfaden.

```
sales-reports/americas/year=2019/
sales-reports/americas/year=2018/
sales-reports/americas/year=2017/
```

Platzhalter bei Benutzern

Bei der Zuweisung von Benutzern, die Benutzern Zugriff gewähren sollen, gibt es zwei integrierte Platzhalter. Der erste ist der Platzhalter „{USER}“, der allen Benutzern Zugriff gewährt. Der zweite Platzhalter ist „{OWNER}“, der Zugriff auf den Eigentümer eines bestimmten Objekts oder direkt ermöglicht. Der Platzhalter „{USER}“ wird derzeit jedoch nicht unterstützt.

Einschränkungen

Die folgenden Einschränkungen gelten derzeit für das EMRFS S3-Plugin:

- Apache-Ranger-Richtlinien können maximal drei Richtlinien haben.
- Der Zugriff auf S3 muss über EMRFS erfolgen und kann mit Hadoop-bezogenen Anwendungen verwendet werden. Folgendes wird nicht unterstützt:
  - Boto3-Bibliotheken
  - AWS- SDK und AWK-CLI
  - S3A-Open-Source-Konnektor
- Die Ablehnungs-Richtlinien von Apache Ranger werden nicht unterstützt.

- Vorgänge auf S3 mit Schlüsseln mit CSE-KMS-Verschlüsselung werden derzeit nicht unterstützt.
- Die Freigabe über Regionsgrenzen hinweg wird nicht unterstützt.
- Das Sicherheitszone-Feature von Apache Ranger wird nicht unterstützt. Einschränkungen der Zugriffskontrolle, die mit demr Sicherheitszone-Feature definiert wurden, gelten nicht für Ihre Amazon-EMR-Cluster.
- Der Hadoop-Benutzer generiert keine Audit-Ereignisse, da Hadoop immer auf das EC2-Instance-Profil zugreift.
- Es wird empfohlen, Amazon EMR Consistency View zu deaktivieren. S3 ist stark konsistent und wird daher nicht mehr benötigt. Weitere Informationen finden Sie unter Starke Konsistenz von Amazon-S3.
- Das EMRFS-S3-Plugin führt zahlreiche STS-Aufrufe durch. Es wird empfohlen, Lasttests auf einem Entwicklungskonto durchzuführen und das STS-Aufrufvolumen zu überwachen. Es wird außerdem empfohlen, eine STS-Anfrage zu stellen, um die AssumeRole-Servicelimits zu erhöhen.

Trino-Plugin

Trino (früher PrestoSQL) ist eine SQL-Abfrage-Engine, mit der Sie Abfragen für Datenquellen wie HDFS, Objektspeicher, relationale Datenbanken und NoSQL-Datenbanken ausführen können. Sie macht die Migration von Daten an einen zentralen Ort überflüssig und ermöglicht es Ihnen, die Daten von jedem Ort aus abzufragen. Amazon EMR bietet ein Apache- Ranger-Plugin für detaillierte Zugriffskontrollen für Trino. Das Plugin ist mit Admin-Server-Version von Open-Source-Apache-Ranger 2.0 und höher kompatibel.

Themen

- Unterstützte Features
- Installation der Servicekonfiguration
- Erstellen von Trino-Richtlinien
- Überlegungen
- Einschränkungen

Unterstützte Features

Das Apache-Ranger-Plugin für Trino auf Amazon EMR unterstützt die gesamte Funktionalität der Trino-Abfrage-Engine, die durch eine detaillierte Zugriffskontrolle geschützt ist. Dazu gehören Zugriffskontrollen auf Datenbank-, Tabellen- und Spaltenebene sowie Zeilenfilterung und

Datenmaskierung. Die Richtlinien von Apache Ranger können Richtlinien für die Gewährung und die Ablehnung von Benutzern und Gruppen beinhalten. Prüfereignisse werden auch an CloudWatch-Protokolle übermittelt.

Installation der Servicekonfiguration

Die Installation der Trino-Servicedefinition erfordert die Einrichtung des Ranger-Admin-Servers. Informationen zum Einrichten des Ranger-Admin-Servers finden Sie unter Richten Sie den Ranger-Admin-Server ein.

Zum Installieren der Trino-Servicedefinition führen Sie die folgenden Schritte aus.

1. Stellen Sie eine SSH-Verbindung zum Apache-Ranger-Admin-Server her.

```
ssh ec2-user@ip-xxx-xxx-xxx-xxx.ec2.internal
```

2. Deinstallieren Sie das Presto-Server-Plugin, falls es existiert. Führen Sie den folgenden Befehl aus. Wenn dieser Fehler mit der Fehlermeldung „Service nicht gefunden“ angezeigt wird, bedeutet dies, dass das Presto-Server-Plugin nicht auf Ihrem Server installiert wurde. Fahren Sie mit dem nächsten Schritt fort.

```
curl -f -u *<admin users login>*:*_<_**_password_ **_for_** _ranger admin
 user_**_>_* -X DELETE -k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/
v2/api/servicedef/name/presto'
```

3. Laden Sie die Servicedefinition und das Apache-Ranger-Admin-Server-Plugin herunter. Laden Sie die Servicedefinition in einem temporären Verzeichnis herunter. Diese Servicedefinition wird von Ranger-2.x-Versionen unterstützt.

```
wget https://s3.amazonaws.com/elasticmapreduce/ranger/service-definitions/
version-2.0/ranger-servicedef-amazon-emr-trino.json
```

4. Registrieren Sie die Apache-Spark-Servicedefinition für Amazon EMR

```
curl -u *<admin users login>*:*_<_**_password_ **_for_** _ranger admin user_**_>_*
 -X POST -d @ranger-servicedef-amazon-emr-trino.json \
-H "Accept: application/json" \
-H "Content-Type: application/json" \
-k 'https://*<RANGER SERVER ADDRESS>*:6182/service/public/v2/api/servicedef'
```

Wenn dieser Befehl erfolgreich ausgeführt wird, wird in Ihrer Ranger-Admin-Benutzeroberfläche ein neuer Service mit dem Namen `TRINO` angezeigt, wie in der folgenden Abbildung dargestellt.

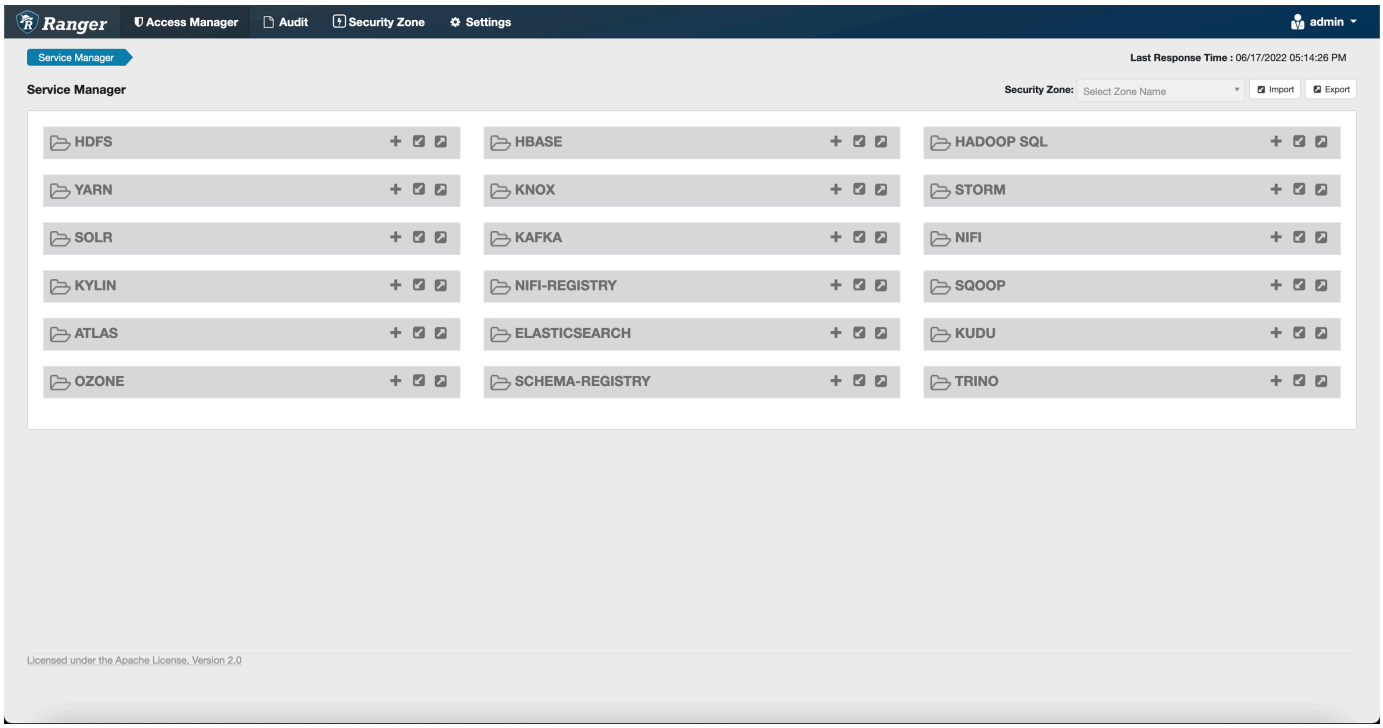

5. Erstellen Sie eine Instance der `TRINO`-Anwendung und geben Sie die folgenden Informationen ein.

   Servicename: Der Servicename, den Sie verwenden werden. Der vorgeschlagene Wert ist `amazonemrtrino`. Notieren Sie sich diesen Servicenamen, da er für die Erstellung einer Amazon-EMR-Sicherheitskonfiguration benötigt wird.

   Anzeigename: Der Name, der für diese Instance angezeigt werden soll. Der vorgeschlagene Wert ist `amazonemrtrino`.

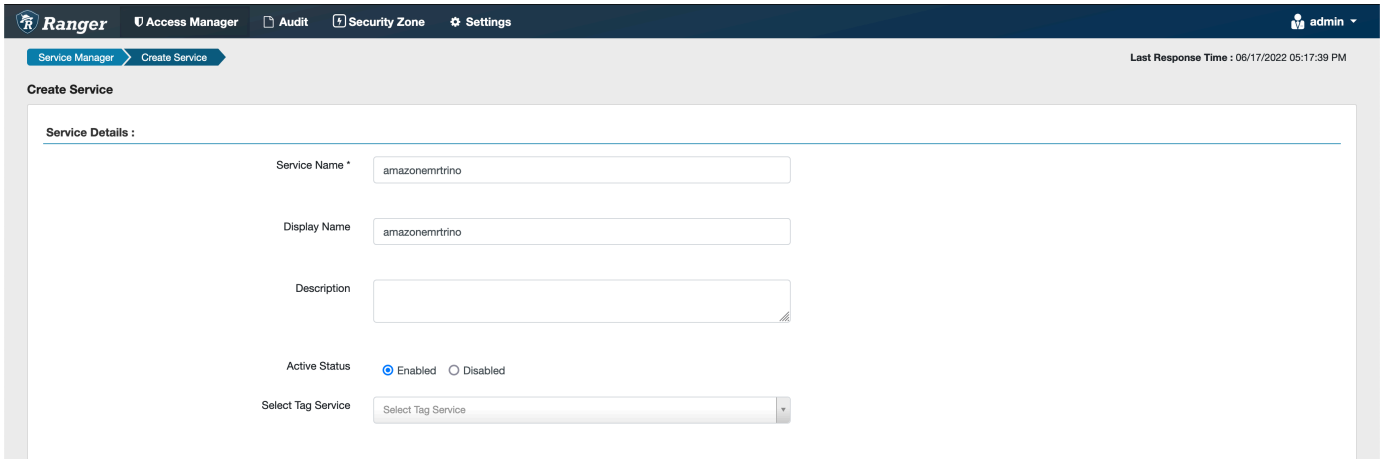

jdbc.Driver.ClassName: Der Klassenname der JDBC-Klasse für Trino-Konnektivität. Sie können den Standardwert verwenden.

jdbc.url: Die JDBC-Verbindungszeichenfolge, die verwendet werden soll, wenn eine Verbindung zum Trino-Koordinator hergestellt wird.

Allgemeiner Name für das Zertifikat: Das CN-Feld innerhalb des Zertifikats, das verwendet wird, um von einem Client-Plugin aus eine Verbindung zum Admin-Server herzustellen. Dieser Wert muss mit dem CN-Feld in Ihrem TLS-Zertifikat übereinstimmen, das für das Plugin erstellt wurde.

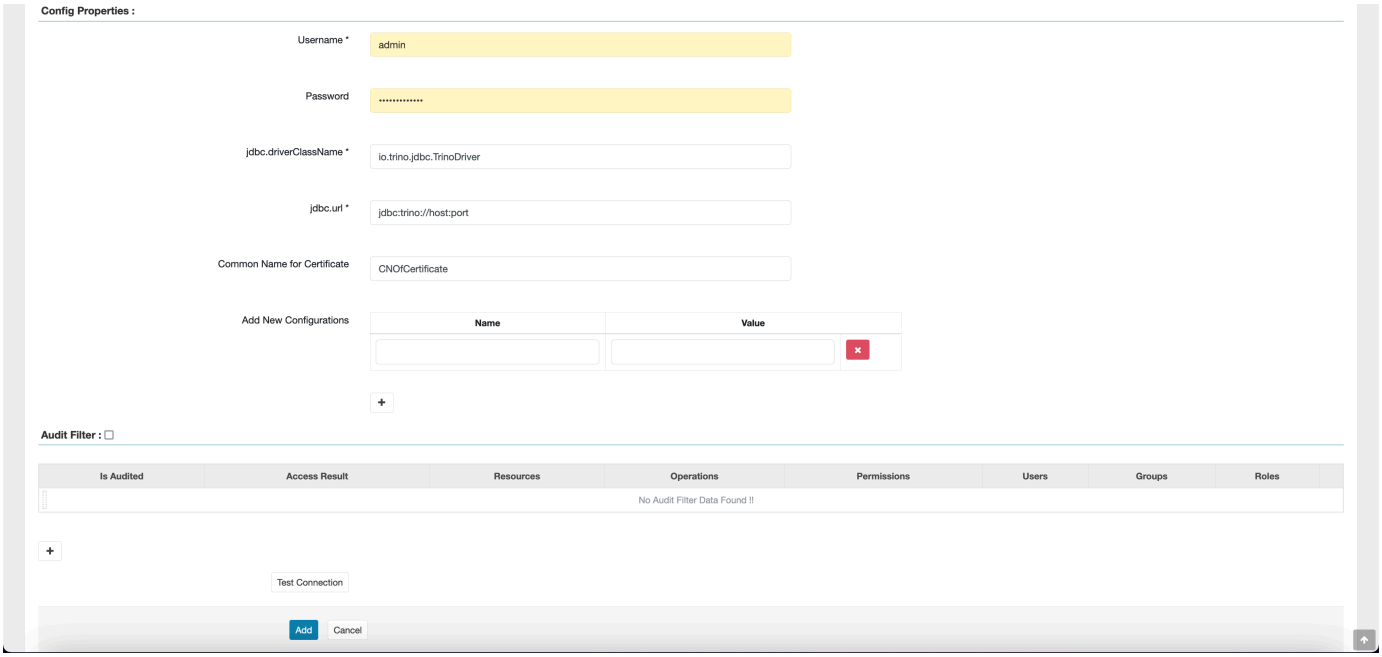

Das TLS-Zertifikat für dieses Plugin sollte im Trust-Store auf dem Ranger-Admin-Server registriert worden sein. Weitere Informationen finden Sie unter TLS-Zertifikate.

Erstellen von Trino-Richtlinien

Wenn Sie eine neue Richtlinie erstellen, füllen Sie die folgenden Felder aus.

Richtlinienname: Der Name dieser Richtlinie.

Richtlinienbezeichnung: Eine Bezeichnung, die Sie dieser Richtlinie hinzufügen können.

Tabelle: Die Tabellen, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Tabellen.

Schema: Die Schemas, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Schemas.

Tabelle: Die Tabellen, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Tabellen.

Spalte: Die Spalten, für die diese Richtlinie gilt. Der Platzhalter „*“ steht für alle Spalten.

Beschreibung: Eine Beschreibung dieser Richtlinie.

Andere Arten von Richtlinien gibt es für den Trino-Benutzer (für den Zugriff, der sich als Benutzer ausgibt), die Trino-System-/Sitzungseigenschaft (für die Änderung der System- oder Sitzungseigenschaften der Engine), für Funktionen/Prozeduren (für das Zulassen von Funktions- oder Prozeduraufrufen) und die URL (für die Gewährung von Lese-/Schreibzugriff auf die Engine an Datenspeicherorten).

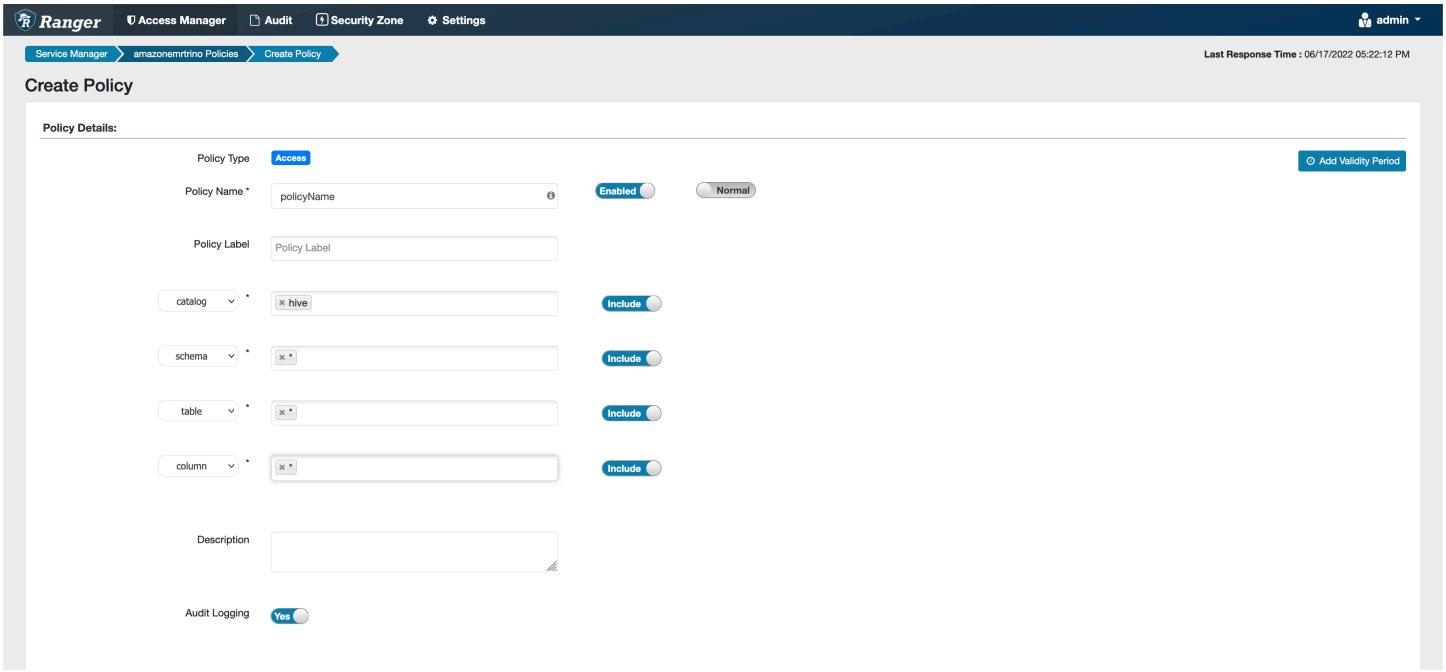

Um die Benutzer und Gruppen anzugeben, geben Sie die Benutzer und Gruppen unten ein, um Berechtigungen zu erteilen. Sie können auch Ausnahmen für Zulassungsbedingungen und Verweigerungsbedingungen angeben.

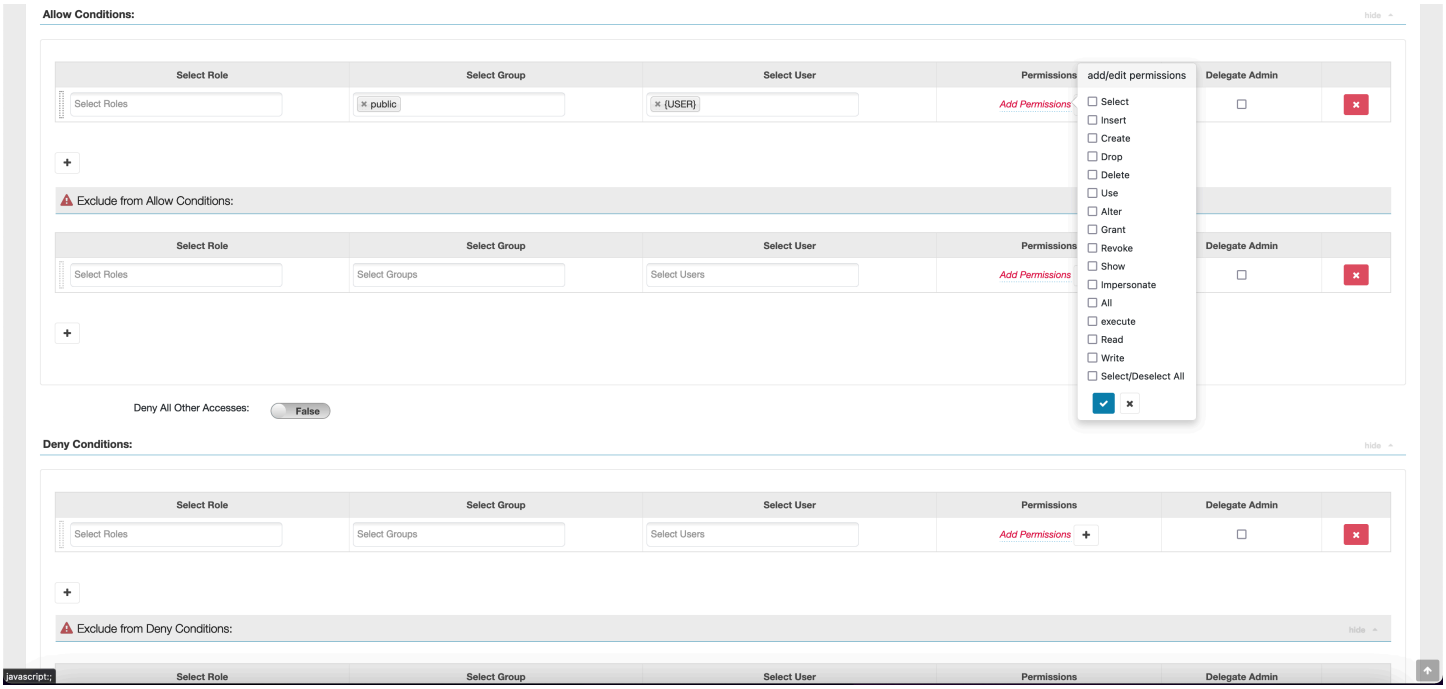

Nachdem Sie die Bedingungen für das Zulassen und Verweigern angegeben haben, klicken Sie auf Speichern.

Überlegungen

Bei der Erstellung von Trino-Richtlinien in Apache Ranger sind einige Nutzungsaspekte zu beachten.

Hive-Metadatenserver

Auf den Hive-Metadatenserver können nur vertrauenswürdige Engines zugreifen, insbesondere die Trino-Engine, um sich vor unbefugtem Zugriff zu schützen. Auf den Hive-Metadatenserver greifen auch alle Knoten im Cluster zu. Der erforderliche Port 9 083 ermöglicht allen Knoten den Zugriff auf den Hauptknoten.

Authentifizierung

Standardmäßig ist Trino so konfiguriert, dass es sich mithilfe von Kerberos authentifiziert, wie in der Amazon-EMR-Sicherheitskonfiguration konfiguriert.

Verschlüsselung während der Übertragung erforderlich

Für das Trino-Plugin müssen Sie die Verschlüsselung während der Übertragung in der Amazon-EMR-Sicherheitskonfiguration aktiviert haben. Informationen zum Aktivieren der Verschlüsselung finden Sie unter Verschlüsselung während der Übertragung.

Einschränkungen

Im Folgenden sind die aktuellen Einschränkungen des Trino-Plugins aufgeführt:

- Der Ranger-Admin-Server unterstützt die automatische Vervollständigung nicht.

Fehlerbehebung für Apache Ranger

Im Folgenden finden Sie einige häufig diagnostizierte Probleme im Zusammenhang mit der Verwendung von Apache Ranger.

Empfehlungen

- Testen Sie mit einem einzigen Hauptknotencluster: Master-Cluster mit einem Knoten können schneller bereitgestellt werden als ein Cluster mit mehreren Knoten, wodurch die Zeit für jede Test-Iteration verkürzt werden kann.
- Stellen Sie den Entwicklungsmodus auf dem Cluster ein. Wenn Sie Ihren EMR-Cluster starten, setzen Sie den `--additional-info`"-Parameter auf:

  ```
  '{"clusterType":"development"}'
  ```

  Dieser Parameter kann nur über die AWS-CLI oder das AWS- SDK festgelegt werden und ist nicht über die Amazon-EMR-Konsole verfügbar. Wenn dieses Flag gesetzt ist und der Master nicht bereitstellen kann, hält der Amazon-EMR-Service den Cluster für einige Zeit am Leben, bevor er außer Betrieb genommen wird. Diese Zeit ist sehr nützlich, um verschiedene Protokolldateien zu überprüfen, bevor der Cluster beendet wird.

EMR-Cluster konnte nicht bereitgestellt werden

Es gibt mehrere Gründe, warum ein Amazon-EMR-Cluster möglicherweise nicht gestartet werden kann. Im Folgenden finden Sie einige Möglichkeiten, das Problem zu diagnostizieren.

Überprüfen Sie die EMR-Bereitstellungsprotokolle

Amazon EMR verwendet Puppet, um Anwendungen auf einem Cluster zu installieren und zu konfigurieren. Anhand der Protokolle erhalten Sie Informationen darüber, ob während der Bereitstellungsphase eines Clusters Fehler aufgetreten sind. Auf die Protokolle kann auf dem Cluster oder in S3 zugegriffen werden, wenn die Protokolle so konfiguriert sind, dass sie an S3 übertragen werden.

Die Protokolle werden auf der Festplatte `/var/log/provision-node/apps-phase/0/{UUID}/puppet.log` und `s3://<LOG LOCATION>/<CLUSTER ID>/node/<EC2 INSTANCE ID>/provision-node/apps-phase/0/{UUID}/puppet.log.gz.` gespeichert.

Allgemeine Fehlermeldungen

Fehlermeldung	Ursache
Puppet (err): Der Systemd-Start für den emr-record-server ist fehlgeschlagen! Journalctl-Protokoll für emr-Record-Server:	EMR Record Server konnte nicht gestartet werden. Weitere Informationen finden Sie unten in den EMR-Record-Server-Protokollen.
Puppet (err): Der Systemd-Start für den emr-record-server ist fehlgeschlagen! Journalctl-Protokoll für emr-Record-Server:	EMR Record Server konnte nicht gestartet werden. Weitere Informationen finden Sie weiter unten unter Secret-Agent-Protokolle überprüfen.
/Stage[main]/Ranger_plugins::Ranger_hive_plugin/Ranger_plugins::Prepare_two_way_tls[configure 2-way TLS in Hive plugin]/Exec[create keystore and truststore for Ranger Hive plugin]/returns (notice): 140408606197664:error:0906D06C:PEM routines:PEM_read_bio:no start line:pem_lib.c:707:Expecting: ANY PRIVATE KEY	Das private TLS-Zertifikat in Secret Manager für das Apache Ranger-Plug-in-Zertifikat hat nicht das richtige Format oder ist kein privates Zertifikat. Informationen zu TLS-Zertifikate den Zertifikatsformaten finden Sie unter.
/Stage[main]/Ranger_plugins::Ranger_s3_plugin/Ranger_plugins::Prepare_two_way_tls[configure 2-way TLS in Ranger s3 plugin]/Exec[create keystore and truststore for Ranger amazon-emr-s3 plugin]/returns (notice): An error occurred (AccessDeniedException) when calling the GetSecretValue operation: User: arn:aws:sts::XXXXXXXXXXX:assumed-role/EMR_EC2_DefaultRole/i-XXXXXXXXXXX	Die EC2-Instance-Profilrolle verfügt nicht über die richtigen Berechtigungen, um die TLS-Zertifikate von Secrets Agent abzurufen.

Fehlermeldung	Ursache
is not authorized to perform: secretsma nager:GetSecretValue on resource: arn:aws:s ecretsmanager:us-east-1:XXXXXXXXXX:s ecret:AdminServer-XXXXX	

Überprüfen Sie die Secret-Agent-Protokolle

Secret-Agent-Protokolle befinden sich in `/emr/secretagent/log/` auf einem EMR-Knoten oder im `s3://<LOG LOCATION>/<CLUSTER ID>/node/<EC2 INSTANCE ID>/daemons/secretagent/`-Verzeichnis in S3.

Allgemeine Fehlermeldungen

Fehlermeldung	Ursache
Ausnahme im Thread „main“ com.amazo naws.services.securitytoken.model.AW SSecurityTokenServiceException: User: arn:aws:sts::XXXXXXXXXXXX:assumed-ro le/EMR_EC2_DefaultRole/i-XXXXXXXXXXX XXXX is not authorized to perform: sts:Assum eRole on resource: arn:aws:iam::XXXXX XXXXXXX:role/*RangerPluginDataAccess Role* (Service: AWSSecurityTokenService; Status Code: 403; Error Code: AccessDenied; Request ID: XXXXXXXX-XXXX-XXXX-XXXX-XXXXXXXXXXXX; Proxy: null)	Die obige Ausnahme bedeutet, dass die EMR-EC2-Instance-Profilrolle nicht berechtig t ist, die Rolle RangerPluginDataAccessRole anzunehmen. Siehe IAM-Rollen für die native Integration mit Apache Ranger.
FEHLER qtp54617902-149: Eine Web-App-A usnahme ist aufgetreten javax.ws.rs.NotAllowedException: HTTP 405-Methode nicht erlaubt	Diese Fehler können ignoriert werden.

Überprüfen Sie die Record-Serverprotokolle (für SparkSQL)

EMR-Record Server-Protokolle sind unter /var/log/emr-record-server/ auf einem EMR-Knoten verfügbar. Sie können auch im Verzeichnis s3://<LOG LOCATION>/<CLUSTER ID>/node/<EC2 INSTANCE ID>/daemons/emr-record-server/ in S3 gefunden werden.

Allgemeine Fehlermeldungen

Fehlermeldung	Ursache
InstanceMetadataServiceResourceFetcher:105 – [] Token konnte nicht abgerufen werden. com.amazonaws.SdkClientException: Verbindung zum Serviceendpunkt konnte nicht hergestellt werden	Der EMR SecretAgent konnte nicht aufgerufen werden oder hat ein Problem. Untersuchen Sie die SecretAgent-Protokolle auf Fehler und das Puppet-Skript, um festzustellen, ob Bereitstellungsfehler aufgetreten sind.

Abfragen schlagen unerwartet fehl

Überprüfen Sie die Protokolle des Apache-Ranger-Plugins (Apache Hive, EMR RecordServer, EMR SecretAgent usw., Protokolle)

Dieser Abschnitt gilt für alle Anwendungen, die in das Ranger-Plugin integriert sind, wie Apache Hive, EMR Record Server und EMR SecretAgent.

Allgemeine Fehlermeldungen

Fehlermeldung	Ursache
FEHLER PolicyRefresher:272 - [] PolicyRefresher (serviceName=policy-repository): Service konnte nicht gefunden werden. Löscht den lokalen Richtliniencache (-1)	Diese Fehlermeldungen bedeuten, dass der Servicename, den Sie in der EMR-Sicherheitskonfiguration angegeben haben, nicht mit einem Service-Richtlinien-Repository auf dem Ranger-Admin-Server übereinstimmt.

Wenn Ihr AMAZON-EMR-SPARK-Dienst auf dem Ranger Admin-Server wie folgt aussieht, sollten Sie als Servicenamen **`amazonemrspark`** eingeben.

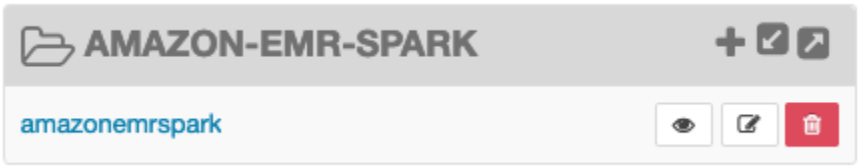

Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen

Sicherheitsgruppen dienen als virtuelle Firewalls für die EC2-Instances in Ihrem Cluster, um den ein- und ausgehenden Datenverkehr zu kontrollieren. Für jede Sicherheitsgruppe gibt es einen Satz von Regeln zur Kontrolle des eingehenden Datenverkehrs und einen Satz von Regeln zur Kontrolle des ausgehenden Datenverkehrs. Weitere Informationen finden Sie unter Amazon-EC2-Sicherheitsgruppen für Linux-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Sie verwenden zwei Klassen von Sicherheitsgruppen mit Amazon EMR:: Amazon EMR:-verwaltete Sicherheitsgruppen und zusätzliche Sicherheitsgruppen.

Mit jedem Cluster sind verwaltete Sicherheitsgruppen verknüpft. Sie können die standardmäßigen verwalteten Sicherheitsgruppen die Amazon EMR erstellt oder benutzerdefinierte verwaltete Sicherheitsgruppen angeben. In jedem Fall fügt Amazon EMR den verwalteten Sicherheitsgruppen automatisch Regeln hinzu, die ein Cluster für die Kommunikation zwischen Cluster-Instances und AWS-Services benötigt.

Zusätzliche Sicherheitsgruppen sind optional. Sie können sie zusätzlich zu den verwalteten Sicherheitsgruppen angeben, um den Zugriff auf Cluster-Instances anzupassen. Zusätzliche Sicherheitsgruppen enthalten nur von Ihnen definierte Regeln. Amazon EMR ändert sie nicht.

Die von Amazon EMR in verwalteten Sicherheitsgruppen erstellten Regeln gestatten dem Cluster nur die Kommunikation zwischen internen Komponenten. Um Benutzern und Anwendungen den Zugriff auf einen Cluster von außerhalb des Clusters zu ermöglichen, können Sie Regeln in verwalteten Sicherheitsgruppen bearbeiten, zusätzliche Sicherheitsgruppen mit zusätzlichen Regeln erstellen oder beides ausführen.

> **Important**
>
> Das Bearbeiten von Regeln in verwalteten Sicherheitsgruppen kann unbeabsichtigte Folgen haben. Möglicherweise blockieren Sie versehentlich den Datenverkehr, der für die ordnungsgemäße Funktion der Cluster erforderlich ist, und verursachen Fehler, da die Knoten

nicht erreichbar sind. Planen und testen Sie Sicherheitsgruppenkonfigurationen sorgfältig, bevor Sie diese implementieren.

Sie können Sicherheitsgruppen nur während der Erstellung eines Clusters angeben. Sie können keine Sicherheitsgruppen zu Clustern oder Cluster-Instances hinzufügen, während ein Cluster ausgeführt wird. Sie können jedoch Regeln in vorhandenen Sicherheitsgruppen bearbeiten, hinzufügen und entfernen. Die Regeln treten in Kraft, sobald Sie sie speichern.

Sicherheitsgruppen sind standardmäßig einschränkend. Wenn keine Regel hinzugefügt wird, die Datenverkehr zulässt, wird der Datenverkehr zurückgewiesen. Wenn es mehr als eine Regel für denselben Datenverkehr und dieselbe Quelle gibt, wird die toleranteste Regel angewendet. Wenn es beispielsweise eine Regel gibt, die SSH-Verbindungen von der IP-Adresse 192.0.2.12/32 zulässt, und eine weitere Regel, die dem gesamten TCP-Datenverkehr Zugriff aus dem Bereich 192.0.2.0/24 gewährt, hat die Regel Vorrang, die dem gesamten TCP-Datenverkehr aus dem Bereich Zugriff gewährt, der 192.0.2.12 einschließt. In diesem Fall könnte der Client unter 192.0.2.12 mehr Zugriff erhalten als beabsichtigt.

Important

Seien Sie vorsichtig, wenn Sie Regeln für offene Ports für Sicherheitsgruppen bearbeiten. Stellen Sie sicher, dass Sie Regeln hinzufügen, die nur Datenverkehr von vertrauenswürdigen und authentifizierten Clients für die Protokolle und Ports zulassen, die zum Ausführen Ihrer Workloads erforderlich sind.

Sie können Amazon EMR Block Public Access in jeder Region konfigurieren, die Sie verwenden, um die Cluster-Erstellung zu verhindern, wenn eine Regel den öffentlichen Zugriff auf beliebige Ports zulässt, die Sie nicht einer Liste von Ausnahmen hinzufügen. Für AWS-Konten, die nach Juli 2019 erstellt wurden, ist Amazon EMR Block Public Access standardmäßig aktiviert. Für AWS-Konten, die vor Juli 2019 einen Cluster erstellt haben, ist Amazon EMR Block Public Access standardmäßig deaktiviert. Weitere Informationen finden Sie unter Verwenden von Amazon EMR Block Public Access.

Themen

- Arbeiten mit von Amazon EMR verwalteten Sicherheitsgruppen
- Arbeiten mit zusätzlichen Sicherheitsgruppen

- Angeben von Amazon EMR-verwalteten und zusätzlichen Sicherheitsgruppen
- Angeben von EC2-Sicherheitsgruppen für EMR Notebooks
- Verwenden von Amazon EMR Block Public Access

> **Note**
>
> Amazon EMR ist bestrebt, integrative Alternativen für potenziell anstößige oder nicht inklusive Branchenbegriffe wie „Master“ und „Slave“ zu verwenden. Wir haben auf eine neue Terminologie umgestellt, um ein umfassenderes Erlebnis zu bieten und Ihnen das Verständnis der Servicekomponenten zu erleichtern.
> Wir beschreiben „Knoten“ jetzt als Instances und Amazon-EMR-Instance-Typen als Primär, Core, und Aufgaben-Instances. Während der Umstellung finden Sie möglicherweise immer noch ältere Verweise auf die veralteten Begriffe, z. B. solche, die sich auf Sicherheitsgruppen für Amazon EMR beziehen.

Arbeiten mit von Amazon EMR verwalteten Sicherheitsgruppen

> **Note**
>
> Amazon EMR ist bestrebt, integrative Alternativen für potenziell anstößige oder nicht inklusive Branchenbegriffe wie „Master“ und „Slave“ zu verwenden. Wir haben auf eine neue Terminologie umgestellt, um ein umfassenderes Erlebnis zu bieten und Ihnen das Verständnis der Servicekomponenten zu erleichtern.
> Wir beschreiben „Knoten“ jetzt als Instances und Amazon-EMR-Instance-Typen als Primär, Core, und Aufgaben-Instances. Während der Umstellung finden Sie möglicherweise immer noch ältere Verweise auf die veralteten Begriffe, z. B. solche, die sich auf Sicherheitsgruppen für Amazon EMR beziehen.

Mit der Primär-Instance und den Core- und Aufgaben-Instances in einem Cluster sind verschiedene verwaltete Sicherheitsgruppen verknüpft. Sie benötigen eine zusätzliche verwaltete Sicherheitsgruppe für den Servicezugriff, wenn Sie einen Cluster in einem privaten Subnetz erstellen. Weitere Informationen zur Rolle von verwalteten Sicherheitsgruppen in Bezug auf Ihre Netzwerkkonfiguration finden Sie unter Optionen für Amazon-VPC.

Wenn Sie verwaltete Sicherheitsgruppen für einen Cluster angeben, müssen Sie für alle verwalteten Sicherheitsgruppen denselben Typ von Sicherheitsgruppe (Standard oder benutzerdefiniert) verwenden. Sie können beispielsweise nicht eine benutzerdefinierte Sicherheitsgruppe für die Primär-Instance angeben und dann keine benutzerdefinierte Sicherheitsgruppe für die Core- und Aufgaben-Instances angeben.

Wenn Sie standardmäßige verwaltete Sicherheitsgruppen verwenden, müssen Sie diese beim Erstellen eines Clusters nicht angeben. Amazon EMR verwendet automatisch die Standardeinstellungen. Wenn die Standardeinstellungen in der VPC des Clusters noch nicht vorhanden sind, werden sie außerdem von Amazon EMR erstellt. Amazon EMR erstellt sie auch, wenn Sie sie explizit angeben und sie noch nicht existieren.

Sie können die Regeln in verwalteten Sicherheitsgruppen nach der Erstellung der Cluster bearbeiten. Wenn Sie einen neuen Cluster erstellen, überprüft Amazon EMR die Regeln in den von Ihnen angegebenen verwalteten Sicherheitsgruppen und erstellt dann alle fehlenden eingehenden Regeln, die der neue Cluster zusätzlich zu den Regeln benötigt, die möglicherweise zuvor hinzugefügt wurden. Sofern nicht anders definiert, werden alle Regeln, die für standardmäßig Amazon EMR-verwaltete Sicherheitsgruppen gelten, auch den von Ihnen angegebenen benutzerdefinierten Amazon EMR-verwalteten Sicherheitsgruppen hinzugefügt.

Die standardmäßigen verwalteten Sicherheitsgruppen sind:

- ElasticMapReduce-primary

  Informationen zu den Regeln in dieser Sicherheitsgruppe finden Sie unter Amazon-EMR-verwaltete Sicherheitsgruppe für die primäre Instance (öffentliche Subnetze).
- ElasticMapReduce-core

  Informationen zu den Regeln in dieser Sicherheitsgruppe finden Sie unter Amazon EMR erwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances (öffentliche Subnetze).
- ElasticMapReduce-Primary-Private

  Informationen zu den Regeln in dieser Sicherheitsgruppe finden Sie unter Amazon EMR-verwaltete Sicherheitsgruppe für die Master-Instance (private Subnetze).
- ElasticMapReduce-Core-Private

  Informationen zu den Regeln in dieser Sicherheitsgruppe finden Sie unter Von Amazon EMR verwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances (private Subnetze).
- ElasticMapReduce-ServiceAccess

Informationen zu den Regeln in dieser Sicherheitsgruppe finden Sie unter Amazon EMR-verwaltete Sicherheitsgruppe für den Servicezugriff (private Subnetze).

Amazon-EMR- verwaltete Sicherheitsgruppe für die primäre Instance (öffentliche Subnetze)

Der Wert der standardmäßigen verwalteten Sicherheitsgruppe für die Primär-Instance in öffentlichen Subnetzen in Gruppenname ist ElasticMapReduce-master. Sie hat die folgenden Regeln. Wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe angeben, fügt Amazon EMR Ihrer benutzerdefinierten Sicherheitsgruppe dieselben Regeln hinzu.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für eingehenden Datenverkehr				
Alle ICMP-IPv4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance. Mit anderen Worten, dieselbe Sicherheitsgruppe, in der die Regel angezeigt wird.	Diese reflexiven Regeln ermöglichen eingehenden Datenverkehr aus allen mit der angegebenen Sicherheitsgruppe verknüpften Instances. Die Verwendung der standardm äßigen verwalteten Sicherheitsgruppe `ElasticMapReduce-primary` für mehrere Cluster ermöglicht den Core- und Aufgabenknoten dieser Cluster die gegenseit ige Kommunikation über ICMP oder einen TCP- oder UDP-Port. Sie geben benutzerd efinierte verwaltete Sicherheitsgruppen an, um den Cluster-übergreifenden Zugriff einzuschränken.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe, die für Core- und	Diese Regeln lassen jeden eingehenden ICMP-Datenverkehr und jeden Datenverk ehr über TCP- oder UDP-Ports aus allen Core- und Aufgaben-Instances zu, die mit der angegebenen Sicherheitsgruppe
Alle TCP	TCP	Alle		

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Alle UDP	UDP	Alle	Aufgabenknoten angegeben wurde.	verknüpft sind, auch wenn sich die Instances in verschiedenen Clustern befinden.
Benutzerd efiniert	TCP	8443	Verschiedene Amazon-IP-Adressbereiche	Diese Regeln ermöglichen dem Cluster-Manager die Kommunikation mit dem Primärknoten.

Wie Sie vertrauenswürdigen Quellen SSH-Zugriff auf die primäre Sicherheitsgruppe mit der alten Konsole gewähren

Um Ihre Sicherheitsgruppen zu bearbeiten, benötigen Sie die Berechtigung, Sicherheitsgruppen für die VPC zu verwalten, in der sich der Cluster befindet. Weitere Informationen finden Sie im IAM-Benutzerhandbuch unter Ändern von Benutzerberechtigungen und unter Beispielrichtlinie, die die Verwaltung von EC2-Sicherheitsgruppen ermöglicht.

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Clusters (Cluster) aus. Wählen Sie den Namen des Clusters, den Sie ändern möchten.
3. Wählen Sie unter Sicherheit und Zugriff den Link Sicherheitsgruppen für Master.
4. Wählen Sie aus der Liste ElasticMapReduce-master.
5. Wählen Sie die Registerkarte Eingehende Regeln und anschließend Eingehende Regeln bearbeiten aus.
6. Suchen Sie mit den folgenden Einstellungen nach einer Regel für eingehenden Datenverkehr, die öffentlichen Zugriff ermöglicht. Falls sie existiert, wählen Sie Löschen, um sie zu entfernen.

   - Typ

     SSH
   - Port

     22

- Source (Quelle)

  Benutzerdefiniert 0.0.0.0/0

> **Warning**
>
> Vor Dezember 2020 verfügte die ElasticMapReduce-Master-Sicherheitsgruppe über eine vorkonfigurierte Regel, die eingehenden Datenverkehr auf Port 22 aus allen Quellen zuließ. Diese Regel wurde erstellt, um die ersten SSH-Verbindungen zum Primärknoten zu vereinfachen. Wir empfehlen Ihnen dringend, diese Eingangsregel zu entfernen und den Datenverkehr auf vertrauenswürdige Quellen zu beschränken.

7. Scrollen Sie zum Ende der Regelliste und wählen Sie Regel hinzufügen.
8. Wählen Sie für Type (Typ) SSH aus.

   Wenn Sie SSH auswählen, wird automatisch TCP für Protokoll und 22 für Portbereich eingegeben.
9. Wählen Sie als Quelle Meine IP aus, um Ihre IP-Adresse automatisch als Quelladresse hinzuzufügen. Sie können auch einen Bereich benutzerdefinierter vertrauenswürdiger Client-IP-Adressen hinzufügen oder zusätzliche Regeln für andere Clients erstellen. In vielen Netzwerkumgebungen werden IP-Adressen dynamisch zugewiesen, sodass Sie in Zukunft möglicherweise Ihre IP-Adressen für vertrauenswürdige Clients aktualisieren müssen.
10. Wählen Sie Save (Speichern).
11. Wählen Sie optional ElasticMapReduce-slave aus der Liste aus und wiederholen Sie die obigen Schritte, um dem SSH-Client Zugriff auf Core- und Aufgabenknoten zu ermöglichen.Clients zuzulassen.

Amazon EMR erwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances (öffentliche Subnetze)

Die standardmäßige verwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances in öffentlichen Subnetzen hat den Gruppennamen ElasticMapReduce-core. Für die verwaltete Standardsicherheitsgruppe gelten die folgenden Regeln. Amazon EMR fügt die gleichen Regeln hinzu, wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe angeben.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für eingehenden Datenverkehr				
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwaltet en Sicherhei tsgruppe für Core- und Aufgaben-Instances. Mit anderen Worten, dieselbe Sicherhei tsgruppe, in der die Regel angezeigt wird.	Diese reflexiven Regeln ermöglichen eingehenden Datenverkehr aus allen mit der angegebenen Sicherheitsgruppe verknüpften Instances. Die Verwendung der standardm äßigen verwalteten Sicherheitsgruppe `ElasticMapReduce-core` für mehrere Cluster ermöglicht den Core- und Aufgaben-Instances dieser Cluster die gegenseitige Kommunikation über ICMP oder einen TCP- oder UDP-Port. Sie geben benutzerdefinierte verwaltete Sicherheitsgruppen an, um den Cluster-übergreifenden Zugriff einzuschr änken.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance.	Diese Regeln lassen jeden eingehenden ICMP-Datenverkehr und jeden Datenverk ehr über TCP- oder UDP-Ports aus allen Primär-Instances zu, die mit der angegeben en Sicherheitsgruppe verknüpft sind, auch wenn sich die Instances in verschiedenen Clustern befinden.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		

Amazon EMR-verwaltete Sicherheitsgruppe für die Master-Instance (private Subnetze)

Die standardmäßige verwaltete Sicherheitsgruppe für die primäre-Instance in privaten Subnetzen hat den Gruppennamen ElasticMapReduce-Primary-Private. Für die verwaltete Standardsicherheitsgruppe gelten die folgenden Regeln. Amazon EMR fügt die gleichen Regeln hinzu, wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe angeben.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für eingehenden Datenverkehr				
Alle ICMP-IPv4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance. Mit anderen Worten, dieselbe Sicherheitsgruppe, in der die Regel angezeigt wird.	Diese reflexiven Regeln ermöglichen eingehenden Datenverkehr aus allen mit der angegebenen Sicherheitsgruppe verknüpften Instances, die aus dem privaten Subnetz erreichbar sind. Die Verwendung der standardmäßigen verwalteten Sicherhei tsgruppe `ElasticMapReduce-Primary-Private` für mehrere Cluster ermöglich t den Core- und Aufgabenknoten dieser Cluster die gegenseitige Kommunikation über ICMP oder einen TCP- oder UDP-Port. Sie geben benutzerdefinierte verwaltete Sicherhei tsgruppen an, um den Cluster-übergreifenden Zugriff einzuschränken.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe für Core- und Aufgabenknoten.	Diese Regeln lassen jeden eingehenden ICMP-Datenverkehr und jeden Datenverk ehr über TCP- oder UDP-Ports aus allen Core- und Aufgaben-Instances zu, die mit der angegebenen Sicherheitsgruppe verknüpft und aus dem privaten Subnetz erreichba r sind, auch wenn sich die Instances in verschiedenen Clustern befinden.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		
HTTPS (8443)	TCP	8443	Die Gruppen-ID der verwalteten Sicherheitsgruppe für den Servicezu griff in einem privaten Subnetz.	Diese Regel ermöglicht dem Cluster-Manager die Kommunikation mit dem Primärknoten.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für ausgehenden Datenverkehr				
Gesamter Datenverkehr	Alle	Alle	0.0.0.0/0	Stellt ausgehenden Zugriff auf das Internet zu.
Custom TCP	TCP	9443	Die Gruppen-ID der verwalteten Sicherheitsgruppe für den Servicezugriff in einem privaten Subnetz.	Wenn die obige Standardregel „Gesamter Datenverkehr“ für ausgehenden Datenverkehr entfernt wird, ist diese Regel eine Mindestanforderung für Amazon EMR 5.30.0 und höher. **Note** Amazon EMR fügt diese Regel nicht hinzu, wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe verwenden.
Custom TCP	TCP	80 (http) oder 443 (https)	Die Gruppen-ID der verwalteten Sicherheitsgruppe für den Servicezugriff in einem privaten Subnetz.	Wenn die obige Standardregel „Gesamter Datenverkehr“ für ausgehenden Datenverkehr entfernt wird, ist diese Regel eine Mindestanforderung für Amazon EMR 5.30.0 und höher, um über https eine Verbindung zu Amazon S3 herzustellen. **Note** Amazon EMR fügt diese Regel nicht hinzu, wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe verwenden.

Von Amazon EMR verwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances (private Subnetze)

Die standardmäßige verwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances in privaten Subnetzen hat den Gruppennamen ElasticMapReduce-Core-Private. Für die verwaltete Standardsicherheitsgruppe gelten die folgenden Regeln. Amazon EMR fügt die gleichen Regeln hinzu, wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe angeben.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für eingehenden Datenverkehr				
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwaltet en Sicherhei tsgruppe für Core- und Aufgaben-Instances. Mit anderen Worten, dieselbe Sicherhei tsgruppe, in der die Regel angezeigt wird.	Diese reflexiven Regeln ermöglichen eingehenden Datenverkehr aus allen mit der angegebenen Sicherheitsgruppe verknüpften Instances. Die Verwendung der standardm äßigen verwalteten Sicherheitsgruppe `ElasticMapReduce-core` für mehrere Cluster ermöglicht den Core- und Aufgaben-Instances dieser Cluster die gegenseitige Kommunikation über ICMP oder einen TCP- oder UDP-Port. Sie geben benutzerdefinierte verwaltete Sicherheitsgruppen an, um den Cluster-übergreifenden Zugriff einzuschr änken.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		
Alle ICMP-IPV4	Alle	–	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance.	Diese Regeln lassen jeden eingehenden ICMP-Datenverkehr und jeden Datenverk ehr über TCP- oder UDP-Ports aus allen Primär-Instances zu, die mit der angegeben en Sicherheitsgruppe verknüpft sind, auch wenn sich die Instances in verschiedenen Clustern befinden.
Alle TCP	TCP	Alle		
Alle UDP	UDP	Alle		

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
HTTPS (8443)	TCP	8443	Die Gruppen-ID der verwalteten Sicherheitsgruppe für den Servicezu griff in einem privaten Subnetz.	Diese Regel ermöglicht dem Cluster-Manager die Kommunikation mit Core- und Aufgabenk noten.
Regeln für ausgehenden Datenverkehr				
Gesamter Datenverk ehr	Alle	Alle	0.0.0.0/0	Weitere Informationen finden Sie unter Regeln für ausgehenden Datenverkehr bearbeiten weiter unten in diesem Dokument.
Custom TCP	TCP	80 (http) oder 443 (https)	Die Gruppen-ID der verwalteten Sicherheitsgruppe für den Servicezu griff in einem privaten Subnetz.	Wenn die obige Standardregel „Gesamter Datenverkehr“ für ausgehenden Datenverkehr entfernt wird, ist diese Regel eine Mindestan forderung für Amazon EMR 5.30.0 und höher, um über https eine Verbindung zu Amazon S3 herzustellen. **Note** Amazon EMR fügt diese Regel nicht hinzu, wenn Sie eine benutzerd efinierte verwaltete Sicherheitsgruppe verwenden.

Regeln für ausgehenden Datenverkehr bearbeiten

Standardmäßig erstellt Amazon EMR diese Sicherheitsgruppe mit ausgehenden Regeln, die den gesamten ausgehenden Datenverkehr auf allen Protokollen und Ports zulassen. Das Zulassen des gesamten ausgehenden Datenverkehrs ist ausgewählt, da für verschiedene Amazon-EMR- und Kundenanwendungen, die auf Amazon-EMR-Clustern ausgeführt werden können,

möglicherweise unterschiedliche Ausgangsregeln erforderlich sind. Amazon EMR kann diese spezifischen Einstellungen bei der Erstellung von Standardsicherheitsgruppen nicht antizipieren. Sie können den ausgehenden Datenverkehr in Ihren Sicherheitsgruppen einschränken, sodass nur die Regeln berücksichtigt werden, die Ihren Anwendungsfällen und Sicherheitsrichtlinien entsprechen. Für diese Sicherheitsgruppe sind mindestens die folgenden Regeln für ausgehenden Datenverkehr erforderlich, für einige Anwendungen sind jedoch möglicherweise zusätzliche Regeln für ausgehenden Datenverkehr erforderlich.

Typ	Protoc (Protok l)	Port-Bere ich	Ziel	Details
Alle TCP	TCP	Alle	pl-*xxxxxxxx*	Verwaltete Präfixliste von Amazon S3 `com.amazonaws.` *MyRegion*`.s3`.
Gesamter Datenverkehr	Alle	Alle	sg-*xxxxxxxxx xxxxxxxx*	Die ID der Sicherheitsgruppe `ElasticMapReduce-Core-Private` .
Gesamter Datenverkehr	Alle	Alle	sg-*xxxxxxxxx xxxxxxxx*	Die ID der Sicherheitsgruppe `ElasticMapReduce-Primary-Private` .
Custom TCP	TCP	9443	sg-*xxxxxxxxx xxxxxxxx*	Die ID der Sicherheitsgruppe `ElasticMapReduce-ServiceAccess` .

Amazon EMR-verwaltete Sicherheitsgruppe für den Servicezugriff (private Subnetze)

Der Wert der standardmäßigen verwalteten Sicherheitsgruppe für den Servicezugriff in privaten Subnetzen in Group Name (Gruppenname) ist ElasticMapReduce-ServiceAccess. Sie besitzt Regeln für den eingehenden und den ausgehenden Datenverkehr, die Datenverkehr über HTTPS (Port 8443, Port 9443) mit den anderen verwalteten Sicherheitsgruppen in privaten Subnetzen zulassen. Diese Regeln ermöglichen dem Cluster-Manager die Kommunikation mit dem Primärknoten und mit Kern- und Aufgabenknoten. Dieselben Regeln sind erforderlich, wenn Sie benutzerdefinierte Sicherheitsgruppen verwenden.

Typ	Protoc (Protok l)	Port-Bere ich	Quelle	Details
Regeln für eingehenden Datenverkehr Erforderlich für EMR-Cluster mit Amazon EMR ab Version 5.30.0.				
Custom TCP	TCP	9443	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance.	Diese Regel ermöglicht die Kommunikation zwischen der Sicherheitsgruppe der Primär-Instance und der Sicherheitsgruppe des Servicezugriffs.
Regeln für ausgehenden Datenverkehr erforderlich für alle Amazon EMR-Cluster				
Custom TCP	TCP	8443	Die Gruppen-ID der verwalteten Sicherheitsgruppe für die Primär-In stance.	Diese Regeln ermöglichen dem Cluster-Manager die Kommunikation mit dem Primärknoten und mit Kern- und Aufgabenk noten.
Custom TCP	TCP	8443	Die Gruppen-I D der verwaltet en Sicherhei tsgruppe für Core- und Aufgaben-Instances.	Diese Regeln ermöglichen dem Cluster-Manager die Kommunikation mit dem Primärknoten und mit Kern- und Aufgabenk noten.

Arbeiten mit zusätzlichen Sicherheitsgruppen

Sie können zusätzliche Sicherheitsgruppen unabhängig davon verwenden, ob Sie die standardmäßigen verwalteten Sicherheitsgruppen verwenden oder benutzerdefinierte verwaltete Sicherheitsgruppen angeben. Mit zusätzlichen Sicherheitsgruppen können Sie den Zugriff auf die einzelnen Cluster und von externen Clients, Ressourcen und Anwendungen anpassen.

Betrachten Sie beispielsweise das folgende Szenario. Es gibt mehrere Cluster, die miteinander kommunizieren müssen. Sie möchten jedoch nur einem bestimmten Teilsatz von Clustern

eingehenden SSH-Zugriff auf die Primär-Instance gewähren. Hierzu können Sie für die Cluster den gleichen Satz von verwalteten Sicherheitsgruppen verwenden. Anschließend erstellen Sie zusätzliche Sicherheitsgruppen, die eingehenden SSH-Zugriff von vertrauenswürdigen Clients zulassen, und geben die zusätzlichen Sicherheitsgruppen für die Primär-Instance für jeden Cluster in der Untergruppe an.

Sie können bis zu vier zusätzliche Sicherheitsgruppen für die Primär-Instance, vier für Core- und Aufgaben-Instances und vier für den Servicezugriff (in privaten Subnetzen) verwenden. Wenn notwendig, können Sie dieselben zusätzlichen Sicherheitsgruppen für Primär-Instances, Core- und Aufgaben-Instances und den Servicezugriff angeben. Die maximale Anzahl von Sicherheitsgruppen und -regeln in Ihrem Konto unterliegt Kontolimits. Weitere Informationen finden Sie unter Sicherheitsgruppenlimits im Amazon-VPC-Benutzerhandbuch.

Angeben von Amazon EMR-verwalteten und zusätzlichen Sicherheitsgruppen

Sie können Sicherheitsgruppen über die AWS Management Console, die AWS CLI oder die Amazon EMR-API angeben. Wenn Sie keine Sicherheitsgruppen angeben, erstellt Amazon EMR Standardsicherheitsgruppen. Die Angabe zusätzlicher Sicherheitsgruppen ist optional. Sie können Primär-Instances, Core- und Aufgaben-Instances und dem Servicezugriff (nur private Subnetze) zusätzliche Sicherheitsgruppen zuweisen.

New console

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

So geben Sie Sicherheitsgruppen mit der Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.

3. Wählen Sie auf der Registerkarte Eigenschaften unter Netzwerk den Pfeil neben EC2-Sicherheitsgruppen (Firewall) aus, um diesen Abschnitt zu erweitern. Unter Primärknoten und Kern- und Aufgabenknoten sind standardmäßig die von Amazon EMR verwalteten Standardsicherheitsgruppen ausgewählt. Wenn Sie ein privates Subnetz verwenden, haben Sie auch die Möglichkeit, eine Sicherheitsgruppe für den Servicezugriff auszuwählen.
4. Um Ihre von Amazon EMR verwaltete Sicherheitsgruppe zu ändern, verwenden Sie das Dropdownmenü Sicherheitsgruppen auswählen, um eine andere Option aus der Optionsliste der von Amazon EMR verwalteten Sicherheitsgruppen auszuwählen. Sie haben eine von Amazon EMR verwaltete Sicherheitsgruppe sowohl für den Primärknoten als auch für den Core- und Aufgabenknoten.
5. Um benutzerdefinierte Sicherheitsgruppen hinzuzufügen, verwenden Sie dasselbe Dropdownmenü Sicherheitsgruppen auswählen, um bis zu vier benutzerdefinierte Sicherheitsgruppen aus der Optionsliste Benutzerdefinierte Sicherheitsgruppen auszuwählen. Sie können bis zu vier benutzerdefinierte Sicherheitsgruppen sowohl für den Primärknoten als auch für den Kern- und Aufgabenknoten einrichten.
6. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
7. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So geben Sie Sicherheitsgruppen mit der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create Cluster (Cluster erstellen) und Go to advanced options (Zu erweiterten Optionen) aus.
3. Wählen Sie Optionen für Ihren Cluster aus, bis Sie Step 4: Security (Schritt 4: Sicherheit) erreichen.
4. Wählen Sie EC2 Security Groups (EC2-Sicherheitsgruppen) aus, um den Abschnitt zu erweitern.

   In EMR managed security groups (EMR-verwaltete Sicherheitsgruppen) sind die standardmäßigen verwalteten Sicherheitsgruppen vorausgewählt. Wenn in der VPC für Master (Master), Core & Task (Core und Aufgabe) oder Service Access (Servicezugriff) (nur

private Subnetze) keine standardmäßigen verwalteten Sicherheitsgruppen vorhanden sind, wird vor dem Namen der verknüpften Sicherheitsgruppe Create (Erstellen) angezeigt.

5. Wenn Sie benutzerdefinierte verwaltete Sicherheitsgruppen verwenden, wählen Sie sie aus den Listen EMR managed security groups (EMR-verwaltete Sicherheitsgruppen) aus.

   Wenn Sie eine benutzerdefinierte verwaltete Sicherheitsgruppe auswählen, werden Sie zur Auswahl einer benutzerdefinierten Sicherheitsgruppe für andere Instances aufgefordert. Sie können für einen Cluster nur benutzerdefinierte oder nur standardmäßige verwaltete Sicherheitsgruppen verwenden.
6. Optional können Sie in Additional security groups (Zusätzliche Sicherheitsgruppen) das Bleistiftsymbol auswählen, bis zu vier Sicherheitsgruppen aus der Liste auswählen und dann Assign security groups (Sicherheitsgruppen zuweisen) auswählen. Wiederholen Sie dies für jeden Eintrag in Master (Master), Core & Task (Core und Aufgabe) und Service Access (Servicezugriff) wie gewünscht.
7. Wählen Sie Create Cluster aus.

Angeben von Sicherheitsgruppen mit der AWS CLI

Um Sicherheitsgruppen über die AWS CLI anzugeben, verwenden Sie den Befehl `create-cluster` mit den folgenden Parametern der Option `--ec2-attributes`:

Parameter	Beschreibung
`EmrManagedPrimarySecurityGroup`	Verwenden Sie diesen Parameter, um eine benutzerdefinierte verwaltete Sicherhei tsgruppe für die Primär-Instance anzugeben . Wenn dieser Parameter angegeben wird, muss auch `EmrManagedCoreSecu rityGroup` angegeben werden. Für Cluster in privaten Subnetzen muss auch `ServiceAc cessSecurityGroup` angegeben werden.
`EmrManagedCoreSecurityGroup`	Verwenden Sie diesen Parameter, um eine benutzerdefinierte verwaltete Sicherheitsgruppe für Core- und Aufgaben-Instances anzugeben.

Parameter	Beschreibung
	Wenn dieser Parameter angegeben wird, muss auch `EmrManagedPrimarySecurityGroup` angegeben werden. Für Cluster in privaten Subnetzen muss auch `ServiceAccessSecurityGroup` angegeben werden.
`ServiceAccessSecurityGroup`	Verwenden Sie diesen Parameter, um eine benutzerdefinierte verwaltete Sicherheitsgruppe für den Servicezugriff anzugeben. Dies gilt nur für Cluster in privaten Subnetzen. Die Sicherheitsgruppe, als die Sie angeben, `ServiceAccessSecurityGroup` sollte nicht für andere Zwecke verwendet werden und sollte auch für Amazon EMR reserviert werden. Wenn dieser Parameter angegeben wird, muss auch `EmrManagedPrimarySecurityGroup` angegeben werden.
`AdditionalPrimarySecurityGroups`	Verwenden Sie diesen Parameter, um bis zu vier zusätzliche verwaltete Sicherheitsgruppen für die Primär-Instance anzugeben.
`AdditionalCoreSecurityGroups`	Verwenden Sie diesen Parameter, um bis zu vier zusätzliche verwaltete Sicherheitsgruppen für die Core- und Aufgaben-Instances anzugeben.

Example – spezifizieren Sie benutzerdefinierte, von Amazon EMR verwaltete Sicherheitsgruppen und zusätzliche Sicherheitsgruppen

Im folgenden Beispiel werden benutzerdefinierte Amazon-EMR-verwaltete Sicherheitsgruppen für einen Cluster in einem privaten Subnetz, mehrere zusätzliche Sicherheitsgruppen für die Master-

Instance und eine einzelne zusätzliche Sicherheitsgruppe für Core- und Aufgaben-Instances angegeben.

> **Note**
>
> Linux-Zeilenfortsetzungszeichen (\) sind aus Gründen der Lesbarkeit enthalten. Sie können entfernt oder in Linux-Befehlen verwendet werden. Entfernen Sie sie unter Windows oder ersetzen Sie sie durch ein Caret-Zeichen (^).

```
aws emr create-cluster --name "ClusterCustomManagedAndAdditionalSGs" \
--release-label emr-emr-5.36.1 --applications Name=Hue Name=Hive \
Name=Pig --use-default-roles --ec2-attributes \
SubnetIds=subnet-xxxxxxxxxxxx,KeyName=myKey,\
ServiceAccessSecurityGroup=sg-xxxxxxxxxxxx,\
EmrManagedPrimarySecurityGroup=sg-xxxxxxxxxxxx,\
EmrManagedCoreSecurityGroup=sg-xxxxxxxxxxx,\
AdditionalPrimarySecurityGroups=['sg-xxxxxxxxxxx',\
'sg-xxxxxxxxxxx','sg-xxxxxxxxxx'],\
AdditionalCoreSecurityGroups=sg-xxxxxxxxxxx \
--instance-type m5.xlarge
```

Weitere Informationen finden Sie unter create-cluster in der AWS CLI-Befehlsreferenz.

Angeben von EC2-Sicherheitsgruppen für EMR Notebooks

Wenn Sie ein EMR Notebook erstellen, wird der Netzwerkdatenverkehr zwischen dem EMR Notebook und dem Amazon-EMR-Cluster mithilfe von zwei Sicherheitsgruppen gesteuert, wenn Notebook-verwendet wird. Die Standard-Sicherheitsgruppen verfügen über Mindestregeln, die nur Netzwerkdatenverkehr zwischen dem EMR-Notebooks-Service und den Clustern zulassen, an die die Notebooks angefügt sind.

Ein EMR-Notebook verwendet Apache Livy, um über einen Proxy über den TCP-Port 18888 mit dem Cluster zu kommunizieren. Indem Sie benutzerdefinierte Sicherheitsgruppen mit an Ihre Umgebung angepassten Regeln erstellen, können Sie den Netzwerkdatenverkehr so einschränken, dass nur ein Teil der Notebooks Code innerhalb des Notebook-Editors auf bestimmten Clustern ausführen kann. Der Cluster verwendet Ihre benutzerdefinierte Sicherheit zusätzlich zu den Standardsicherheitsgruppen für den Cluster. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen im Verwaltungshandbuch für Amazon EMR und Angeben von EC2-Sicherheitsgruppen für EMR Notebooks.

EC2-Standard-Sicherheitsgruppe für die primäre Instance

Zusätzlich zu den Sicherheitsgruppen des Clusters für die primären Instance ist die EC2-Standard-Sicherheitsgruppe für die primären-Instance der Master-Instance zugeordnet.

Gruppenname: ElasticMapReduceEditors-Livy

Regeln

- Eingehend

  Zulassen von TCP Port 18888 von allen Ressourcen in der EC2-Standard-Sicherheitsgruppe für EMR Notebooks
- Ausgehend

  Keine

Standard-EC2-Sicherheitsgruppe für EMR Notebooks

Die EC2-Standard-Sicherheitsgruppe für ist mit dem EMR- Notebook-Editor für alle EMR Notebooks verknüpft, denen sie zugewiesen ist.

Gruppenname: ElasticMapReduceEditors-Editor

Regeln

- Eingehend

  Keine
- Ausgehend

  Lassen Sie TCP Port 18888 auf alle Ressourcen in der EC2-Standard-Sicherheitsgruppe für EMR Notebooks zu.

Benutzerdefinierte EC2-Sicherheitsgruppe für EMR Notebooks beim Zuordnen von Notebooks zu Git-Repositorys

Um ein Git-Repository mit Ihrem Notebook verknüpfen zu können, muss die Sicherheitsgruppe für das EMR Notebook eine Regel für ausgehenden Datenverkehr enthalten, damit das Notebook

Datenverkehr an das Internet weiterleiten kann. Es wird empfohlen, zu diesem Zweck eine neue Sicherheitsgruppe zu erstellen. Wenn Sie die Standard-Sicherheitsgruppe ElasticMapReduceEditors-Editor aktualisieren, können andere Notebooks, die dieser Sicherheitsgruppe zugeordnet sind, möglicherweise die gleichen Regeln für ausgehenden Datenverkehr erhalten.

Regeln

- Eingehend

  Keine

- Ausgehend

  Erlauben Sie dem Notebook, Datenverkehr über den Cluster an das Internet zu leiten, wie im folgenden Beispiel veranschaulicht. Der Wert 0.0.0.0/0 wird für Beispielzwecke verwendet. Sie können diese Regel ändern, um die IP-Adressen für Ihre Git-basierten Repositorys anzugeben.

Typ	Protocol (Protokoll)	Port-Bereich	Ziel
Benutzerdefinierte TCP-Regel	TCP	18888	SG-
HTTPS	TCP	443	0.0.0.0/0

Verwenden von Amazon EMR Block Public Access

Amazon EMR Block Public Access (BPA) verhindert, dass Sie einen Cluster in einem öffentlichen Subnetz starten, wenn der Cluster über eine Sicherheitskonfiguration verfügt, die eingehenden Datenverkehr von öffentlichen IP-Adressen an einem Port zulässt.

> **Important**
>
> Den öffentlichen Zugriff blockieren ist standardmäßig aktiviert. Um den Kontoschutz zu erhöhen, empfehlen wir, ihn aktiviert zu lassen.

Grundlegendes zum Blockieren des öffentlichen Zugriffs

Sie können die Konfiguration Block Public Access auf Kontoebene verwenden, um den öffentlichen Netzwerkzugriff auf Amazon-EMR-Cluster zentral zu verwalten.

Wenn ein Benutzer von Ihrem AWS-Konto einen Cluster startet, überprüft Amazon EMR die Portregeln in der Sicherheitsgruppe für den Cluster und vergleicht sie mit Ihren Regeln für eingehenden Datenverkehr. Wenn die Sicherheitsgruppe über eine Regel für eingehenden Datenverkehr verfügt, die Ports zu den öffentlichen IP-Adressen IPv4 0.0.0.0/0 oder IPv6: :/0 öffnet, und diese Ports nicht als Ausnahmen für Ihr Konto angegeben sind, lässt Amazon EMR den Benutzer den Cluster nicht erstellen.

Wenn ein Benutzer die Sicherheitsgruppenregeln für einen laufenden Cluster in einem öffentlichen Subnetz so ändert, dass er über eine Regel für den öffentlichen Zugriff verfügt, die gegen die BPA-Konfiguration für Ihr Konto verstößt, widerruft Amazon EMR die neue Regel, sofern es dazu berechtigt ist. Wenn Amazon EMR nicht berechtigt ist, die Regel zu widerrufen, wird im AWS Health-Dashboard ein Ereignis erstellt, das den Verstoß beschreibt. Informationen dazu, wie Sie Amazon EMR die Berechtigung zum Widerrufen der Regel erteilen, finden Sie unter Amazon EMR so konfigurieren, dass Sicherheitsgruppenregeln aufgehoben werden.

Den öffentlichen Zugriff blockieren ist standardmäßig für alle Cluster in jedem AWS-Region für Ihr AWS-Konto aktiviert. BPA gilt für den gesamten Lebenszyklus eines Clusters, gilt jedoch nicht für Cluster, die Sie in privaten Subnetzen erstellen. Sie können Ausnahmen von der BPA-Regel konfigurieren. Port 22 ist standardmäßig eine Ausnahme. Weitere Informationen zur Einstellung finden Sie unter Konfigurieren von Block Public Access.

Konfigurieren von Block Public Access

Sie können die Sicherheitsgruppen und die Konfiguration zum Sperren des öffentlichen Zugriffs in Ihren Konten jederzeit aktualisieren.

Sie können die Einstellungen für den Block Public Access (BPA) mit der AWS Management Console, der AWS Command Line Interface (AWS CLI) und der Amazon-EMR-API ein- und ausschalten. Die Einstellungen gelten für Ihr Konto je nach Region. Um die Clustersicherheit aufrechtzuerhalten, wird die Verwendung von BPA empfohlen.

New console

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

So konfigurieren Sie Block Public Access mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an dann öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie in der oberen Navigationsleiste die Region aus, die Sie konfigurieren möchten, sofern sie nicht bereits ausgewählt ist.
3. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Block Public Access aus.
4. Führen Sie unter Block public access settings (Einstellungen für die Sperrung des öffentlichen Zugriffs) die folgenden Schritte aus.

Aufgabe	Vorgehensweise
Block Public Access aktivieren oder deaktivieren	Wählen Sie Bearbeiten, wählen Sie je nach Bedarf Einschalten oder Ausschalten und wählen Sie dann Speichern.
Ports in der Liste der Ausnahmen bearbeiten	1. Wählen Sie Bearbeiten und suchen Sie den Abschnitt Ausnahmen für den Portbereich. 2. Um der Liste der Ausnahmen Ports hinzuzufügen, wählen Sie Add a port range (Port-Bereich hinzufügen) aus und geben Sie einen neuen Port oder Port-Bereich ein. Wiederholen Sie den

Aufgabe	Vorgehensweise
	Vorgang für jeden Port oder Port-Bereich, der hinzugefügt werden soll. 3. Um einen Port oder Portbereich zu entfernen, wählen Sie das Entfernen neben dem Eintrag in der Liste Portbereiche. 4. Wählen Sie Save (Speichern).

Old console

Zum Anzeigen, Konfigurieren und Blockieren von öffentlichem Zugriff mit der alten Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/emr.
2. Stellen Sie in der Navigationsleiste sicher, dass die Region, die Sie konfigurieren möchten, ausgewählt ist.
3. Wählen Sie Block public access (Öffentlichen Zugriff sperren) aus.
4. Führen Sie unter Block public access settings (Einstellungen für die Sperrung des öffentlichen Zugriffs) die folgenden Schritte aus.

Aufgabe	Vorgehensweise
Block Public Access aktivieren oder deaktivieren	Wählen Sie Change (Ändern), On (Ein) oder Off (Aus) und dann das Häkchen zur Bestätigung aus.
Ports in der Liste der Ausnahmen bearbeiten	1. Wählen Sie unter Exceptions (Ausnahmen), die Option Edit (Bearbeiten) aus. 2.

Aufgabe	Vorgehensweise
	Um der Liste der Ausnahmen Ports hinzuzufügen, wählen Sie Add a port range (Port-Bereich hinzufügen) aus und geben Sie einen neuen Port oder Port-Bereich ein. Wiederholen Sie den Vorgang für jeden Port oder Port-Bere ich, der hinzugefügt werden soll. 3. Um einen Port oder Port-Bereich zu entfernen, wählen Sie das x neben dem Eintrag in der Liste Port ranges (Bort-Ber eiche) aus. 4. Wählen Sie Save Changes.

AWS CLI

So konfigurieren Sie Block Public Access mithilfe der AWS CLI

- Verwenden Sie den `aws emr put-block-public-access-configuration`-Befehl, um Block Public Access zu konfigurieren, wie in den folgenden Beispielen gezeigt.

Aufgabe	Vorgehensweise
Block Public Access aktivieren	Legen Sie `BlockPublicSecurityGroupRules` wie im folgenden Beispiel gezeigt auf `true` fest. Damit der Cluster gestartet werden kann, darf keine Sicherheitsgruppe, die einem Cluster zugeordnet ist, über eine Regel für eingehenden Datenverkehr verfügen, die den öffentlichen Zugriff zulässt. `aws emr put-block-public-access-configuration --block-public-access-configuration BlockPublicSecurityGroupRules=true`
Block Public Access deaktivieren	Legen Sie `BlockPublicSecurityGroupRules` wie im folgenden Beispiel gezeigt auf `false` fest. Sicherheitsgruppen, die einem Cluster zugeordnet sind, können Regeln für eingehenden Datenverkehr aufweisen, die öffentlichen Zugriff auf beliebige Ports zulassen. Wir empfehlen diese Konfiguration nicht. `aws emr put-block-public-access-configuration --block-public-access-configuration BlockPublicSecurityGroupRules=false`

Aufgabe	Vorgehensweise
Block Public Access aktivieren und Ports als Ausnahmen angeben	Im folgenden Beispiel wird Block Public Access aktiviert und Port 22 sowie die Ports 100-101 werden als Ausnahmen angegeben. Auf diese Weise können Cluster erstellt werden, wenn eine zugeordnete Sicherheitsgruppe über eine Regel für eingehenden Datenverkehr verfügt, die öffentlichen Zugriff auf die Ports 22, 100 oder 101 zulässt. `aws emr put-block-public-access-configuration --block-public-access-configuration '{ "BlockPublicSecurityGroupRules": true, "PermittedPublicSecurityGroupRuleRanges": [ { "MinRange": 22, "MaxRange": 22 }, { "MinRange": 100, "MaxRange": 101 } ] }'`

Amazon EMR so konfigurieren, dass Sicherheitsgruppenregeln aufgehoben werden

Amazon EMR benötigt die Erlaubnis, Sicherheitsgruppenregeln zu widerrufen und Ihre Konfiguration für die Blockierung des öffentlichen Zugriffs einzuhalten. Sie können einen der folgenden Ansätze verwenden, um Amazon EMR die erforderliche Genehmigung zu erteilen:

- (Empfohlen) Fügen Sie der Servicerolle die `AmazonEMRServicePolicy_v2`-verwaltete Richtlinie hinzu. Weitere Informationen finden Sie unter Servicerolle für Amazon EMR (EMR-Rolle).
- Erstellen Sie eine neue Inline-Richtlinie, die die `ec2:RevokeSecurityGroupIngress`-Aktion für Sicherheitsgruppen ermöglicht. Weitere Informationen zum Ändern einer Rollenberechtigungsrichtlinie finden Sie unter Ändern einer Rollenberechtigungsrichtlinie mit der IAM-Konsole, der AWS-API und AWS CLI im IAM-Benutzerhandbuch.

Beheben von Verletzungen des Blockieren des öffentlichen Zugriffs

Wenn ein Verstoß gegen die Sperrung des öffentlichen Zugriffs auftritt, können Sie ihn mit einer der folgenden Maßnahmen beheben:

- Wenn Sie auf eine Webschnittstelle Ihres Clusters zugreifen möchten, verwenden Sie eine der unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen beschriebenen Optionen, um über SSH (Port 22) auf die Schnittstelle zuzugreifen.
- Um den Datenverkehr zum Cluster von bestimmten IP-Adressen statt von der öffentlichen IP-Adresse aus zuzulassen, fügen Sie eine Sicherheitsgruppenregel hinzu. Weitere Informationen finden Sie unter Hinzufügen von Regeln zur Sicherheitsgruppe im Amazon-EC2-Benutzerhandbuch.
- (Nicht empfohlen) Sie können Amazon-EMR-BPA-Ausnahmen so konfigurieren, dass sie den gewünschten Port oder Portbereich enthalten. Wenn Sie eine BPA-Ausnahme angeben, gehen Sie mit einem ungeschützten Port ein Risiko ein. Wenn Sie beabsichtigen, eine Ausnahme anzugeben, sollten Sie die Ausnahme entfernen, sobald sie nicht mehr benötigt wird. Weitere Informationen finden Sie unter Konfigurieren von Block Public Access.

Identifizieren Sie Cluster, die Sicherheitsgruppenregeln zugeordnet sind

Möglicherweise müssen Sie alle Cluster identifizieren, die einer bestimmten Sicherheitsgruppenregel zugeordnet sind, oder die Sicherheitsgruppenregel für einen bestimmten Cluster finden.

- Wenn Sie die Sicherheitsgruppe kennen, können Sie die zugehörigen Cluster identifizieren, wenn Sie die Netzwerkschnittstellen für die Sicherheitsgruppe finden. Weitere Informationen finden Sie unter Wie finde ich die Ressourcen, die einer Amazon-EC2-Sicherheitsgruppe zugeordnet sind? in AWS re:Post. Die Amazon EC2-Instances, die an diese Netzwerkschnittstellen angeschlossen sind, werden mit der ID des Clusters gekennzeichnet, zu dem sie gehören.
- Wenn Sie die Sicherheitsgruppen für einen bekannten Cluster suchen möchten, folgen Sie den Schritten unter Cluster-Status und -Details anzeigen. Sie finden die Sicherheitsgruppen für den Cluster im Bereich Netzwerk und Sicherheit in der Konsole oder im `Ec2InstanceAttributes`-Feld unter AWS CLI.

Compliance-Validierung für Amazon EMR

Externe Prüfer bewerten im Rahmen verschiedener AWS-Compliance-Programme die Sicherheit und Compliance von Amazon EMR. Hierzu zählen unter anderem SOC, PCI, FedRAMP und HIPAA.

Eine Liste der AWS-Services, die in den Geltungsbereich bestimmter Compliance-Programme fallen, finden Sie auf der Seite AWS-Services in Scope nach Compliance-Programm. Allgemeine Informationen finden Sie unter AWS-Compliance-Programme.

Die Auditberichte von Drittanbietern lassen sich mit herunterlade AWS Artifact. Weitere Informationen finden Sie unter Herunterladen von Berichten in AWS Artifact.

Ihre Compliance-Verantwortung bei Verwendung von Amazon EMR hängt von der Vertraulichkeit der Daten, den Compliance-Zielen des Unternehmens und den geltenden Gesetzen und Vorschriften ab. Wenn Ihre Nutzung von Amazon EMR Gegenstand der Compliance mit Standards wie HIPAA, PCI oder FedRAMP ist, stellt AWS Ressourcen zur Unterstützung bereit:

- Kurzanleitungen für Sicherheit und Compliance – In diesen Bereitstellungsleitfäden finden Sie wichtige Überlegungen zur Architektur sowie die einzelnen Schritte zur Bereitstellung von sicherheits- und Compliance-orientierten Basisumgebungen in AWS.
- Whitepaper zur Erstellung einer Architektur mit HIPAA-konformer Sicherheit und Compliance – In diesem Whitepaper wird beschrieben, wie Unternehmen mithilfe von AWS HIPAA-konforme Anwendungen erstellen können.
- AWS-Compliance-Ressourcen – Diese Arbeitsbücher und Leitfäden könnten für Ihre Branche und Ihren Standort interessant sein.
- AWS Config – Dieser AWS-Service bewertet, zu welchem Grad die Konfiguration Ihrer Ressourcen den internen Vorgehensweisen, Branchenrichtlinien und Vorschriften entspricht.
- AWS Security Hub – Dieser AWS-Service liefert einen umfassenden Überblick über den Sicherheitsstatus in AWS. So können Sie die Compliance mit den Sicherheitsstandards in der Branche und den bewährten Methoden abgleichen.

Ausfallsicherheit bei Amazon EMR

Im Zentrum der globalen AWS Infrastruktur stehen die AWS-Regionen und Availability Zones (Verfügbarkeitszonen, AZs). AWS Regionen stellen mehrere physisch getrennte und isolierte Availability Zones bereit, die mit Netzwerken mit geringer Latenz, hohem Durchsatz und

hochredundanten Vernetzungen verbunden sind. Mithilfe von Availability Zones können Sie Anwendungen und Datenbanken erstellen und ausführen, die automatisch Failover zwischen Availability Zones ausführen, ohne dass es zu Unterbrechungen kommt. Availability Zones sind besser hoch verfügbar, fehlertoleranter und skalierbarer als herkömmliche Infrastrukturen mit einem oder mehreren Rechenzentren.

Weitere Informationen über AWS-Regionen und -Availability Zones finden Sie unter Globale AWS-Infrastruktur.

Neben der globalen AWS-Infrastruktur stellt Amazon EMR verschiedene Features bereit, um Ihren Anforderungen an Ausfallsicherheit und Datensicherung gerecht zu werden.

- Integration in Amazon S3 über EMRFS
- Support für mehrere Master-Knoten

Infrastruktursicherheit in Amazon EMR

Als verwalteter Service ist Amazon EMR durch die globalen Verfahren zur Gewährleistung der Netzwerksicherheit von AWS geschützt, die im Whitepaper Amazon Web Services: Übersicht über die Sicherheitsprozesse beschrieben sind.

Sie greifen mithilfe von AWS veröffentlichten API-Aufrufe über das Netzwerk auf Amazon EMR zu. Clients müssen Transport Layer Security (TLS) 1.2 unterstützen. Clients müssen außerdem Verschlüsselungssammlungen mit PFS (Perfect Forward Secrecy) wie DHE (Ephemeral Diffie-Hellman) oder ECDHE (Elliptic Curve Ephemeral Diffie-Hellman) unterstützen. Die meisten modernen Systemen wie Java 7 und höher unterstützen diese Modi.

Außerdem müssen Anforderungen mit einer Zugriffsschlüssel-ID und einem geheimen Zugriffsschlüssel signiert sein, der einem IAM-Prinzipal zugeordnet ist. Alternativ können Sie mit AWS Security Token Service (AWS STS) temporäre Sicherheitsanmeldeinformationen erstellen, um die Anforderungen zu signieren.

Themen

- Herstellen einer Verbindung mit Amazon EMR über einen Schnittstellen-VPC-Endpunkt

Herstellen einer Verbindung mit Amazon EMR über einen Schnittstellen-VPC-Endpunkt

Sie können sich direkt mit Amazon EMR über einen Schnittstellen-VPC-Endpunkt (AWS PrivateLink) in Ihrer Virtual Private Cloud (VPC) verbinden, anstatt eine Verbindung über das Internet herzustellen. Wenn Sie einen Schnittstellen-VPC-Endpunkt verwenden, findet die Kommunikation zwischen Ihrer VPC und Amazon EMR vollständig innerhalb des AWS-Netzwerks statt. Jeder VPC-Endpunkt wird durch eine oder mehrere Elastic-Network-Schnittstellen (ENIs) mit privaten IP-Adressen in Ihren VPC-Subnetzen repräsentiert.

Der Schnittstellen-VPC-Endpunkt verbindet Ihre VPC direkt mit Amazon EMR, ohne ein Internet-Gateway, ein NAT-Gerät, eine VPN-Verbindung oder eine AWS Direct Connect-Verbindung. Die Instances in Ihrer VPC benötigen für die Kommunikation mit der API von Amazon EMR keine öffentlichen IP-Adressen.

Um Amazon EMR über Ihre VPC zu verwenden, müssen Sie für die Verbindung eine Instance innerhalb Ihrer VPC verwenden oder Ihr privates Netzwerk mit Ihrer VPC verbinden. Dies erreichen Sie mithilfe eines Amazon Virtual Private Network (VPN) oder mit AWS Direct Connect. Informationen zu Amazon VPN finden Sie unter VPN-Verbindungen im Benutzerhandbuch für Amazon Virtual Private Cloud. Informationen zu AWS Direct Connect finden Sie unter Erstellen einer Verbindung im AWS Direct Connect-Benutzerhandbuch.

Sie können über die AWS oder AWS Command Line Interface (AWS CLI)-Befehle einen Schnittstellen-VPC-Endpunkt erstellen, um eine Verbindung zu Amazon EMR herzustellen. Weitere Informationen finden Sie unter Erstellen eines Schnittstellenendpunkts.

Wenn Sie nach dem Erstellen eines Schnittstellen-VPC-Endpunkts private DNS-Host-Namen für den Endpunkt aktivieren, wird der Standardendpunkt von Amazon EMR in den VPC-Endpunkt aufgelöst. Der Service-Standardname für den Endpunkt für Amazon EMR hat das folgende Format.

```
elasticmapreduce.Region.amazonaws.com
```

Wenn Sie keine privaten DNS-Hostnamen aktiviert haben, stellt Amazon VPC einen DNS-Endpunktnamen bereit, den Sie im folgenden Format verwenden können.

```
VPC_Endpoint_ID.elasticmapreduce.Region.vpce.amazonaws.com
```

Weitere Informationen finden Sie unter Schnittstellen-VPC-Endpunkte (AWS-PrivateLink) im Amazon-VPC-Benutzerhandbuch.

Amazon EMR unterstützt Aufrufe aller API-Aktionen innerhalb Ihrer VPC.

Sie können VPC-Endpunktrichtlinien an einen VPC-Endpunkt anfügen, um den Zugriff für IAM-Prinzipale zu steuern. Sie können einem VPC-Endpunkt auch Sicherheitsgruppen zuordnen, um den eingehenden und ausgehenden Zugriff basierend auf Ursprung und Ziel des Netzwerkdatenverkehrs zu steuern, z. B. mit einem IP-Adressbereich. Weitere Informationen finden Sie unter Steuern des Zugriffs auf Services mit VPC-Endpunkten.

Eine VPC-Endpunktrichtlinie für Amazon EMR erstellen

Sie können eine Richtlinie für Amazon-VPC-Endpunkte für Amazon EMR erstellen, in der Sie Folgendes angeben:

- Prinzipal, der Aktionen ausführen/nicht ausführen kann
- Aktionen, die ausgeführt werden können
- Ressourcen, für die Aktionen ausgeführt werden können

Weitere Informationen finden Sie unter Steuerung des Zugriffs auf Services mit VPC-Endpunkten im Amazon-VPC-Benutzerhandbuch.

Example – VPC-Endpunktrichtlinie zum Verweigern des Zugriffs mit einem angegebenen AWS-Konto

Die folgende VPC-Endpunktrichtlinie verweigert dem AWS-Konto *123456789012* jeglichen Zugriff auf Ressourcen, die den Endpunkt verwenden.

```
{
    "Statement": [
        {
            "Action": "*",
            "Effect": "Allow",
            "Resource": "*",
            "Principal": "*"
        },
        {
            "Action": "*",
            "Effect": "Deny",
            "Resource": "*",
            "Principal": {
                "AWS": [
                    "123456789012"
                ]
```

```
            }
        }
    ]
}
```

Example – VPC-Endpunktrichtlinie zum Gewähren des VPC-Zugriffs auf einen angegebenen IAM-Prinzipal (Benutzer)

Die folgende VPC-Endpunktrichtlinie gewährt nur dem Benutzer *lijuan* im AWS-Konto *123456789012* vollen Zugriff. Allen anderen IAM-Prinzipalen wird der Zugriff über den Endpunkt verweigert.

```
{
    "Statement": [
        {
            "Action": "*",
            "Effect": "Allow",
            "Resource": "*",
            "Principal": {
                "AWS": [
                    "arn:aws:iam::123456789012:user/lijuan"
                ]
            }
        }]
}
```

Example – VPC-Endpunktrichtlinie zum Erlauben von EMR-Leseoperationen

Die folgende VPC-Endpunktrichtlinie erlaubt nur dem AWS-Konto *123456789012*, die angegebenen Aktionen für Amazon EMR auszuführen.

Die angegebenen Aktionen stellen das Äquivalent von schreibgeschütztem Zugriff für Amazon EMR dar. Alle anderen Aktionen in der VPC werden dem angegebenen Konto verweigert. Allen anderen Konten wird der Zugriff verweigert. Eine Liste der Aktionen in Amazon EMR finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für Amazon EMR.

```
{
    "Statement": [
        {
            "Action": [
                "elasticmapreduce:DescribeSecurityConfiguration",
```

```
                "elasticmapreduce:GetBlockPublicAccessConfiguration",
                "elasticmapreduce:ListBootstrapActions",
                "elasticmapreduce:ViewEventsFromAllClustersInConsole",
                "elasticmapreduce:ListSteps",
                "elasticmapreduce:ListInstanceFleets",
                "elasticmapreduce:DescribeCluster",
                "elasticmapreduce:ListInstanceGroups",
                "elasticmapreduce:DescribeStep",
                "elasticmapreduce:ListInstances",
                "elasticmapreduce:ListSecurityConfigurations",
                "elasticmapreduce:DescribeEditor",
                "elasticmapreduce:ListClusters",
                "elasticmapreduce:ListEditors"
            ],
            "Effect": "Allow",
            "Resource": "*",
            "Principal": {
                "AWS": [
                    "123456789012"
                ]
            }
        }
    ]
}
```

Example – VPC-Endpunktrichtlinie, die den Zugriff auf einen angegebenen Cluster verweigert

Die folgende VPC-Endpunktrichtlinie gewährt vollen Zugriff für alle Konten und Prinzipale, verweigert jedoch jeglichen Zugriff des AWS-Kontos *123456789012* auf Aktionen, die im Amazon-EMR-Cluster mit der Cluster-ID *j-A1B2CD34EF5G* ausgeführt werden. Andere Amazon-EMR-Aktionen, die keine Berechtigungen auf Ressourcenebene für Cluster unterstützen, sind weiterhin zulässig. Eine Liste der Amazon EMR-Aktionen und die entsprechenden Ressourcentypen finden Sie unter Aktionen, Ressourcen und Bedingungsschlüssel für .Amazon EMR.

```
{
    "Statement": [
        {
            "Action": "*",
            "Effect": "Allow",
            "Resource": "*",
            "Principal": "*"
        },
        {
```

```
            "Action": "*",
            "Effect": "Deny",
            "Resource": "arn:aws:elasticmapreduce:us-west-2:123456789012:cluster/j-
A1B2CD34EF5G",
            "Principal": {
                "AWS": [
                    "123456789012"
                ]
            }
        }
    ]
}
```

Verwalten von Clustern

Nach dem Starten Ihres Clusters können Sie ihn überwachen und verwalten. Amazon EMR bietet mehrere Tools, die Sie verwenden können, um eine Verbindung mit Ihrem Cluster herzustellen und diesen zu kontrollieren.

Themen

- Verbinden mit einem Cluster
- Übermitteln von Arbeit an einen Cluster
- Einen Cluster anzeigen und überwachen
- Clusterskalierung verwenden
- Einen Cluster beenden
- Klonen eines Clusters mithilfe der Konsole
- Automatisieren wiederkehrender Cluster mit AWS Data Pipeline

Verbinden mit einem Cluster

Wenn Sie einen Amazon-EMR-Cluster ausführen, müssen Sie häufig nur eine Anwendung ausführen, um die Daten zu analysieren, und dann die Ausgabe aus dem Amazon-S3-Bucket erfassen. In anderen Fällen möchten Sie vielleicht mit dem Primärknoten interagieren, während der Cluster ausgeführt wird. Sie möchten z. B. eine Verbindung mit dem Primärknoten herstellen, um interaktive Abfragen auszuführen, Protokolldateien zu prüfen, ein Problem mit dem Cluster zu debuggen, Leistung mithilfe einer Anwendung wie Ganglia zu überwachen, die im Primärknoten ausgeführt wird, und so weiter. In den folgenden Abschnitten werden Techniken beschrieben, mit denen Sie eine Verbindung mit dem Primärknoten herstellen können.

In einem EMR-Cluster ist der Primärknoten eine Amazon-EC2-Instance. Diese koordiniert die EC2-Instances, die als Aufgaben- und Core-Knoten ausgeführt werden. Der Primärknoten stellt einen öffentlichen DNS-Namen bereit, den Sie verwenden können, um eine Verbindung mit der Instance herzustellen. Amazon EMR erstellt standardmäßig die Sicherheitsgruppenregeln für Primär-, Core- und Slave-Knoten, die bestimmen, wie Sie auf die Knoten zugreifen.

> **Note**
>
> Eine Verbindung mit dem Primärknoten ist nur möglich, während der Cluster ausgeführt wird. Wenn der Cluster beendet wird, wird die EC2-Instance beendet, die als Primärknoten fungiert, und ist nicht länger verfügbar. Um eine Verbindung mit dem Primärknoten einzurichten, müssen Sie sich auch beim Cluster authentifizieren. Sie können entweder Kerberos für die Authentifizierung verwenden, oder einen privaten Schlüssel eines Amazon-EC2-Schlüsselpaars angeben, wenn Sie den Cluster starten. Weitere Informationen zur Konfiguration von Kerberos und die Einrichtung einer Verbindung finden Sie unter Verwenden Sie Kerberos für die Authentifizierung mit Amazon EMR. Wenn Sie einen Cluster über die Konsole starten, wird der private Schlüssel des Amazon-EC2-Schlüsselpaares im Abschnitt Security and Access auf der Seite Create Cluster angegeben.

Standardmäßig erlaubt die Sicherheitsgruppe "ElasticMapReduce-master" keinen eingehenden SSH-Zugriff. Möglicherweise müssen Sie eine Regel hinzufügen, die eingehenden SSH-Zugriff (TCP-Port 22) von bestimmten Quellen erlaubt. Weitere Informationen zum Ändern von Sicherheitsgruppenregeln finden Sie unter Hinzufügen von Regeln zu einer Sicherheitsgruppe im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

> **Important**
>
> Ändern Sie nicht die verbleibenden Regeln in der Sicherheitsgruppe "ElasticMapReduce-master". Das Ändern dieser Regeln kann die Ausführung des Clusters beeinträchtigen.

Themen

- Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs
- Mit dem Primärknoten über SSH verbinden

Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs

Bevor Sie eine Verbindung zu einem Amazon-EMR-Cluster herstellen, müssen Sie eingehenden SSH-Verkehr (Port 22) von vertrauenswürdigen Clients autorisieren, z. B. die IP-Adresse Ihres Computers. Bearbeiten Sie dazu die verwalteten Sicherheitsgruppenregeln für die Knoten, zu denen

Sie eine Verbindung herstellen möchten. Die folgenden Anweisungen zeigen Ihnen beispielsweise, wie Sie der standardmäßigen ElasticMapReduce-Master-Sicherheitsgruppe eine eingehende Regel für den SSH-Zugriff hinzufügen.

Weitere Informationen zur Verwendung von Sicherheitsgruppen mit Amazon EMR finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

New console

Um vertrauenswürdigen Quellen SSH-Zugriff auf die primäre Sicherheitsgruppe mit der neuen Konsole zu gewähren

Um Ihre Sicherheitsgruppen zu bearbeiten, benötigen Sie die Berechtigung, Sicherheitsgruppen für die VPC zu verwalten, in der sich der Cluster befindet. Weitere Informationen finden Sie im IAM-Benutzerhandbuch unter Ändern von Benutzerberechtigungen und unter Beispielrichtlinie, die die Verwaltung von EC2-Sicherheitsgruppen ermöglicht.

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten. Dadurch wird die Cluster-Detailseite geöffnet. Die Registerkarte Eigenschaften auf dieser Seite sollte vorausgewählt sein.
3. Wählen Sie auf der Registerkarte Eigenschaften unter Netzwerk den Pfeil neben EC2-Sicherheitsgruppen (Firewall) aus, um diesen Abschnitt zu erweitern. Wählen Sie unter Primärknoten den Link zur Sicherheitsgruppe aus. Daraufhin wird die EC2-Konsole geöffnet.
4. Wählen Sie die Registerkarte Eingehende Regeln und anschließend Eingehende Regeln bearbeiten aus.
5. Suchen Sie mit den folgenden Einstellungen nach einer Regel für eingehenden Datenverkehr, die öffentlichen Zugriff ermöglicht. Falls sie existiert, wählen Sie Löschen, um sie zu entfernen.

   - Typ

     SSH
   - Port

     22
   - Source (Quelle)

Benutzerdefiniert 0.0.0.0/0

> **Warning**
>
> Vor Dezember 2020 verfügte die ElasticMapReduce-Master-Sicherheitsgruppe über eine vorkonfigurierte Regel, die eingehenden Datenverkehr auf Port 22 aus allen Quellen zuließ. Diese Regel wurde erstellt, um die ersten SSH-Verbindungen zum Primärknoten zu vereinfachen. Wir empfehlen Ihnen dringend, diese Eingangsregel zu entfernen und den Datenverkehr auf vertrauenswürdige Quellen zu beschränken.

6. Scrollen Sie zum Ende der Regelliste und wählen Sie Regel hinzufügen.
7. Wählen Sie für Type (Typ) SSH aus. Bei dieser Auswahl werden automatisch TCP als Protokoll und 22 als Portbereich eingetragen.
8. Wählen Sie als Quelle Meine IP aus, um Ihre IP-Adresse automatisch als Quelladresse hinzuzufügen. Sie können auch einen Bereich benutzerdefinierter vertrauenswürdiger Client-IP-Adressen hinzufügen oder zusätzliche Regeln für andere Clients erstellen. In vielen Netzwerkumgebungen werden IP-Adressen dynamisch zugewiesen, sodass Sie in Zukunft möglicherweise Ihre IP-Adressen für vertrauenswürdige Clients aktualisieren müssen.
9. Wählen Sie Save (Speichern).
10. Kehren Sie optional zu Schritt 3 zurück, wählen Sie Core- und Aufgabenknoten aus, und wiederholen Sie die Schritte 4 bis 8. Dadurch wird den Core- und Aufgabenknoten SSH-Clientzugriff gewährt.

Old console

Wie Sie vertrauenswürdigen Quellen SSH-Zugriff auf die primäre Sicherheitsgruppe mit der alten Konsole gewähren

Um Ihre Sicherheitsgruppen zu bearbeiten, benötigen Sie die Berechtigung, Sicherheitsgruppen für die VPC zu verwalten, in der sich der Cluster befindet. Weitere Informationen finden Sie im IAM-Benutzerhandbuch unter Ändern von Benutzerberechtigungen und unter Beispielrichtlinie, die die Verwaltung von EC2-Sicherheitsgruppen ermöglicht.

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.

2. Wählen Sie Clusters (Cluster) aus. Wählen Sie den Namen des Clusters, den Sie ändern möchten.
3. Wählen Sie unter Sicherheit und Zugriff den Link Sicherheitsgruppen für Master.
4. Wählen Sie aus der Liste ElasticMapReduce-master.
5. Wählen Sie die Registerkarte Eingehende Regeln und anschließend Eingehende Regeln bearbeiten aus.
6. Suchen Sie mit den folgenden Einstellungen nach einer Regel für eingehenden Datenverkehr, die öffentlichen Zugriff ermöglicht. Falls sie existiert, wählen Sie Löschen, um sie zu entfernen.

   - Typ

     SSH
   - Port

     22
   - Source (Quelle)

     Benutzerdefiniert 0.0.0.0/0

   > **Warning**
   >
   > Vor Dezember 2020 verfügte die ElasticMapReduce-Master-Sicherheitsgruppe über eine vorkonfigurierte Regel, die eingehenden Datenverkehr auf Port 22 aus allen Quellen zuließ. Diese Regel wurde erstellt, um die ersten SSH-Verbindungen zum Primärknoten zu vereinfachen. Wir empfehlen Ihnen dringend, diese Eingangsregel zu entfernen und den Datenverkehr auf vertrauenswürdige Quellen zu beschränken.

7. Scrollen Sie zum Ende der Regelliste und wählen Sie Regel hinzufügen.
8. Wählen Sie für Type (Typ) SSH aus.

   Wenn Sie SSH auswählen, wird automatisch TCP für Protokoll und 22 für Portbereich eingegeben.
9. Wählen Sie als Quelle Meine IP aus, um Ihre IP-Adresse automatisch als Quelladresse hinzuzufügen. Sie können auch einen Bereich benutzerdefinierter vertrauenswürdiger Client-IP-Adressen hinzufügen oder zusätzliche Regeln für andere Clients erstellen. In vielen

Netzwerkumgebungen werden IP-Adressen dynamisch zugewiesen, sodass Sie in Zukunft möglicherweise Ihre IP-Adressen für vertrauenswürdige Clients aktualisieren müssen.

10. Wählen Sie Save (Speichern).
11. Wählen Sie optional ElasticMapReduce-slave aus der Liste aus und wiederholen Sie die obigen Schritte, um dem SSH-Client Zugriff auf Core- und Aufgabenknoten zu ermöglichen.Clients zuzulassen.

Mit dem Primärknoten über SSH verbinden

Secure Shell (SSH) ist ein Netzwerkprotokoll, mit dem Sie eine sichere Verbindung mit einem Remote-Computer erstellen können. Nach dem Verbinden verhält sich das Terminal auf Ihrem lokalen Computer so, als würde es auf dem Remote-Computer ausgeführt. Lokal erstellte Befehle werden auf dem Remote-Computer ausgeführt und die Befehlsausgabe vom Remote-Computer wird im Terminal-Fenster angezeigt.

Wenn Sie SSH mit AWS verwenden, stellen Sie eine Verbindung mit einer EC2-Instance her, die ein in der Cloud ausgeführter virtueller Server ist. Beim Arbeiten mit Amazon EMR wird SSH am häufigsten verwendet, um eine Verbindung mit der EC2-Instance herzustellen, die als Primärknoten des Clusters dient.

Wenn Sie SSH zum Herstellen einer Verbindung mit dem Primärknoten verwenden, können Sie den Cluster überwachen und mit ihm interagieren. Sie können Linux-Befehle auf dem Primärknoten absetzen, Anwendungen wie Hive und Pig interaktiv ausführen, Verzeichnisse durchsuchen, Protokolldateien lesen usw. Darüber hinaus können Sie einen Tunnel in Ihrer SSH-Verbindung erstellen, um die auf dem Primärknoten gehosteten Webschnittstellen anzeigen zu lassen. Weitere Informationen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Um eine Verbindung mit dem Primärknoten unter Verwendung von SSH herzustellen, müssen Sie den öffentlichen DNS-Namen des Primärknotens verwenden. Darüber hinaus muss die dem Primärknoten zugeordnete Sicherheitsgruppe über eine Regel für eingehenden Datenverkehr verfügen, die SSH (TCP-Port 22)-Datenverkehr von einer Quelle zulässt, an der die SSH-Verbindung ihren Ursprung hat. Möglicherweise müssen Sie eine Regel hinzufügen, um eine SSH-Verbindung von Ihrem Client zuzulassen. Weitere Informationen zum Ändern von Sicherheitsgruppenregeln finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen und Hinzufügen von Regeln zu einer Sicherheitsgruppe im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Abrufen des öffentlichen DNS-Namens für den Primärknoten

Sie können den primären öffentlichen DNS-Namen über die Amazon EMR-Konsole und die AWS CLI abrufen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So rufen Sie den öffentlichen DNS-Namen für den Primärknoten mit der neuen Konsole ab

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, von dem Sie den öffentlichen DNS-Namen abrufen möchten.
3. Beachten Sie den öffentlichen DNS-Wert des Primärknotens im Abschnitt Zusammenfassung der Cluster-Detailseite.

Old console

So rufen Sie den öffentlichen DNS-Namen für den Primärknoten mit der alten Konsole ab

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie auf der Seite Cluster List (Cluster-Liste) den Link für Ihren Cluster aus.
3. Beachten Sie den öffentlichen Master-DNS-Wert, der im Abschnitt Zusammenfassung der Seite Clusterdetails angezeigt wird.

> **Note**
>
> Sie können auch den SSH-Link neben dem öffentlichen DNS-Namen für Anweisungen zum Erstellen einer SSH-Verbindung mit dem Primärknoten verwenden.

CLI

So rufen Sie den öffentlichen DNS-Namen für den Primärknoten mit der AWS CLI ab

1. Geben Sie den folgenden Befehl ein, um die Cluster-Kennung abzurufen:

```
aws emr list-clusters
```

Die Ausgabe enthält Ihre Cluster einschließlich Cluster-IDs. Notieren Sie die Cluster-ID für den Cluster, mit dem Sie eine Verbindung herstellen.

```
"Status": {
    "Timeline": {
        "ReadyDateTime": 1408040782.374,
        "CreationDateTime": 1408040501.213
    },
    "State": "WAITING",
    "StateChangeReason": {
        "Message": "Waiting after step completed"
    }
},
"NormalizedInstanceHours": 4,
"Id": "j-2AL4XXXXXX5T9",
"Name": "My cluster"
```

2. Geben Sie einen der folgenden Befehle ein, um die Cluster-Instances mitsamt dem öffentlichen DNS-Namen für den Cluster aufzulisten. Ersetzen Sie *j-2AL4XXXXXX5T9* durch die Cluster-ID, die vom vorherigen Befehl zurückgegeben wurde.

```
aws emr list-instances --cluster-id j-2AL4XXXXXX5T9
```

Oder:

```
aws emr describe-cluster --cluster-id j-2AL4XXXXXX5T9
```

Die Ausgabe enthält die Cluster-Instances einschließlich DNS-Namen und IP-Adressen. Notieren Sie den Wert für `PublicDnsName`.

```
"Status": {
    "Timeline": {
        "ReadyDateTime": 1408040779.263,
        "CreationDateTime": 1408040515.535
    },
    "State": "RUNNING",
    "StateChangeReason": {}
},
"Ec2InstanceId": "i-e89b45e7",
"PublicDnsName": "ec2-###-##-##-###.us-west-2.compute.amazonaws.com"

"PrivateDnsName": "ip-###-##-##-###.us-west-2.compute.internal",
"PublicIpAddress": "##.###.###.##",
"Id": "ci-12XXXXXXXXFMH",
"PrivateIpAddress": "###.##.#.###"
```

Weitere Informationen finden Sie unter Amazon-EMR-Befehle in der AWS CLI.

Verbinden mit dem Primärknoten unter Verwendung von SSH und eines privaten Amazon-EC2-Schlüssels unter Linux, Unix und Mac OS X

Um eine SSH-Verbindung einzurichten, die mit einem privaten Schlüssel authentifiziert ist, müssen Sie den privaten Schlüssel des Amazon-EC2-Schlüsselpaars angeben, wenn Sie einen Cluster starten. Weitere Informationen zum Zugriff auf Ihr Schlüsselpaar finden Sie unter Amazon-EC2-Schlüsselpaare im Benutzerhandbuch von Amazon EC2 für Linux-Instances.

Ihr Linux-Computer verfügt höchstwahrscheinlich standardmäßig über einen SSH-Client. OpenSSH wird beispielsweise bei den meisten Linux-, Unix- und MacOS-Betriebssystemen installiert. Sie können nach einem SSH-Client suchen, indem Sie in der Befehlszeile ssh eingeben. Wenn Ihr Computer den Befehl nicht erkennt, installieren Sie einen SSH-Client, um eine Verbindung mit dem Primärknoten herzustellen. Das OpenSSH-Projekt bietet eine kostenlose Implementierung der umfassenden Palette von SSH-Tools. Weitere Informationen finden Sie auf der OpenSSH-Website.

In den folgenden Anleitungen wird gezeigt, wie Sie eine SSH-Verbindung mit dem Amazon-EMR-Primärknoten unter Linux, Unix und Mac OS X öffnen.

So konfigurieren Sie Berechtigungen für die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares

Bevor Sie mit dem privaten Schlüssel Ihres Amazon-EC2-Schlüsselpaares eine SSH-Verbindung erstellen können, müssen Sie die Berechtigungen für die `.pem`-Datei so festlegen, dass nur der Besitzer berechtigt ist, auf die Datei zuzugreifen. Dies ist für das Erstellen einer SSH-Verbindung mithilfe des Terminals oder der AWS CLI erforderlich.

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Suchen Sie Ihre `.pem`-Datei. In dieser Anleitung wird davon ausgegangen, dass die Datei `mykeypair.pem` heißt und im Stammverzeichnis des aktuellen Benutzers gespeichert ist.
3. Geben Sie den folgenden Befehl ein, um die Berechtigungen festzulegen. Ersetzen Sie *~/mykeypair.pem* durch den vollständigen Pfad und Namen der Datei mit dem privaten Schlüssel Ihres Schlüsselpaares. Zum Beispiel `C:/Users/<username>/.ssh/mykeypair.pem`.

   ```
   chmod 400 ~/mykeypair.pem
   ```

   Wenn Sie keine Berechtigungen für die `.pem`-Datei festlegen, erhalten Sie die Fehlermeldung, dass Ihre Schlüsseldatei nicht geschützt ist und der Schlüssel abgelehnt wird. Zum Verbinden müssen Sie die Berechtigungen für die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares nur bei der ersten Verwendung festlegen.

So stellen Sie eine Verbindung mit dem Primärknoten mithilfe des Terminals her

1. Öffnen Sie ein Terminal-Fenster. Wählen Sie unter Mac OS X Applications > Utilities > Terminal (Anwendungen > Dienstprogramme > Terminal) aus. In anderen Linux-Distributionen befindet sich „Terminal“ in der Regel unter Applications > Accessories > Terminal (Anwendungen > Zubehör > Terminal).
2. Geben Sie den folgenden Befehl ein, um eine Verbindung mit dem Primärknoten herzustellen. Ersetzen Sie *ec2-###-##-##-###.compute-1.* durch den öffentlichen DNS-Namen für den Primärknoten Ihres Clusters und *~/mykeypair.pem* durch den Speicherort und den Namen Ihrer `.pem`-Datei. Zum Beispiel `C:/Users/<username>/.ssh/mykeypair.pem`.

```
ssh hadoop@ec2-###-##-##-###.compute-1.amazonaws.com -i ~/mykeypair.pem
```

> **Important**
>
> Sie müssen den Anmeldenamen `hadoop` verwenden, wenn Sie eine Verbindung mit dem Amazon-EMR-Primärknoten herstellen. Andernfalls wird eine Fehlermeldung ähnlich wie `Server refused our key` angezeigt.

3. Es wird die Warnung angezeigt, dass die Authentizität des Hosts, mit dem Sie eine Verbindung herstellen, nicht überprüft werden konnte. Geben Sie `yes` ein, um fortzufahren.
4. Wenn Sie Ihre Arbeit am Primärknoten abgeschlossen haben, geben Sie den folgenden Befehl ein, um die SSH-Verbindung zu schließen.

```
exit
```

Wenn Sie Probleme bei der Verwendung von SSH haben, um eine Verbindung zu Ihrem Primärknoten herzustellen, finden Sie weitere Informationen unter Problembehandlung bei der Verbindung mit Ihrer Instance.

Verbinden mit dem Primärknoten mithilfe von SSH unter Windows

Windows-Benutzer können eine Verbindung mit dem Primärknoten mithilfe eines SSH-Clients wie z. B. PuTTY herstellen. Bevor Sie eine Verbindung mit dem Amazon-EMR-Primärknoten herstellen, sollten Sie PuTTY und &puttygen; herunterladen und installieren. Sie können diese Tools auf der PuTTY-Download-Seite herunterladen.

PuTTY unterstützt nicht das von Amazon EC2 generierte Dateiformat für den privaten Schlüssel des Schlüsselpaares (`.pem`). Konvertieren Sie mithilfe von PuTTYgen Ihre Schlüsseldatei in das erforderliche PuTTY-Format (`.ppk`). Sie müssen Ihren Schlüssel in dieses Format (`.ppk`) konvertieren, bevor Sie mithilfe von PuTTY eine Verbindung mit dem Primärknoten herstellen können.

Weitere Informationen finden Sie unter Konvertieren Ihres privaten Schlüssels mit PuTTYgen im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

So stellen Sie eine Verbindung mit dem Primärknoten mithilfe von PuTTY her

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Öffnen Sie `putty.exe`. Sie können PuTTY auch über die Windows-Programmliste starten.
3. Falls erforderlich, wählen Sie in der Category (Kategorie)-Liste Session (Sitzung) aus.
4. Geben Sie in das Feld Host Name (or IP address) (Host-Name (oder IP-Adresse)) die Zeichenfolge `hadoop@`*`MasterPublicDNS`* ein. Beispiel: `hadoop@`*`ec2-###-##-##-###.compute-1.amazonaws.com`*.
5. Wählen Sie in der Category (Kategorie)-Liste Connection > SSH (Verbindung > SSH), Auth aus.
6. Klicken Sie bei Private key file for authentication (Private Schlüsseldatei für Authentifizierung) auf Browse (Durchsuchen), und wählen Sie die `.ppk`-Datei aus, die Sie generiert haben.
7. Wählen Sie Öffnen und dann Ja aus, um die PuTTY-Sicherheitswarnung zu schließen.

   > **Important**
   >
   > Wenn Sie sich beim Primärknoten anmelden und zur Angabe eines Benutzernamens aufgefordert werden, geben Sie `hadoop` ein.

8. Wenn Sie Ihre Arbeit am Primärknoten beendet haben, können Sie durch Schließen von PuTTY die SSH-Verbindung schließen.

   > **Note**
   >
   > Um zu verhindern, dass die SSH-Verbindung das Zeitlimit überschreitet, können Sie Connection (Verbindung) in der Category (Kategorie)-Liste und anschließend die Option Enable TCP_keepalives (TCP_keepalives aktivieren) auswählen. Wenn eine SSH-Sitzung in PuTTY aktiv ist, können Sie die Einstellungen ändern, indem Sie das Kontextmenü (rechte Maustaste) für die PuTTY-Titelleiste öffnen und dann Einstellungen ändern auswählen.

Wenn Sie Probleme bei der Verwendung von SSH haben, um eine Verbindung zu Ihrem Primärknoten herzustellen, finden Sie weitere Informationen unter Problembehandlung bei der Verbindung mit Ihrer Instance.

Mit dem Primärknoten über die AWS CLI verbinden

Sie können eine SSH-Verbindung mit dem Primärknoten mithilfe der AWS CLI unter Windows, Linux, Unix und Mac OS X herstellen. Unabhängig von der Plattform benötigen Sie den öffentlichen DNS-Namen des Primärknotens und den privaten Schlüssel Ihres Amazon-EC2-Schlüsselpaares. Wenn Sie die AWS CLI unter Linux, Unix oder Mac OS X verwenden, müssen Sie außerdem Berechtigungen für die `.pem`- oder `.ppk`-Datei für den privaten Schlüssel wie in So konfigurieren Sie Berechtigungen für die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares gezeigt festlegen.

So stellen Sie eine Verbindung mit dem Primärknoten über die AWS CLI her

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Geben Sie Folgendes ein, um die Cluster-Kennung abzurufen:

   ```
   aws emr list-clusters
   ```

   Die Ausgabe enthält Ihre Cluster einschließlich Cluster-IDs. Notieren Sie die Cluster-ID für den Cluster, mit dem Sie eine Verbindung herstellen.

   ```
   "Status": {
       "Timeline": {
           "ReadyDateTime": 1408040782.374,
           "CreationDateTime": 1408040501.213
       },
       "State": "WAITING",
       "StateChangeReason": {
           "Message": "Waiting after step completed"
       }
   },
   "NormalizedInstanceHours": 4,
   "Id": "j-2AL4XXXXXX5T9",
   "Name": "AWS CLI cluster"
   ```

3. Geben Sie den folgenden Befehl ein, um eine SSH-Verbindung mit dem Primärknoten zu öffnen. Ersetzen Sie im folgenden Beispiel *j-2AL4XXXXXX5T9* durch die Cluster-ID sowie *~/mykeypair.key* durch den vollständigen Pfad und Namen Ihrer `.pem`-Datei (für Linux, Unix und Mac OS X) oder `.ppk`-Datei (für Windows). Zum Beispiel `C:\Users\<username>\.ssh\mykeypair.pem`.

```
aws emr ssh --cluster-id j-2AL4XXXXXX5T9 --key-pair-file ~/mykeypair.key
```

4. Wenn Sie die Arbeit am Primärknoten beendet haben, schließen Sie das AWS CLI-Fenster.

   Weitere Informationen finden Sie unter Amazon-EMR-Befehle in der AWS CLI. Wenn Sie Probleme bei der Verwendung von SSH haben, um eine Verbindung zu Ihrem Primärknoten herzustellen, finden Sie weitere Informationen unter Problembehandlung bei der Verbindung mit Ihrer Instance.

Amazon-EMR-Serviceports

> **Note**
>
> Im Folgenden finden Sie Schnittstellen und Serviceports für Komponenten auf Amazon EMR. Dies ist keine vollständige Liste der Serviceports. Nicht standardmäßige Services, wie SSL-Ports und verschiedene Arten von Protokollen, sind nicht aufgeführt.

> **Important**
>
> Seien Sie vorsichtig, wenn Sie Regeln für offene Ports für Sicherheitsgruppen bearbeiten. Stellen Sie sicher, dass Sie Regeln hinzufügen, die nur Datenverkehr von vertrauenswürdigen und authentifizierten Clients für die Protokolle und Ports zulassen, die zum Ausführen Ihrer Workloads erforderlich sind.

Komponente	Service description (Service-Beschreibung)	Der Service wird standardmäßig ausgeführt	Port	Schlüssel zur Konfiguration
Hadoop	HTTP-KMS-REST-API	Ja	9 600	hadoop.kms.http.port
HDFS	Namenode-Web-Benutzeroberfläche	Ja	9 870	dfs.namenode.http-address

Komponente	Service description (Service-Beschreibung)	Der Service wird standardmäßig ausgeführt	Port	Schlüssel zur Konfiguration
	Nameknode-RPC	Ja	8 020	dfs.namenode.rpc-address
	DataNode-Web-Benutzeroberfläche	Ja	9 864	dfs.datanode.http.address
	Datanode-HTTP für die Datenübertragung	Ja	9 866	dfs.datanode.address
	Datanode-RPC für die Datenübertragung	Ja	9 867	dfs.datanode.ipc.address
Hive	HiveServer2 Thrift	Ja	10000	hive.server2.thrift.port
	HiveServer2 HTTP	Nein	10001	hive.server2.thrift.http.port
	HiveServer2 Web UI	Ja	10002	hive.server2.webui.port
	Hive Metastore	Ja	9 083	hive.metastore.port / metastore.thrift.port
	WebHCat	Nein	50 111	templeton.port
	LLAP-Daemon-Verwaltungsservice (RPC)	Nein	15 004	hive.llap.management.rpc.port

Komponente	Service description (Service-Beschreibung)	Der Service wird standardmäßig ausgeführt	Port	Schlüssel zur Konfiguration
	YARN-Shuffle-Port für LLAP-Daemon-gehostetes Shuffle	Nein	15 551	hive.llap.daemon.yarn.shuffle.port
	Der LLAP-Daemon (RPC)	Nein	Dynamisch	hive.llap.daemon.rpc.port
	Webbenutzeroberfläche des LLAP-Daemons	Nein	15 002	hive.llap.daemon.web.port
	LLAP-Daemon-Ausgabeservice	Nein	15 003	hive.llap.daemon.output.service.port
Oozie		Ja	11 000	
Tez	Tez UI	Ja	8080	
YARN	Shuffle	Ja	13 562	mapreduce.shuffle.port
	Lokalisierer-RPC	Ja	8 040	yarn.nodemanager.localizer.address
		Ja	8 041	
	NM-Webapp-Adresse	Ja	8 042	yarn.nodemanager.webapp.address

Komponente	Service description (Service-Beschreibung)	Der Service wird standardmäßig ausgeführt	Port	Schlüssel zur Konfiguration
	RM-Webanwendung	Ja	8 088	yarn.resourcemanager.webapp.address
		Ja	8 025	
	Scheduler	Ja	8 030	yarn.resourcemanager.scheduler.address
	Schnittstelle für den Anwendungsmanager	Ja	8 032	yarn.resourcemanager.address
	RM-Admin-Oberfläche	Ja	8 033	yarn.resourcemanager.admin.address
	JobHistory-Server-Web-Benutzeroberfläche	Ja	19 888	mapreduce.jobhistory.webapp.address
	Web-Benutzeroberfläche für JobHistory-Server-Admin	Ja	10 033	mapreduce.jobhistory.admin.adresse
	JobHistory-Server (RPC)	Ja	10 020	mapreduce.jobhistory.address

Komponente	Service description (Service-Beschreibung)	Der Service wird standardmäßig ausgeführt	Port	Schlüssel zur Konfiguration
	Anwendungs-Timeline-Server (RPC)	Ja	10 200	garn.timeline-service.adresse
	HTTP-Webbenutzeroberfläche für Anwendungszeitserver	Ja	8 188	garn.timeline-service.webapp.adresse
	HTTPS-Webbenutzeroberfläche für Anwendungszeitserver	Nein	8190	yarn.timeline-service.webapp.https.address
		Ja	20 888	
Zookeeper	Client-Port	Ja	2 181	
		Ja	37 301	
		Ja	8 341	

Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen

Important

Sie können eine benutzerdefinierte Sicherheitsgruppe konfigurieren, um den eingehenden Zugriff auf diese Webschnittstellen zu ermöglichen. Beachten Sie, dass jeder Port, an dem Sie eingehenden Datenverkehr zulassen, eine potenzielle Sicherheitslücke darstellt. Überprüfen Sie sorgfältig die benutzerdefinierten Sicherheitsgruppen, um Schwachstellen zu minimieren. Weitere Informationen finden Sie unter Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Hadoop und andere Anwendungen, die Sie auf Ihrem -Cluster installieren, veröffentlichen Benutzeroberflächen als auf dem Primärknoten gehostete Websites. Aus Sicherheitsgründen stehen diese Websites bei der Verwendung von Amazon EMR verwalteten Sicherheitsgruppen nur auf dem lokalen Webserver des Primärknotens zur Verfügung. Daher müssen Sie eine Verbindung mit dem Primärknoten herstellen, um sie anzuzeigen. Aus diesem Grund müssen Sie eine Verbindung zum Primärknoten herstellen, um die Weboberflächen anzeigen zu können. Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden. Hadoop veröffentlicht Benutzeroberflächen auch als Websites, die auf Core- und Aufgabenknoten gehostet werden. Diese Websites sind ebenfalls nur auf dem lokalen Webserver auf dem Knoten verfügbar.

Die folgende Tabelle enthält die Webschnittstellen, die Sie auf Cluster-Instances anzeigen lassen können: Diese Hadoop-Schnittstellen sind in allen Clustern verfügbar. Für die Master-Instance-Schnittstellen, ersetzen Sie *master-public-dns-name* durch den Öffentlicher Master-DNS auf der Registerkarte Übersicht des Clusters in der Amazon-EMR-Konsole. Für Core- und Task-Instance-Schnittstellen, ersetzen Sie *coretask-public-dns-name* durch den für die Instance aufgeführten Public DNS name (Öffentlicher DNS-Name). Um den Öffentlicher DNS-Name einer instance zu finden, wählen Sie in der Amazon-EMR-Konsole Ihren Cluster aus der Liste, wählen Sie die Registerkarte Hardware, wählen Sie die ID der Instance-Gruppe, die die Instance enthält, zu der Sie eine Verbindung herstellen möchten, und notieren Sie sich dann den für die Instance angegebenen Öffentlicher DNS-Name.

Name der Schnittstelle	URI
Flink History Server (EMR-Version 5.33 und höher)	http://*master-public-dns-name* :8082/
Ganglia	http://*master-public-dns-name* /ganglia/
Hadoop HDFS NameNode (EMR-Version vor 6.x)	https://*master-public-dns-name* :50470/
Hadoop HDFS NameNode	http://*master-public-dns-name* :50070/
Hadoop HDFS DataNode	http://*coretask-public-dns-name* :50075/
Hadoop HDFS NameNode (EMR Version 6.x)	https://*master-public-dns-name* :9870/

Name der Schnittstelle	URI
Hadoop HDFS DataNode (EMR-Version vor 6.x)	https://*coretask-public-dns-name* :50475/
Hadoop HDFS-DataNode (EMR-Version 6.x)	https://*coretask-public-dns-name* :9865/
HBase	http://*master-public-dns-name* :16010/
Hue	http://*master-public-dns-name* :8888/
JupyterHub	https://*master-public-dns-name* :9443/
Livy	http://*master-public-dns-name* :8998/
Spark HistoryServer	http://*master-public-dns-name* :18080/
Tez	http: //*master-public-dns-name:8080/tez-ui*
YARN NodeManager	http://*coretask-public-dns-name* :8042/
YARN ResourceManager	http://*master-public-dns-name* :8088/
Zeppelin	http://*master-public-dns-name* :8890/

Da mehrere anwendungsspezifische Schnittstellen für den Primärknoten, aber nicht für den Core- und Aufgabenknoten verfügbar sind, gelten die Anweisungen in diesem Dokument speziell für den Amazon-EMR-Primärknoten. Auf die Webschnittstellen im Core- und Aufgabenknoten kann auf die gleiche Weise zugegriffen werden wie auf die Webschnittstellen im Primärknoten.

Es gibt mehrere Möglichkeiten, auf die Webschnittstellen im Primärknoten zuzugreifen. Am einfachsten und schnellsten stellen Sie eine Verbindung mit dem Primärknoten mithilfe von SSH her und verwenden den Browser Lynx zum Betrachten der Websites in Ihrem SSH-Client. Lynx ist jedoch ein textbasierter Browser mit einer eingeschränkten Benutzeroberfläche, die keine Grafiken anzeigen kann. Das folgende Beispiel zeigt, wie Sie die Hadoop ResourceManager-Schnittstelle mithilfe von Lynx öffnen (Lynx-URLs werden auch beim Anmelden am Primärknoten über SSH bereitgestellt).

```
lynx http://ip-###-##-##-###.us-west-2.compute.internal:8088/
```

Es gibt zwei verbleibende Optionen für den Zugriff auf Webschnittstellen im Primärknoten, die vollständige Browserfunktionalität bieten. Wählen Sie eine der folgenden Optionen aus:

- Option 1 (empfohlen für technisch fortgeschrittene Benutzer): Stellen Sie eine Verbindung mit dem Primärknoten mithilfe eines SSH-Clients her, konfigurieren Sie SSH-Tunneling mit lokaler Port-Weiterleitung und verwenden Sie einen Internetbrowser, um auf dem Primärknoten gehostete Webschnittstellen zu öffnen. Durch diese Methode können Sie den Zugriff auf Webschnittstellen so konfigurieren, dass kein SOCKS-Proxy benötigt wird.
- Option 2 (empfohlen für neue Benutzer): Stellen Sie eine Verbindung mit dem Primärknoten mithilfe eines SSH-Clients her, konfigurieren Sie SSH-Tunneling mit dynamischer Port-Weiterleitung und konfigurieren Sie den Internetbrowser so, dass zum Verwalten Ihrer SOCKS-Proxy-Einstellungen ein Add-On wie FoxyProxy oder SwitchySharp verwendet wird. Mit dieser Methode können Sie URLs basierend auf Textmuster automatisch filtern und die Proxy-Einstellungen auf die Domains beschränken, die mit dem Format des DNS-Namens für den Primärknoten übereinstimmen. Weitere Informationen zum Konfigurieren von FoxyProxy für Firefox und Google Chrome finden Sie unter Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen.

> **Note**
>
> Wenn Sie den Port, auf dem eine Anwendung ausgeführt wird, über die Cluster-Konfiguration ändern, wird der Hyperlink zum Port in der Amazon-EMR-Konsole nicht aktualisiert. Das liegt daran, dass die Konsole nicht über die Funktionalität verfügt, die Konfiguration `server.port` zu lesen.

Mit Amazon EMR Version 5.25.0 oder höher können Sie über die Konsole auf die Benutzeroberfläche des Spark History Servers zugreifen, ohne einen Web-Proxy über eine SSH-Verbindung einzurichten. Weitere Informationen finden Sie unter Zugriff auf den persistenten Spark History Server mit nur einem Klick.

Themen

- Option 1: Einen SSH-Tunnel zum Primärknoten mithilfe der lokalen Port-Weiterleitung einrichten

- Option 2, Teil 1: Einen SSH-Tunnel zum Primärknoten mithilfe der dynamischen Port-Weiterleitung einrichten
- Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen

Option 1: Einen SSH-Tunnel zum Primärknoten mithilfe der lokalen Port-Weiterleitung einrichten

Stellen Sie eine Verbindung mit dem lokalen Webserver im Primärknoten her, indem Sie einen SSH-Tunnel zwischen Ihrem Computer und dem Primärknoten erstellen. Dies wird auch als Port-Weiterleitung bezeichnet. Wenn Sie keinen SOCKS-Proxy verwenden möchten, können Sie einen SSH-Tunnel zum Primärknoten mithilfe der lokalen Port-Weiterleitung einrichten. Bei der lokalen Port-Weiterleitung geben Sie ungenutzte lokale Ports an, die zum Weiterleiten von Datenverkehr zu bestimmten Remote-Ports auf dem lokalen Webserver des Primärknotens verwendet werden.

Zum Einrichten eines SSH-Tunnels mithilfe der lokalen Port-Weiterleitung benötigen Sie den öffentlichen DNS-Namen des Primärknotens und die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares. Weitere Informationen darüber, wie Sie den öffentlichen DNS-Namen für den Master abrufen, finden Sie unter So rufen Sie den öffentlichen DNS-Namen für den Primärknoten mit der alten Konsole ab. Weitere Informationen zum Zugriff auf Ihr Schlüsselpaar finden Sie unter Amazon-EC2-Schlüsselpaare im Benutzerhandbuch von Amazon EC2 für Linux-Instances. Weitere Informationen zu den Websites, die Sie sich auf dem Primärknoten ansehen können, finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Einen SSH-Tunnel zum Primärknoten mithilfe der lokalen Port-Weiterleitung unter Windows einrichten

So richten Sie einen SSH-Tunnel mithilfe der lokalen Port-Weiterleitung im Terminal ein

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Öffnen Sie ein Terminal-Fenster. Wählen Sie unter Mac OS X Applications > Utilities > Terminal (Anwendungen > Dienstprogramme > Terminal) aus. In anderen Linux-Distributionen befindet sich „Terminal“ in der Regel unter Applications > Accessories > Terminal (Anwendungen > Zubehör > Terminal).
3. Dieser Befehl greift auf die ResourceManager-Webschnittstelle zu, indem Datenverkehr am lokalen Port 8 157 (einem zufällig ausgewählten, ungenutzten lokalen Port) zum Port 8 088 auf dem lokalen Webserver des Hauptknotens weitergeleitet wird.

Ersetzen Sie im Befehl *~/mykeypair.pem* durch den Speicherort und den Dateinamen Ihrer `.pem`-Datei und ersetzen Sie *ec2-###-##-##-###.compute-1.amazonaws.com* durch den öffentlichen Master-DNS-Namen Ihres Clusters. Um auf eine andere Weboberfläche zuzugreifen, ersetzen Sie `8088` durch die entsprechende Portnummer. Ersetzen Sie beispielsweise für die Zeppelin-Schnittstelle `8088` durch `8890`.

```
ssh -i ~/mykeypair.pem -N -L 8157:ec2-###-##-##-
###.compute-1.amazonaws.com:8088 hadoop@ec2-###-##-##-###.compute-1.amazonaws.com
```

`-L` bezeichnet die Verwendung der lokalen Port-Weiterleitung. Damit können Sie einen lokalen Port für die Weiterleitung von Datenverkehr zu einem bestimmten Remote-Port auf dem lokalen Webserver des Hauptknotens angeben.

Nachdem Sie diesen Befehl ausgeführt haben, bleibt das Terminal geöffnet und gibt keine Antwort zurück.

4. Geben Sie in die Adressleiste `http://localhost:8157/` ein, um die ResourceManager-Webschnittstelle in Ihrem Browser zu öffnen.
5. Wenn Sie die Arbeit mit den Webschnittstellen im Primärknoten beendet haben, schließen Sie die Terminal-Fenster.

Option 2, Teil 1: Einen SSH-Tunnel zum Primärknoten mithilfe der dynamischen Port-Weiterleitung einrichten

Stellen Sie eine Verbindung mit dem lokalen Webserver im Primärknoten her, indem Sie einen SSH-Tunnel zwischen Ihrem Computer und dem Primärknoten erstellen. Dies wird auch als Port-Weiterleitung bezeichnet. Wenn Sie Ihren SSH-Tunnel mithilfe der dynamischen Port-Weiterleitung erstellen, wird der gesamte, an einen bestimmten ungenutzten lokalen Port geleitete Datenverkehr an den lokalen Web-Server des Primärknotens weitergeleitet. Dies erstellt einen SOCKS-Proxy. Anschließend können Sie Ihren Internetbrowser so konfigurieren, dass zum Verwalten Ihrer SOCKS-Proxy-Einstellungen ein Add-On wie FoxyProxy oder SwitchyOmega verwendet wird.

Mit einem Add-On zur Proxy-Verwaltung können Sie URLs basierend auf Textmuster automatisch filtern und die Proxy-Einstellungen auf die Domains beschränken, die mit dem Format des öffentlichen DNS-Namens für den Primärknoten übereinstimmen. Das Browser-Add-On aktiviert und deaktiviert den Proxy automatisch, wenn Sie zwischen den auf dem Primärknoten gehosteten Websites und solchen im Internet wechseln.

Bevor Sie beginnen, benötigen Sie den öffentlichen DNS-Namen des Primärknotens und die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares. Informationen darüber, wie Sie den primären öffentlichen DNS-Namen finden, erhalten Sie unter So rufen Sie den öffentlichen DNS-Namen für den Primärknoten mit der alten Konsole ab. Weitere Informationen zum Zugriff auf Ihr Schlüsselpaar finden Sie unter Amazon-EC2-Schlüsselpaare im Benutzerhandbuch von Amazon EC2 für Linux-Instances. Weitere Informationen zu den Websites, die Sie sich auf dem Primärknoten ansehen können, finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Richten Sie mithilfe der dynamischen Portweiterleitung mit OpenSSH einen SSH-Tunnel zum Primärknoten ein

So richten Sie einen SSH-Tunnel mithilfe der dynamischen Portweiterleitung mit OpenSSH ein

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Öffnen Sie ein Terminal-Fenster. Wählen Sie unter Mac OS X Applications > Utilities > Terminal (Anwendungen > Dienstprogramme > Terminal) aus. In anderen Linux-Distributionen befindet sich „Terminal“ in der Regel unter Applications > Accessories > Terminal (Anwendungen > Zubehör > Terminal).
3. Geben Sie den folgenden Befehl ein, um einen SSH-Tunnel auf Ihrem lokalen Computer zu öffnen. Ersetzen Sie *~/mykeypair.pem* durch den Speicherort und Namen Ihrer `.pem`-Datei, die Portnummer *8157* durch eine ungenutzte lokale Portnummer sowie *c2-###-##-##-###.compute-1.amazonaws.com* durch den primären öffentlichen DNS-Namen Ihres Clusters.

   ```
   ssh -i ~/mykeypair.pem -N -D 8157 hadoop@ec2-###-##-##-###.compute-1.amazonaws.com
   ```

   Nachdem Sie diesen Befehl ausgeführt haben, bleibt das Terminal geöffnet und gibt keine Antwort zurück.

   > **Note**
   >
   > `-D` bezeichnet die Verwendung der dynamischen Port-Weiterleitung. Damit können Sie einen lokalen Port für die Weiterleitung von Datenverkehr zu allen Remote-Ports auf dem lokalen Webserver des Primärknotens angeben. Die dynamische Port-Weiterleitung erstellt einen lokalen SOCKS-Proxy, der den im Befehl angegebenen Port überwacht.

4. Wenn der Tunnel aktiv ist, konfigurieren Sie einen SOCKS-Proxy für Ihren Browser. Weitere Informationen finden Sie unter Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen.
5. Wenn Sie die Arbeit mit den Webschnittstellen im Primärknoten beendet haben, schließen Sie das Terminal-Fenster.

Einrichten eines SSH-Tunnels mithilfe der dynamischen Port-Weiterleitung mit der AWS CLI

Sie können eine SSH-Verbindung mit dem Primärknoten mithilfe der AWS CLI unter Windows, Linux, Unix und Mac OS X erstellen. Wenn Sie die AWS CLI unter Linux, Unix oder Mac OS X verwenden, müssen Sie Berechtigungen für die `.pem`-Datei, wie in So konfigurieren Sie Berechtigungen für die Datei mit dem privaten Schlüssel Ihres Schlüsselpaares gezeigt, festlegen. Wenn Sie die AWS CLI unter Windows verwenden, muss PuTTY in der Pfad-Umgebungsvariablen angezeigt werden. Andernfalls erhalten Sie möglicherweise eine Fehlermeldung wie beispielsweise, OpenSSH oder PuTTY nicht verfügbar.

So richten Sie einen SSH-Tunnel mithilfe der dynamischen Port-Weiterleitung mit der AWS CLI ein

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Erstellen Sie eine SSH-Verbindung mit dem Primärknoten wie unter Mit dem Primärknoten über die AWS CLI verbinden gezeigt.
3. Geben Sie Folgendes ein, um die Cluster-Kennung abzurufen:

   ```
   aws emr list-clusters
   ```

   Die Ausgabe enthält Ihre Cluster einschließlich Cluster-IDs. Notieren Sie die Cluster-ID für den Cluster, mit dem Sie eine Verbindung herstellen.

   ```
   "Status": {
       "Timeline": {
           "ReadyDateTime": 1408040782.374,
           "CreationDateTime": 1408040501.213
       },
       "State": "WAITING",
       "StateChangeReason": {
           "Message": "Waiting after step completed"
   ```

```
    }
},
"NormalizedInstanceHours": 4,
"Id": "j-2AL4XXXXXX5T9",
"Name": "AWS CLI cluster"
```

4. Geben Sie den folgenden Befehl ein, um einen SSH-Tunnel zum Primärknoten mithilfe der dynamischen Port-Weiterleitung zu öffnen. Ersetzen Sie im folgenden Beispiel *j-2AL4XXXXXX5T9* durch die Cluster-ID sowie *~/mykeypair.key* durch den Speicherort und Namen Ihrer `.pem`-Datei (für Linux, Unix und Mac OS X) oder `.ppk`-Datei (für Windows).

   ```
   aws emr socks --cluster-id j-2AL4XXXXXX5T9 --key-pair-file ~/mykeypair.key
   ```

   > **Note**
   >
   > Mit dem Socks-Befehl wird die dynamische Port-Weiterleitung am lokalen Port 8157 automatisch konfiguriert. Derzeit kann diese Einstellung nicht geändert werden.

5. Wenn der Tunnel aktiv ist, konfigurieren Sie einen SOCKS-Proxy für Ihren Browser. Weitere Informationen finden Sie unter Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen.
6. Wenn Sie die Arbeit mit den Webschnittstellen im Primärknoten beendet haben, schließen Sie das AWS CLI-Fenster.

   Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Mit PuTTY einen SSH-Tunnel zum Primärknoten einrichten

Windows-Benutzer können einen SSH-Tunnel zum Primärknoten mithilfe eines SSH-Clients wie z. B. PuTTY erstellen. Bevor Sie eine Verbindung mit dem Amazon-EMR-Primärknoten herstellen, sollten Sie PuTTY und &puttygen; herunterladen und installieren. Sie können diese Tools auf der PuTTY-Download-Seite herunterladen.

PuTTY unterstützt nicht das von Amazon EC2 generierte Dateiformat für den privaten Schlüssel des Schlüsselpaares (`.pem`). Konvertieren Sie mithilfe von PuTTYgen Ihre Schlüsseldatei in das erforderliche PuTTY-Format (`.ppk`). Sie müssen Ihren Schlüssel in dieses Format (`.ppk`) konvertieren, bevor Sie mithilfe von PuTTY eine Verbindung mit dem Primärknoten herstellen können.

Weitere Informationen finden Sie unter Konvertieren Ihres privaten Schlüssels mit PuTTYgen im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

So richten Sie einen SSH-Tunnel mit dynamischer Portweiterleitung mithilfe von PuTTY ein

1. Stellen Sie sicher, dass Sie eingehenden SSH-Verkehr zugelassen haben. Detaillierte Anweisungen finden Sie unter Bevor Sie eine Verbindung herstellen: Autorisieren des eingehenden Datenverkehrs.
2. Doppelklicken Sie auf `putty.exe`, um PuTTY zu starten. Sie können PuTTY auch über die Windows-Programmliste starten.

   > **Note**
   >
   > Wenn bereits eine aktive SSH-Sitzung mit dem Primärknoten vorhanden ist, können Sie einen Tunnel hinzufügen. Klicken Sie hierfür mit der rechten Maustaste auf die PuTTY-Titelleiste und wählen Sie Einstellungen ändern aus.

3. Falls erforderlich, wählen Sie in der Category (Kategorie)-Liste Session (Sitzung) aus.
4. Geben Sie im Feld Host Name (Host-Name) **hadoop@***MasterPublicDNS* ein. Beispiel: **hadoop@***ec2-###-##-##-###.compute-1.amazonaws.com*.
5. Erweitern Sie in der Liste Category (Kategorie) die Option Connection > SSH (Verbindung > SSH), und wählen Sie anschließend Auth aus.
6. Klicken Sie bei Private key file for authentication (Private Schlüsseldatei für Authentifizierung) auf Browse (Durchsuchen), und wählen Sie die `.ppk`-Datei aus, die Sie generiert haben.

   > **Note**
   >
   > PuTTY unterstützt nicht das von Amazon EC2 generierte Dateiformat für den privaten Schlüssel des Schlüsselpaares (`.pem`). Konvertieren Sie mithilfe von PuTTYgen Ihre Schlüsseldatei in das erforderliche PuTTY-Format (`.ppk`). Sie müssen Ihren Schlüssel in dieses Format (`.ppk`) konvertieren, bevor Sie mithilfe von PuTTY eine Verbindung mit dem Primärknoten herstellen können.

7. Erweitern Sie in der Liste Category (Kategorie) die Option Connection > SSH (Verbindung (SSH)), und wählen Sie anschließend Tunnels (Tunnel) aus.
8. Geben Sie im Feld Quellport `8157` (einen nicht verwendeten lokalen Port) ein und wählen Sie dann Hinzufügen aus.

9. Lassen Sie das Feld Destination (Zieladresse) leer.
10. Wählen Sie die Optionen Dynamic (Dynamisch) und Auto.
11. Klicken Sie auf Open.
12. Wählen Sie Yes (Ja) aus, um die PuTTY-Sicherheitswarnung zu schließen.

> **Important**
>
> Wenn Sie sich beim Primärknoten anmelden, geben Sie `hadoop` ein, wenn Sie zur Angabe eines Benutzernamens aufgefordert werden.

13. Wenn der Tunnel aktiv ist, konfigurieren Sie einen SOCKS-Proxy für Ihren Browser. Weitere Informationen finden Sie unter Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen.
14. Wenn Sie die Arbeit mit den Webschnittstellen im Primärknoten beendet haben, schließen Sie das PuTTY-Fenster.

Option 2, Teil 2: Proxy-Einstellungen konfigurieren, um auf dem Primärknoten gehostete Websites anzeigen zu lassen

Wenn Sie einen SSH-Tunnel mit dynamischer Port-Weiterleitung verwenden, müssen Sie ein Add-On für die SOCKS-Proxy-Verwaltung einsetzen, um die Proxy-Einstellungen in Ihrem Browser zu steuern. Mit einem Tool zur SOCKS-Proxy-Verwaltung können Sie URLs basierend auf Textmuster automatisch filtern und die Proxy-Einstellungen auf die Domains beschränken, die mit dem Format des öffentlichen DNS-Namens für den Primärknoten übereinstimmen. Das Browser-Add-On aktiviert und deaktiviert den Proxy automatisch, wenn Sie zwischen den auf dem Primärknoten gehosteten Websites und solchen im Internet wechseln. Konfigurieren Sie Ihren Internetbrowser so, dass zum Verwalten Ihrer Proxy-Einstellungen ein Add-On wie FoxyProxy oder SwitchyOmega verwendet wird.

Weitere Informationen zum Erstellen eines SSH-Tunnels finden Sie unter Option 2, Teil 1: Einen SSH-Tunnel zum Primärknoten mithilfe der dynamischen Port-Weiterleitung einrichten. Weitere Informationen zu den verfügbaren Webschnittstellen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Geben Sie bei der Einrichtung Ihres Proxy-Add-ons die folgenden Einstellungen an:

- Verwenden Sie localhost als Hostadresse.

- Verwenden Sie dieselbe lokale Portnummer, die Sie für die Einrichtung des SSH-Tunnels mit dem Primärknoten ausgewählt haben. Option 2, Teil 1: Einen SSH-Tunnel zum Primärknoten mithilfe der dynamischen Port-Weiterleitung einrichten Zum Beispiel Port *8157*. Dieser Port muss zudem mit der Port-Nummer in PuTTY oder anderen Terminal-Emulatoren übereinstimmen, die Sie zum Verbinden nutzen.
- Geben Sie das SOCKS-v5-Protokoll an. Mit SOCKS v5 können Sie optional die Benutzerautorisierung einrichten.
- URL Patterns (URL-Muster)

  Die folgenden URL-Muster sollten in die Zulassungsliste aufgenommen und mit einem Platzhaltermustertyp angegeben werden:

  - Die Muster *ec2*.*compute*.amazonaws.com* und *10*.amazonaws.com* stimmen mit den öffentlichen DNS-Namen von Clustern in US-Regionen überein.
  - Die Muster *ec2*.compute* und *10*.compute* stimmen mit den öffentlichen DNS-Namen von Clustern in allen anderen Regionen überein.
  - Das Muster 10.* bietet Zugriff auf die JobTracker-Protokolldateien in Hadoop. Ändern Sie diesen Filter bei Konflikten mit Ihrem Netzwerkzugriffsplan.
  - Die Muster *.ec2.internal* und *.compute.internal* müssen den privaten (internen) DNS-Namen der Cluster in der `us-east-1`-Region bzw. allen anderen Regionen entsprechen.

Beispiel: FoxyProxy für Firefox konfigurieren

Das folgende Beispiel zeigt eine FoxyProxy Standard-Konfiguration (Version 7.5.1) für Mozilla Firefox.

FoxyProxy bietet eine Reihe von Proxy-Management-Tools. Damit können Sie einen Proxy-Server für URLs verwenden, die Mustern entsprechen, die den Domains entsprechen, die von den Amazon-EC2-Instances in Ihrem Amazon-EMR-Cluster verwendet werden.

So installieren und konfigurieren Sie FoxyProxy mit Mozilla Firefox

1. Gehen Sie in Firefox zu https://addons.mozilla.org/, suchen Sie nach FoxyProxy Standard und folgen Sie den Anweisungen, um FoxyProxy zu Firefox hinzuzufügen.
2. Erstellen Sie mit einem Texteditor eine JSON-Datei mit dem Namen `foxyproxy-settings.json` aus der folgenden Beispielkonfiguration.

```
{
```

```
  "k20d21508277536715": {
    "active": true,
    "address": "localhost",
    "port": 8157,
    "username": "",
    "password": "",
    "type": 3,
    "proxyDNS": true,
    "title": "emr-socks-proxy",
    "color": "#0055E5",
    "index": 9007199254740991,
    "whitePatterns": [
      {
        "title": "*ec2*.*compute*.amazonaws.com*",
        "active": true,
        "pattern": "*ec2*.*compute*.amazonaws.com*",
        "importedPattern": "*ec2*.*compute*.amazonaws.com*",
        "type": 1,
        "protocols": 1
      },
      {
        "title": "*ec2*.compute*",
        "active": true,
        "pattern": "*ec2*.compute*",
        "importedPattern": "*ec2*.compute*",
        "type": 1,
        "protocols": 1
      },
      {
        "title": "10.*",
        "active": true,
        "pattern": "10.*",
        "importedPattern": "http://10.*",
        "type": 1,
        "protocols": 2
      },
      {
        "title": "*10*.amazonaws.com*",
        "active": true,
        "pattern": "*10*.amazonaws.com*",
        "importedPattern": "*10*.amazonaws.com*",
        "type": 1,
        "protocols": 1
      },
```

```
      {
        "title": "*10*.compute*",
        "active": true,
        "pattern": "*10*.compute*",
        "importedPattern": "*10*.compute*",
        "type": 1,
        "protocols": 1
      },
      {
        "title": "*.compute.internal*",
        "active": true,
        "pattern": "*.compute.internal*",
        "importedPattern": "*.compute.internal*",
        "type": 1,
        "protocols": 1
      },
      {
        "title": "*.ec2.internal* ",
        "active": true,
        "pattern": "*.ec2.internal*",
        "importedPattern": "*.ec2.internal*",
        "type": 1,
        "protocols": 1
      }
    ],
    "blackPatterns": []
  },
  "logging": {
    "size": 100,
    "active": false
  },
  "mode": "patterns",
  "browserVersion": "68.12.0",
  "foxyProxyVersion": "7.5.1",
  "foxyProxyEdition": "standard"
}
```

3. Öffnen Sie die Firefox-Seite Ihre Erweiterungen verwalten (gehen Sie zu about:addons und wählen Sie dann Erweiterungen).
4. Wählen Sie FoxyProxy Standard und dann die Schaltfläche „Weitere Optionen“ (die Schaltfläche, die wie eine Ellipse aussieht).
5. Wählen Sie Optionen aus der Dropdown-Liste aus.

6. Wählen Sie im linken Menü die Option Einstellungen importieren.
7. Wählen Sie auf der Seite Einstellungen importieren unter Einstellungen aus FoxyProxy 6.0+ importieren die Option Einstellungen importieren, suchen Sie den Speicherort der von Ihnen erstellten `foxyproxy-settings.json`-Datei, wählen Sie die Datei aus und wählen Sie Öffnen.
8. Wählen Sie OK, wenn Sie aufgefordert werden, die vorhandenen Einstellungen zu überschreiben und Ihre neue Konfiguration zu speichern.

Beispiel: SwitchyOmega für Chrome konfigurieren

Das folgende Beispiel zeigt, wie die SwitchyOmega-Erweiterung für Google Chrome eingerichtet wird. Mit SwitchyOmega können Sie mehrere Proxys konfigurieren, verwalten und zwischen ihnen wechseln.

So installieren und konfigurieren Sie SwitchyOmega mithilfe von Google Chrome

1. Gehen Sie zu https://chrome.google.com/webstore/category/extensions, suchen Sie nach Proxy SwitchyOmega und fügen Sie ihn zu Chrome hinzu.
2. Wählen Sie Neues Profil und geben Sie `emr-socks-proxy` als Profilnamen ein.
3. Wählen Sie PAC-Profil und dann Erstellen. Mithilfe von PAC-Dateien (Proxy Auto Configuration) können Sie eine Zulassungsliste für Browseranfragen definieren, die an einen Web-Proxyserver weitergeleitet werden sollen.
4. Ersetzen Sie im Feld PAC-Skript den Inhalt durch das folgende Skript, das definiert, welche URLs über Ihren Web-Proxyserver weitergeleitet werden sollen. Wenn Sie bei der Einrichtung Ihres SSH-Tunnels eine andere Portnummer angegeben haben, ersetzen Sie *8157* durch Ihre Portnummer.

```
function FindProxyForURL(url, host) {
    if (shExpMatch(url, "*ec2*.*compute*.amazonaws.com*")) return 'SOCKS5
 localhost:8157';
    if (shExpMatch(url, "*ec2*.compute*")) return 'SOCKS5 localhost:8157';
    if (shExpMatch(url, "http://10.*")) return 'SOCKS5 localhost:8157';
    if (shExpMatch(url, "*10*.compute*")) return 'SOCKS5 localhost:8157';
    if (shExpMatch(url, "*10*.amazonaws.com*")) return 'SOCKS5 localhost:8157';
    if (shExpMatch(url, "*.compute.internal*")) return 'SOCKS5 localhost:8157';
    if (shExpMatch(url, "*ec2.internal*")) return 'SOCKS5 localhost:8157';
    return 'DIRECT';
}
```

5. Wählen Sie unter Aktionen die Option Änderungen übernehmen aus, um Ihre Proxyeinstellungen zu speichern.
6. Wählen Sie in der Chrome-Symbolleiste SwitchyOmega und wählen Sie das `emr-socks-proxy`-Profil aus.

Im Browser auf eine Weboberfläche zugreifen

Um eine Weboberfläche zu öffnen, geben Sie den öffentlichen DNS-Namen Ihres Primär- oder Core-Knotens gefolgt von der Portnummer für die von Ihnen gewählte Schnittstelle in die Adressleiste Ihres Browsers ein. Das folgende Beispiel zeigt die URL, die Sie eingeben würden, um eine Verbindung zum Spark HistoryServer herzustellen.

```
http://master-public-dns-name:18080/
```

Anweisungen zum Abrufen des öffentlichen DNS-Namens eines Knotens finden Sie unter Abrufen des öffentlichen DNS-Namens für den Primärknoten. Eine vollständige Liste der Webinterface-URLs finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

Übermitteln von Arbeit an einen Cluster

In diesem Abschnitt werden die Methoden beschrieben, mit denen Sie Arbeiten an einen Amazon-EMR-Cluster einreichen können. Um Arbeit einzureichen, können Sie Schritte hinzufügen oder interaktiv Hadoop-Jobs an den Primärknoten senden.

Beachten Sie beim Einreichen von Schritten an einen Cluster die folgenden Verhaltensregeln:

- Eine Schritt-ID kann bis zu 256 Zeichen enthalten.
- Sie können bis zu 256 PENDING- und RUNNING-Schritte in einem Cluster haben.
- Sie können Aufträge interaktiv an den Primärknoten übermitteln, auch dann, wenn auf dem Cluster 256 aktive Schritte ausgeführt werden. Sie können unbegrenzt viele Schritte während der Nutzungsdauer eines langlebigen Clusters übermitteln, es können aber nur 256 Schritte zu einem bestimmten Zeitpunkt den Status RUNNING oder PENDING haben.
- Mit Amazon-EMR-Versionen 4.8.0 und höher, außer Version 5.0.0, können Sie ausstehende Schritte abbrechen. Weitere Informationen finden Sie unter Abbrechen von Schritten.
- Mit Amazon-EMR-Version 5.28.0 und höher können Sie sowohl ausstehende als auch ausgeführte Schritte abbrechen. Sie können auch mehrere Schritte parallel ausführen, um die

Clusterauslastung zu verbessern und Kosten zu sparen. Weitere Informationen finden Sie unter Überlegungen zum parallelen Ausführen mehrerer Schritte.

> **Note**
>
> Für eine optimale Leistung empfehlen wir, benutzerdefinierte Bootstrap-Aktionen, -Skripts und andere Dateien, die Sie mit Amazon EMR verwenden möchten, in einem Amazon-S3-Bucket zu speichern, der sich in derselben AWS-Region wie Ihr Cluster befindet.

Themen

- Hinzufügen von Schritten zu einem Cluster mit der Verwaltungskonsole für Amazon EMR
- Hinzufügen von Schritten zu einem Cluster mit AWS CLI
- Überlegungen zum parallelen Ausführen mehrerer Schritte
- Anzeigen von Schritten
- Abbrechen von Schritten

Hinzufügen von Schritten zu einem Cluster mit der Verwaltungskonsole für Amazon EMR

Verwenden Sie die folgenden Verfahren, um Schritte zu einem Cluster mit dem AWS Management Console hinzuzufügen. Detaillierte Informationen zum Einreichen von Schritten für bestimmte Big-Data-Anwendungen finden Sie in den folgenden Abschnitten des Amazon-EMR-Versionshandbuchs:

- Einen benutzerdefinierten JAR-Schritt senden
- Einen Hadoop-Streaming-Schritt senden
- Einen Spark-Schritt senden
- Einen Pig-Schritt senden
- Einen Befehl oder ein Skript als Schritt ausführen
- Werte in Schritte übergeben, um Hive-Skripte auszuführen

So fügen Sie Schritte während der Clustererstellung hinzu

Von AWS Management Console aus können Sie Schritte hinzufügen, wenn Sie einen Cluster erstellen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Wie Sie Schritte hinzuzufügen, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie unter Schritte die Option Schritt hinzufügen aus. Geben Sie die entsprechenden Werte in die Felder im Dialogfeld Schritt hinzufügen ein. Informationen zur Formatierung Ihrer Schrittargumente finden Sie unter Schritt-Argumente hinzufügen. Die Optionen unterscheiden sich je nach Schritttyp. Um Ihren Schritt hinzuzufügen und das Dialogfeld zu verlassen, wählen Sie Schritt hinzufügen.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

Um Schritte hinzuzufügen, wenn Sie einen Cluster mit der alten Konsole erstellen

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home. Wählen Sie Cluster erstellen – Erweiterte Optionen.
2. Wählen Sie auf der Seite Step 1: Software and Steps (Schritt 1: Software und Schritte) für Steps (optional) (Schritte (optional)) die Option Run multiple steps in parallel to improve cluster utilization and save cost (Mehrere Schritte parallel ausführen, um die

Clusterauslastung zu verbessern und Kosten zu sparen) aus. Der Standardwert für die Nebenläufigkeitsstufe ist 10. Sie können zwischen 2 und 256 Schritten wählen, die parallel ausgeführt werden können.

> **Note**
>
> Das parallele Ausführen mehrerer Schritte wird nur mit Amazon-EMR-Version 5.28.0 und höher unterstützt.

3. Wählen Sie für After last step completes (Nach Abschluss des letzten Schritts) die Option Cluster enters waiting state (Cluster in den Wartezustand) oder Auto-terminate the cluster (Cluster automatisch beenden) aus.
4. Wählen Sie Step type (Schritttyp) und dann Add step (Schritt hinzufügen) aus.
5. Geben Sie die entsprechenden Werte in die Felder im Dialogfeld Add Step (Schritt hinzufügen) ein. Informationen zur Formatierung Ihrer Schrittargumente finden Sie unter Schritt-Argumente hinzufügen. Die Optionen unterscheiden sich je nach Schritttyp. Wenn Sie Mehrere Schritte parallel ausführen, um die Clusterauslastung zu verbessern und Kosten zu sparen aktiviert haben, ist die einzige Option für Aktion bei Fehler Weiter. Wählen Sie als Nächstes Add (Hinzufügen) aus.

So fügen Sie einem ausgeführten Cluster Schritte hinzu

Mit AWS Management Console können Sie einem Cluster Schritte hinzufügen, bei denen die Option zum automatischen Beenden deaktiviert ist.

New console

So fügen Sie Schritte zu einem laufenden Cluster mit der neuen Konsole hinzu

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Wählen Sie auf der Seite „Clusterdetails“ auf der Registerkarte Schritte die Option Schritt hinzufügen aus. Um einen vorhandenen Schritt zu klonen, wählen Sie das Dropdownmenü Aktionen und dann Schritt klonen aus.

4. Geben Sie die entsprechenden Werte in die Felder im Dialogfeld Schritt hinzufügen ein. Die Optionen unterscheiden sich je nach Schritttyp. Um Ihren Schritt hinzuzufügen und das Dialogfeld zu verlassen, wählen Sie Schritt hinzufügen.

Old console

So fügen Sie Schritte zu einem laufenden Cluster mit der alten Konsole hinzu

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home. Wählen Sie auf der Seite Cluster List (Cluster-Liste) den Link für Ihren Cluster aus.
2. Wählen Sie auf der Seite Cluster Details (Clusterdetails) die Registerkarte Steps (Schritte) aus.
3. Wählen Sie auf der Registerkarte Steps (Schritte) die Option Add step (Schritt hinzufügen) aus.
4. Geben Sie die entsprechenden Werte in die Felder im Dialogfeld Add Step (Schritt hinzufügen) ein und wählen Sie dann Add (Hinzufügen) aus. Die Optionen unterscheiden sich je nach Schritttyp.

So ändern Sie die Nebenläufigkeitsstufe für Schritte in einem ausgeführten Cluster

Mit der AWS Management Console können Sie die Nebenläufigkeitsstufe für Schritte in einem ausgeführten Cluster ändern.

> **Note**
>
> Sie können mehrere Schritte nur mit Amazon EMR Version 5.28.0 und höher parallel ausführen.

New console

So ändern Sie die Schrittparallelität in einem laufenden Cluster mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.

2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten. Der Cluster muss ausgeführt werden, um sein Parallelitätsattribut zu ändern.
3. Suchen Sie auf der Seite mit den Cluster-Details auf der Registerkarte Schritte den Abschnitt Attribute. Wählen Sie Bearbeiten aus, um die Parallelität zu ändern. Geben Sie einen Wert zwischen 1 und 256 ein.

Old console

So ändern Sie die Schrittparallelität in einem laufenden Cluster mit der alten Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/home. Wählen Sie auf der Seite Cluster List (Cluster-Liste) den Link für Ihren Cluster aus.
2. Wählen Sie auf der Seite Cluster Details (Clusterdetails) die Registerkarte Steps (Schritte) aus.
3. Wählen Sie für Concurrency (Nebenläufigkeit) die Option Change (Ändern) aus. Wählen Sie einen neuen Wert für die Nebenläufigkeitsstufe von Schritten aus und speichern Sie ihn.

Schritt-Argumente hinzufügen

Wenn Sie AWS Management Console verwenden, um Ihrem Cluster einen Schritt hinzuzufügen, können Sie Argumente für diesen Schritt im Feld Argumente angeben. Sie müssen Argumente durch Leerzeichen trennen und Zeichenkettenargumente einschließen, die aus Zeichen und Leerzeichen in Anführungszeichen bestehen.

Example : Richtige Argumente

Die folgenden Beispielargumente sind für AWS Management Console korrekt formatiert, wobei das letzte Zeichenkettenargument in Anführungszeichen gesetzt ist.

```
bash -c "aws s3 cp s3://DOC-EXAMPLE-BUCKET/my-script.sh ."
```

Sie können auch jedes Argument aus Gründen der besseren Lesbarkeit in eine separate Zeile einfügen, wie im folgenden Beispiel gezeigt.

```
bash
```

```
-c
"aws s3 cp s3://DOC-EXAMPLE-BUCKET/my-script.sh ."
```

Example : Falsche Argumente

Die folgenden Beispielargumente sind falsch formatiert für AWS Management Console. Beachten Sie, dass das letzte Zeichenkettenargument, `aws s3 cp s3://DOC-EXAMPLE-BUCKET/my-script.sh .`, Leerzeichen enthält und nicht von Anführungszeichen umgeben ist.

```
bash -c aws s3 cp s3://DOC-EXAMPLE-BUCKET/my-script.sh .
```

Hinzufügen von Schritten zu einem Cluster mit AWS CLI

Die folgenden Verfahren zeigen, wie Sie Schritte zu einem neu erstellten Cluster und zu einem aktiven Cluster mit der AWS CLI hinzufügen. In beiden Beispielen wird der Unterbefehl `--steps` verwendet, um Schritte zum Cluster hinzuzufügen.

So fügen Sie Schritte während der Clustererstellung hinzu

- Geben Sie den folgenden Befehl ein, um einen Cluster zu erstellen und einen Apache Pig-Schritt hinzuzufügen. Ersetzen Sie *myKey* mit dem Namen Ihres Amazon-EC2-Schlüsselpaars oder öffentlichen Schlüssels.

```
aws emr create-cluster --name "Test cluster" \
--applications Name=Spark \
--use-default-roles \
--ec2-attributes KeyName=myKey \
--instance-groups InstanceGroupType=PRIMARY,InstanceCount=1,InstanceType=m5.xlarge
 InstanceGroupType=CORE,InstanceCount=2,InstanceType=m5.xlarge \
--steps '[{"Args":["spark-submit","--deploy-mode","cluster","--
class","org.apache.spark.examples.SparkPi","/usr/lib/spark/examples/jars/spark-
examples.jar","5"],"Type":"CUSTOM_JAR","ActionOnFailure":"CONTINUE","Jar":"command-
runner.jar","Properties":"","Name":"Spark application"}]'
```

> **Note**
>
> Die Liste der Argumente ändert sich je nach Art des Schritts.

Standardmäßig ist Nebenläufigkeitsstufe für Schritte 1. Sie können die Nebenläufigkeitsstufe für Schritte festlegen, indem Sie den `StepConcurrencyLevel`-Parameter beim Erstellen eines Clusters verwenden.

Die Ausgabe ist eine Cluster-Kennung ähnlich der folgenden.

```
{
    "ClusterId": "j-2AXXXXXXGAPLF"
}
```

So fügen Sie einen Schritt einem aktiven Cluster hinzu

- Geben Sie den folgenden Befehl ein, um einen Schritt zu einem aktiven Cluster hinzuzufügen. Ersetzen Sie *j-2AXXXXXXGAPLF* durch die ID Ihres eigenen Clusters.

```
aws emr add-steps --cluster-id j-2AXXXXXXGAPLF \
--steps '[{"Args":["spark-submit","--deploy-mode","cluster","--
class","org.apache.spark.examples.SparkPi","/usr/lib/spark/examples/jars/spark-
examples.jar","5"],"Type":"CUSTOM_JAR","ActionOnFailure":"CONTINUE","Jar":"command-
runner.jar","Properties":"","Name":"Spark application"}]'
```

Die Ausgabe ist eine Schrittkennung ähnlich der folgenden.

```
{
    "StepIds": [
 "s-Y9XXXXXXAPMD"
    ]
}
```

So ändern Sie die Nebenläufigkeitsstufe für Schritte in einem ausgeführten Cluster

1. In einem laufenden Cluster können Sie den `StepConcurrencyLevel` mit der `ModifyCluster`-API ändern. Geben Sie beispielsweise den folgenden Befehl ein, um die`StepConcurrencyLevel` für Schritte auf `10` zu erhöhen. Ersetzen Sie *j-2AXXXXXXGAPLF* durch die ID Ihres Clusters.

```
aws emr modify-cluster --cluster-id j-2AXXXXXXGAPLF --step-concurrency-level 10
```

2. Die Ausgabe sieht folgendermaßen oder ähnlich aus.

```
{
"StepConcurrencyLevel": 10
}
```

Weitere Informationen zu den Amazon-EMR-Befehlen finden Sie unter AWS CLI in der AWS CLI-Befehlsreferenz.

Überlegungen zum parallelen Ausführen mehrerer Schritte

- Parallel laufende Schritte können in beliebiger Reihenfolge abgeschlossen werden, aber ausstehende Schritte in der Warteschlange gehen in der Reihenfolge in den laufenden Zustand über, in der sie eingereicht wurden.
- Wenn Sie eine Nebenläufigkeitsstufe für Schritte für den Cluster auswählen, müssen Sie überlegen, ob der Primärknoten-Instance-Typ die Speicheranforderungen von Benutzer-Workloads erfüllt. Der Hauptschrittausführungsprozess wird für jeden Schritt auf dem Primärknoten ausgeführt. Das parallele Ausführen mehrerer Schritte erfordert mehr Arbeitsspeicher und eine höhere CPU-Auslastung auf dem Primärknoten als die Ausführung eines einzelnen Schrittes.
- Um eine komplexe Planung und Ressourcenverwaltung von gleichzeitigen Schritten zu erreichen, können Sie YARN-Planungsfunktionen wie `FairScheduler` oder verwenden `CapacityScheduler`. Beispielsweise können Sie `FairScheduler` mit einem `queueMaxAppsDefault`-Satz verwenden, um zu verhindern, dass mehr als eine bestimmte Anzahl von Aufgaben gleichzeitig ausgeführt werden.
- Die Nebenläufigkeitsstufe für Schritte unterliegt den Konfigurationen von Ressourcenmanagern. Wenn YARN beispielsweise nur mit einer Parallelität von 5 konfiguriert ist, können Sie nur fünf YARN-Anwendungen parallel laufen lassen, selbst wenn `StepConcurrencyLevel` auf `10` gesetzt ist. Weitere Informationen finden Sie unter Konfigurieren von Anwendungen in den Amazon-EMR-Versionshinweisen.
- Sie können keinen Schritt mit einem anderen `ActionOnFailure` als CONTINUE hinzufügen, solange die Schrittparallelitätsstufe des Clusters größer als 1 ist.
- Wenn die Step-Parallelitätsstufe eines Clusters größer als eins ist, wird das `ActionOnFailure`-Step-Feature nicht aktiviert.

- Wenn ein Cluster über die Schritt-Parallelitätsstufe 1, aber über mehrere laufende Schritte verfügt, wird `TERMINATE_CLUSTER ActionOnFailure` möglicherweise aktiviert, `CANCEL_AND_WAIT ActionOnFailure` jedoch nicht. Dieser Grenzfall tritt auf, wenn die Parallelitätsstufe für Clusterschritte höher als eins war, aber während der Ausführung mehrerer Schritte niedriger war.
- Sie können EMR Auto Scaling verwenden, um basierend auf den YARN-Ressourcen vertikal zu skalieren und Ressourcenkonflikte zu vermeiden. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen im Amazon-EMR-Managementhandbuch.
- Wenn Sie die Nebenläufigkeitsstufe für Schritte verringern, erlaubt EMR das Abschließen aller laufenden Schritte, bevor die Anzahl der Schritte reduziert wird. Wenn die Ressourcen ausgeschöpft sind, weil der Cluster zu viele gleichzeitige Schritte ausführt, empfehlen wir, alle laufenden Schritte manuell abzubrechen, um Ressourcen freizumachen.

Anzeigen von Schritten

Die Gesamtanzahl der Schrittdatensätze, die Sie anzeigen können (unabhängig vom Status) ist 1 000. Diese Gesamtzahl umfasst sowohl vom Benutzer übermittelte Schritte als auch Systemschritte. Da der Status der vom Benutzer übermittelten Schritte sich in COMPLETED oder FAILED ändert, können zusätzliche vom Benutzer übermittelte Schritte zum Cluster hinzugefügt werden, bis das Limit der 1 000 Schritte erreicht ist. Nachdem einem Cluster 1 000 Schritte hinzugefügt wurden, führt die Übermittlung weiterer Schritte dazu, dass ältere, vom Benutzer übermittelte Schrittdatensätze gelöscht werden. Diese Datensätze werden nicht aus den Protokolldateien entfernt. Sie werden aber aus der Konsolenanzeige entfernt. Sie werden nicht angezeigt, wenn Sie die AWS CLI oder API zum Abrufen von Cluster-Informationen verwenden. Systemschrittdatensätze werden niemals entfernt.

Welche Schrittinformationen Sie anzeigen können, hängt vom Mechanismus ab, der zum Abrufen der Cluster-Informationen verwendet wurde. Die folgende Tabelle enthält die Schrittinformationen, die von den verfügbaren Optionen jeweils zurückgegeben werden.

Option	DescribeJobFlow oder --describe --jobflow	ListSteps oder list-steps
SDK	256 Schritte	1.000 Schritte
Amazon-EMR-CLI	256 Schritte	N/A

Option	DescribeJobFlow oder --describe --jobflow	ListSteps oder list-steps
AWS CLI	N/A	1.000 Schritte
API	256 Schritte	1.000 Schritte

Abbrechen von Schritten

Sie können ausstehende und ausgeführte Schritte mithilfe der AWS Management Console, der AWS CLI oder der Amazon-EMR-API abbrechen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So brechen Sie Schritte mit der neuen Konsole ab

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Klicken Sie auf der Seite Cluster-Details auf der Registerkarte Schritte auf das Kontrollkästchen neben dem Schritt, den Sie abbrechen möchten. Wählen Sie das Dropdownmenü Aktionen und dann Schritte abbrechen aus.
4. Wählen Sie im Dialogfeld Schritt abbrechen entweder den Schritt abbrechen und warten, bis er beendet ist, oder ob Sie den Schritt abbrechen und das Beenden erzwingen möchten. Wählen Sie dann Confirm (Bestätigen) aus.
5. Der Status der Schritte in der Tabelle Schritte ändert sich in `CANCELLED`.

Old console

So brechen Sie Schritte mit der alten Konsole ab

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Erweitern Sie auf der Seite Cluster Details (Cluster-Details) den Abschnitt Steps (Schritte).
3. Wählen Sie für jeden Schritt, den Sie abbrechen möchten, den Schritt aus der Liste Steps (Schritte)aus. Wählen Sie dann Cancel step (Schritt abbrechen) aus.
4. Behalten Sie im Dialogfeld Cancel step (Schritt abbrechen) die Standardoption Cancel the step and wait for it to exit (Schritt abbrechen und warten, bis er beendet wird). Wenn Sie den Schritt sofort beenden möchten, ohne darauf zu warten, dass Prozesse abgeschlossen sind, wählen Sie Cancel the step and force it to exit (Schritt abbrechen und Beenden erzwingen) aus.
5. Wählen Sie Cancel step (Schritt abbrechen) aus.

CLI

So brechen Sie mit der AWS CLI ab

- Verwenden Sie den Befehl `aws emr cancel-steps` unter Angabe des Clusters und der abzubrechenden Schritte. Das folgende Beispiel zeigt einen AWS CLI-Befehl für den Abbruch von zwei Schritten.

```
aws emr cancel-steps --cluster-id j-2QUAXXXXXXXXX \
--step-ids s-3M8DXXXXXXXXX s-3M8DXXXXXXXXX \
--step-cancellation-option SEND_INTERRUPT
```

Mit Amazon-EMR-Version 5.28.0 können Sie beim Abbrechen von Schritten eine der beiden folgenden Abbruchoptionen für `StepCancellationOption`-Parameter auswählen.

- `SEND_INTERRUPT` – Dies ist die Standardoption. Wenn eine Anfrage zum Abbruch eines Schritts eingeht, sendet EMR ein `SIGTERM`-Signal an den Schritt. Fügen Sie Ihrer Schrittlogik einen `SIGTERM`-Signal-Handler hinzu, um dieses Signal abzufangen und die Prozesse der untergeordneten Schritte zu beenden oder zu warten, bis sie abgeschlossen sind.

- `TERMINATE_PROCESS` – Wenn diese Option ausgewählt ist, sendet EMR ein `SIGKILL`-Signal an den Schritt und alle seine untergeordneten Prozesse, wodurch sie sofort beendet werden.

Was es bei der Stornierung von Schritten zu berücksichtigen gibt

- Wenn Sie einen laufenden oder ausstehenden Schritt abbrechen, wird dieser Schritt aus der aktiven Schrittanzahl entfernt.
- Wenn Sie einen laufenden Schritt abbrechen, kann ein ausstehender Schritt nicht ausgeführt werden, vorausgesetzt, dass keine Änderung an `stepConcurrencyLevel` vorgenommen wurde.
- Durch das Abbrechen eines laufenden Schritts wird der Schritt `ActionOnFailure` nicht ausgelöst.
- `SEND_INTERRUPT StepCancellationOption` sendet für EMR 5.32.0 und höher ein `SIGTERM`-Signal an den untergeordneten Schrittprozess. Sie sollten auf dieses Signal achten und eine Säuberung durchführen und das System ordnungsgemäß herunterfahren. `TERMINATE_PROCESS StepCancellationOption` sendet ein `SIGKILL`-Signal an den untergeordneten Schrittprozess und alle seine untergeordneten Prozesse. Asynchrone Prozesse sind jedoch nicht betroffen.

Einen Cluster anzeigen und überwachen

Amazon EMR bietet mehrere Tools, die Sie verwenden können, um Informationen über Ihren Cluster zu sammeln. Sie können Informationen zum Cluster über die Konsole, die Befehlszeilenschnittstelle (CLI) oder programmgesteuert abrufen. Die Standard-Hadoop-Webschnittstellen und Protokolldateien sind auf dem Primärknoten verfügbar. Sie können auch Überwachungsservices wie CloudWatch und Ganglia verwenden, um die Leistung Ihres Clusters zu verfolgen.

Der Anwendungsverlauf ist auch über die Konsole mit den „persistenten“ Anwendungs-UIs für Spark History Server ab Amazon EMR 5.25.0 verfügbar. Mit Amazon EMR 6.x sind auch persistente YARN Timeline Server und Tez-Benutzeroberflächen verfügbar. Diese Dienste werden außerhalb des Clusters gehostet, sodass Sie nach Beendigung des Clusters 30 Tage lang auf den Anwendungsverlauf zugreifen können, ohne dass eine SSH-Verbindung oder ein Web-Proxy erforderlich ist. Weitere Information unter Anwendungsverlauf anzeigen

Themen

- Cluster-Status und -Details anzeigen
- Verbessertes Schritt-Debuggen
- Anwendungsverlauf anzeigen

- Anzeige von -Protokolldateien
- Anzeigen von Cluster-Instances in Amazon EC2
- CloudWatch-Ereignisse und Metriken
- Anzeigen von Cluster-Anwendungsmetriken mit Ganglia
- Protokollieren von Amazon-EMR-API-Aufrufen mit AWS CloudTrail

Cluster-Status und -Details anzeigen

Nach dem Erstellen eines Clusters können Sie seinen Status überwachen und detaillierte Informationen zu seiner Ausführung sowie eventuell aufgetretenen Fehlern erhalten – auch nach dem Beenden des Clusters. Amazon EMR speichert für Ihre Referenz Metadaten über beendete Cluster für zwei Monate. Anschließend werden die Metadaten gelöscht. Sie können keine Cluster aus dem Cluster-Verlauf löschen. Sie können jedoch in der AWS Management Console die Option Filter (Filtern) und in der AWS CLI Optionen mit dem Befehl `list-clusters` verwenden, um sich auf für Sie relevante Cluster zu konzentrieren.

Sie können auf den innerhalb des Clusters gespeicherten Anwendungsverlauf eine Woche ab dem Zeitpunkt der Aufzeichnung zugreifen, unabhängig davon, ob der Cluster ausgeführt wird oder beendet wurde. Darüber hinaus speichern persistente Anwendungsbenutzeroberflächen den Anwendungsverlauf für 30 Tage nach Beendigung eines Clusters außerhalb des Clusters. Weitere Information unter Anwendungsverlauf anzeigen

Weitere Hinweise zu Clusterstatus, wie Wartend und Läuft, finden Sie unter Verstehen des Cluster-Lebenszyklus.

So lassen Sie Cluster-Details mithilfe der AWS Management Console anzeigen

Die Clusterliste unter https://console.aws.amazon.com/emr listet alle Cluster in Ihrem Konto und IhrerAWS- Region auf, einschließlich beendeter Cluster. Die Liste zeigt Folgendes für jeden Cluster: den Namen und die ID, den Status und die Statusdetails, die Erstellungszeit, die verstrichene Zeit, in der der Cluster ausgeführt wurde, und die normalisierten Instance-Stunden, die für alle EC2-Instances im Cluster angefallen sind. Diese Liste ist der Ausgangspunkt für die Überwachung des Status von Clustern. Sie ist so konzipiert, dass Sie jeden Cluster zu Analyse- und Fehlerbehebungszwecken aufschlüsseln können.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So zeigen Sie Clusterinformationen mit der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie anzeigen möchten.
3. Im Bereich Zusammenfassung können Sie sich die Grundlagen Ihrer Cluster-Konfiguration ansehen, z. B. den Cluster-Status, die Open-Source-Anwendungen, die Amazon EMR auf dem Cluster installiert hat, und die Version von Amazon EMR, mit der Sie den Cluster erstellt haben. Verwenden Sie jede Registerkarte unterhalb der Zusammenfassung, um die in der folgenden Tabelle beschriebenen Informationen anzuzeigen.

Old console

So zeigen Sie Clusterinformationen mit der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Um eine gekürzte Zusammenfassung der Clusterinformationen anzuzeigen, klicken Sie unter Name auf den Abwärtspfeil neben dem Link für den Cluster. Die Zeile für den Cluster wird erweitert, sodass weitere Informationen zu Clustern, Hardware, Schritten und Bootstrap-Aktionen dargestellt werden. Verwenden Sie die Links in diesem Abschnitt, um aufgegliederte Details einzusehen. Klicken Sie beispielsweise auf einen Link in Steps (Schritte), um auf Schrittprotokolldateien zuzugreifen, die JAR-Datei für den Schritt anzuzeigen, die Aufträge und Aufgaben für den Schritt detailliert anzuzeigen und auf Protokolldateien zuzugreifen.

3. Um die Clusterinformationen ausführlich anzuzeigen, wählen Sie den Cluster-Link unter Name aus, um die Seite mit den Clusterdetails zu öffnen. Die folgenden Informationen sind auf der Seite mit den Cluster-Details in der alten Konsole verfügbar:

Registerkarte (Alte Konsole)	Beschreibung (Alte Konsole)
Eigenschaften	Verwenden Sie diese Registerkarte, um das Betriebssystem Ihres Clusters, Ihre Clusterbeendigung und Sicherheitskonfigurationen, Ihre VPC- und Subnetzinformationen sowie den Speicherort der Protokolle in Amazon S3 anzuzeigen.
Bootstrap-Aktionen	Über diese Registerkarte können Sie den Status von Bootstrap-Aktionen anzeigen, die der Cluster beim Start ausführt. Bootstrap-Aktionen werden für benutzerdefinierte Softwareinstallationen und erweiterte Konfigurationen verwendet. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.
Überwachung	Verwenden Sie diese Registerkarte, um die wichtigsten Metriken des Clusterbetriebs einzusehen. Sie können Daten auf Cluster-Ebene, Daten auf Knotenebene und Informationen zu E/A und Datenspeicherung anzeigen.
Instances	Verwenden Sie diese Registerkarte, um Informationen zu Knoten in Ihrem Cluster anzuzeigen, einschließlich EC2-Instance-IDs, DNS-Namen, EBS-Volumes und mehr.r.
Schritte	Über diese Registerkarte können Sie den Status für Schritte einsehen, die Sie übermittelt haben, und auf entsprechende Protokoll

Registerkarte (Alte Konsole)	Beschreibung (Alte Konsole)
	dateien zugreifen. Weitere Informationen zu den Schritten finden Sie unter Übermitteln von Arbeit an einen Cluster.
Anwendungen	Verwenden Sie diese Registerkarte, um persistente YARN Timeline Server- und Tez UI-Anwendungsdetails außerhalb des Clusters anzuzeigen. Sie können auch Informationen über Ihre installierten Anwendungen, Cluster-Konfigurationen und Instance-Gruppen anzeigen. Anwendung sbenutzeroberflächen für Anwendungen innerhalb des Clusters sind verfügbar, während der Cluster ausgeführt wird.
Ereignisse	Über diese Registerkarte können Sie das Ereignisprotokoll für den Cluster anzeigen. Weitere Informationen finden Sie unter Überwachung von Amazon-EMR-Ereignissen mit CloudWatch.
Tags	Verwenden Sie diese Registerkarte, um alle Tags anzuzeigen, die Sie auf den Cluster angewendet haben.

So lassen Sie Cluster-Details mithilfe der AWS CLI anzeigen

Die folgenden Beispiele zeigen, wie Sie Cluster-Details über die AWS CLI abrufen. Weitere Informationen zu verfügbaren Befehlen finden Sie in der AWS CLI-Befehlsreferenz für Amazon EMR. Sie können den Befehl describe-cluster verwenden, um Cluster-Details einschließlich Status, Hardware- und Softwarekonfiguration, VPC-Einstellungen, Bootstrap-Aktionen, Instance-Gruppen usw. anzuzeigen. Weitere Informationen zu Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus. Das folgende Beispiel zeigt die Verwendung des Befehls `describe-cluster`, gefolgt von Beispielen für den Befehl list-clusters.

Example Anzeigen des Cluster-Status

Sie benötigen die Cluster-ID, um den Befehl `describe-cluster` zu verwenden. In diesem Beispiel wird gezeigt, wie Sie eine Liste von innerhalb eines bestimmten Zeitraums erstellten Clustern abrufen und dann mit einer der zurückgegebenen Cluster-IDs weitere Informationen zum Status eines bestimmten Clusters auflisten.

Der folgende Befehl beschreibt einen Cluster mit der ID *j-1K48XXXXXXHCB*, die Sie durch Ihre Cluster-ID ersetzen.

```
aws emr describe-cluster --cluster-id j-1K48XXXXXXHCB
```

Die Ausgabe des Befehls ähnelt der folgenden:

```
{
    "Cluster": {
        "Status": {
            "Timeline": {
                "ReadyDateTime": 1438281058.061,
                "CreationDateTime": 1438280702.498
            },
            "State": "WAITING",
            "StateChangeReason": {
                "Message": "Waiting for steps to run"
            }
        },
        "Ec2InstanceAttributes": {
            "EmrManagedMasterSecurityGroup": "sg-cXXXXX0",
            "IamInstanceProfile": "EMR_EC2_DefaultRole",
            "Ec2KeyName": "myKey",
            "Ec2AvailabilityZone": "us-east-1c",
            "EmrManagedSlaveSecurityGroup": "sg-example"
        },
        "Name": "Development Cluster",
        "ServiceRole": "EMR_DefaultRole",
        "Tags": [],
        "TerminationProtected": false,
        "ReleaseLabel": "emr-4.0.0",
        "NormalizedInstanceHours": 16,
        "InstanceGroups": [
            {
                "RequestedInstanceCount": 1,
                "Status": {
```

```
                    "Timeline": {
                        "ReadyDateTime": 1438281058.101,
                        "CreationDateTime": 1438280702.499
                    },
                    "State": "RUNNING",
                    "StateChangeReason": {
                        "Message": ""
                    }
                },
                "Name": "CORE",
                "InstanceGroupType": "CORE",
                "Id": "ig-2EEXAMPLEXXP",
                "Configurations": [],
                "InstanceType": "m5.xlarge",
                "Market": "ON_DEMAND",
                "RunningInstanceCount": 1
            },
            {
                "RequestedInstanceCount": 1,
                "Status": {
                    "Timeline": {
                        "ReadyDateTime": 1438281023.879,
                        "CreationDateTime": 1438280702.499
                    },
                    "State": "RUNNING",
                    "StateChangeReason": {
                        "Message": ""
                    }
                },
                "Name": "MASTER",
                "InstanceGroupType": "MASTER",
                "Id": "ig-2A1234567XP",
                "Configurations": [],
                "InstanceType": "m5.xlarge",
                "Market": "ON_DEMAND",
                "RunningInstanceCount": 1
            }
        ],
        "Applications": [
            {
                "Version": "1.0.0",
                "Name": "Hive"
            },
            {
```

```
                "Version": "2.6.0",
                "Name": "Hadoop"
            },
            {
                "Version": "0.14.0",
                "Name": "Pig"
            },
            {
                "Version": "1.4.1",
                "Name": "Spark"
            }
        ],
        "BootstrapActions": [],
        "MasterPublicDnsName": "ec2-X-X-X-X.compute-1.amazonaws.com",
        "AutoTerminate": false,
        "Id": "j-jobFlowID",
        "Configurations": [
            {
                "Properties": {
                    "hadoop.security.groups.cache.secs": "250"
                },
                "Classification": "core-site"
            },
            {
                "Properties": {
                    "mapreduce.tasktracker.reduce.tasks.maximum": "5",
                    "mapred.tasktracker.map.tasks.maximum": "2",
                    "mapreduce.map.sort.spill.percent": "90"
                },
                "Classification": "mapred-site"
            },
            {
                "Properties": {
                    "hive.join.emit.interval": "1000",
                    "hive.merge.mapfiles": "true"
                },
                "Classification": "hive-site"
            }
        ]
    }
}
```

Example Auflisten von Clustern nach Erstellungsdatum

Zum Abrufen von in einem bestimmten Datenbereich erstellten Clustern verwenden Sie den Befehl `list-clusters` mit den Parametern `--created-after` und `--created-before`.

Mit dem folgenden Befehl werden alle Cluster aufgelistet, die zwischen dem 9. Oktober 2019 und dem 12. Oktober 2019 erstellt wurden.

```
aws emr list-clusters --created-after 2019-10-09T00:12:00 --created-
before 2019-10-12T00:12:00
```

Example Auflisten von Clustern nach Status

Verwenden Sie zum Auflisten von Clustern nach Status den Befehl `list-clusters` mit dem Parameter `--cluster-states`. Zu den zulässigen Cluster-Status gehören: STARTING, BOOTSTRAPPING, RUNNING, WAITING, TERMINATING, TERMINATED und TERMINATED_WITH_ERRORS.

```
aws emr list-clusters --cluster-states TERMINATED
```

Sie können auch die folgenden Abkürzungsparameter verwenden, um alle Cluster in den angegebenen Zuständen aufzulisten:

- `--active` filtert Cluster mit den Status STARTING, BOOTSTRAPPING, RUNNING, WAITING oder TERMINATING.
- `--terminated` filtert Cluster mit dem Status TERMINATED.
- `--failed` filtert Cluster mit dem Status TERMINATED_WITH_ERRORS.

Die folgenden Befehle geben dasselbe Ergebnis zurück.

```
aws emr list-clusters --cluster-states TERMINATED
```

```
aws emr list-clusters --terminated
```

Weitere Informationen zu Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus.

Verbessertes Schritt-Debuggen

Wenn ein Amazon-EMR-Schritt fehlschlägt und Sie Ihre Arbeit mit der Schritt-API-Operation mit einem AMI, Version 5.x oder höher, gesendet haben, kann Amazon EMR in einigen Fällen die Ursache des Schrittfehlers ermitteln und zusammen mit den Namen der entsprechenden Protokolldatei und einem Teil der Anwendungs-Stack-Trace-Informationen über die API zurückgeben. Die folgenden Fehler können identifiziert werden:

- Ein üblicher Hadoop-Fehler, wie z. B. das Ausgabeverzeichnis ist bereits vorhanden, das Eingabeverzeichnis ist nicht vorhanden oder für eine Anwendung ist nicht mehr genügend Speicherplatz vorhanden.
- Java-Fehler, wie z. B. eine Anwendung, die mit einer inkompatiblen Version von Java kompiliert und mit einer Hauptklasse ausgeführt wurde, die nicht gefunden wird.
- Ein Problem mit dem Zugriff auf Objekte, die in Amazon S3 gespeichert sind.

Diese Informationen stehen über die API-Operationen DescribeStep und ListSteps zur Verfügung. Das Feld FailureDetails der StepSummary, das von diesen Operationen zurückgegeben wird. Für den Zugriff auf die FailureDetails-Informationen, verwenden Sie die AWS-Befehlszeilenschnittstelle oder AWS SDK.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Die neue Amazon-EMR-Konsole bietet kein schrittweises Debugging. Mit den folgenden Schritten können Sie jedoch Details zur Clusterbeendigung anzeigen.

So zeigen Sie Fehlerdetails in der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie anzeigen möchten.

3. Notieren Sie sich den Statuswert im Abschnitt Zusammenfassung der Cluster-Detailseite. Wenn der Status Mit Fehlern beendet lautet, bewegen Sie den Mauszeiger über den Text, um Details zum Clusterausfall anzuzeigen.

Old console

So zeigen Sie Fehlerdetails in der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie die Option Cluster List (Clusterliste) und wählen Sie einen Cluster aus.
3. Wählen Sie das Pfeilsymbol neben den einzelnen Schritten, um weitere Details anzuzeigen. Wenn der Schritt fehlgeschlagen ist und Amazon EMR die Ursache ermitteln kann, sehen Sie die Fehlerdetails.

CLI

Um Fehlerdetails anzuzeigen, verwenden Sie die AWS CLI

- Verwenden Sie den `describe-step`-Befehl, um Fehlerdetails für einen Schritt mit der AWS CLI abzurufen.

```
aws emr describe-step --cluster-id j-1K48XXXXXHCB --step-id s-3QM0XXXXXM1W
```

Die Ausgabe sieht etwa folgendermaßen aus:

```
{
  "Step": {
    "Status": {
      "FailureDetails": {
        "LogFile": "s3://myBucket/logs/j-1K48XXXXXHCB/steps/s-3QM0XXXXXM1W/
stderr.gz",
        "Message": "org.apache.hadoop.mapred.FileAlreadyExistsException: Output
 directory s3://myBucket/logs/beta already exists",
        "Reason": "Output directory already exists."
      },
      "Timeline": {
        "EndDateTime": 1469034209.143,
```

```
        "CreationDateTime": 1469033847.105,
        "StartDateTime": 1469034202.881
      },
      "State": "FAILED",
      "StateChangeReason": {}
    },
    "Config": {
      "Args": [
        "wordcount",
        "s3://myBucket/input/input.txt",
        "s3://myBucket/logs/beta"
      ],
      "Jar": "s3://myBucket/jars/hadoop-mapreduce-examples-2.7.2-amzn-1.jar",
      "Properties": {}
    },
    "Id": "s-3QM0XXXXXM1W",
    "ActionOnFailure": "CONTINUE",
    "Name": "ExampleJob"
  }
}
```

Anwendungsverlauf anzeigen

Sie können die Anwendungsdetails für den Spark History Server und den YARN-Timeline-Dienst auf der Detailseite des Clusters in der Konsole einsehen. Durch die Verwendung des Amazon-EMR-Anwendungsverlaufs wird es einfacher, Probleme mit aktiven Aufträgen und dem Auftragsverlauf zu beheben und zu analysieren.

New console

Der Abschnitt Anwendungsbenutzeroberflächen auf der Registerkarte Anwendungen bietet verschiedene Anzeigeoptionen, abhängig vom Clusterstatus und den Anwendungen, die Sie auf dem Cluster installiert haben.

- Off-Cluster-Zugriff auf persistente Anwendungsbenutzeroberflächen – Ab Amazon-EMR-Version 5.25.0 sind persistente Anwendungsbenutzeroberflächenlinks für die Spark-Benutzeroberfläche und den Spark History Service verfügbar. Mit Amazon-EMR-Version 5.30.1 und höher verfügen Tez UI und der YARN Timeline Server auch über persistente Anwendungsbenutzeroberflächen. Der YARN Timeline Server und die Tez UI sind Open-Source-Anwendungen, die Metriken für aktive und beendete Cluster bereitstellen. Die

Benutzeroberfläche von Spark enthält Details zu Planungsphasen und -aufgaben, RDD-Größen und Speichernutzung, Umgebungsinformationen und Informationen zu den laufenden Executoren. Persistente Anwendungs-UIs werden außerhalb des Clusters ausgeführt, sodass Clusterinformationen und -protokolle für 30 Tage nach dem Beenden einer Anwendung verfügbar sind. Im Gegensatz zu Anwendungsbenutzeroberflächen auf dem Cluster erfordern persistente Anwendungs-UIs nicht, dass Sie einen Web-Proxy über eine SSH-Verbindung einrichten.

- Anwendungsbenutzeroberflächen innerhalb des Clusters – Es gibt eine Vielzahl von Anwendungsverlauf-Benutzeroberflächen, die auf einem Cluster ausgeführt werden können. Benutzeroberflächen innerhalb eines Clusters werden auf dem Master-Knoten gehostet und erfordern, dass Sie eine SSH-Verbindung zum Webserver einrichten. Anwendungsbenutzeroberflächen innerhalb eines Clusters speichern den Anwendungsverlauf für eine Woche nach dem Beenden einer Anwendung. Weitere Informationen und Anweisungen zum Einrichten eines SSH-Tunnels finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

  Mit Ausnahme von Spark History Server-, YARN Timeline Server- und Hive-Anwendungen kann der Anwendungsverlauf innerhalb eines Clusters nur angezeigt werden, während der Cluster ausgeführt wird.

Old console

Die Registerkarte Application user interfaces (Anwendungsbenutzeroberflächen) bietet verschiedene Anzeigeoptionen:

- Zugriff innerhalb des Clusters auf persistente Anwendungsbenutzeroberflächen – Ab Amazon-EMR-Version 5.25.0 stehen persistente Verknüpfungen für Anwendungsbenutzeroberflächen für Spark zur Verfügung. Mit Amazon-EMR-Version 5.30.1 und höher verfügen Tez UI und der YARN Timeline Server auch über persistente Anwendungsbenutzeroberflächen. Der YARN Timeline Server und die Tez UI sind Open-Source-Anwendungen, die Metriken für aktive und beendete Cluster bereitstellen. Die Benutzeroberfläche von Spark enthält Details zu Planungsphasen und -aufgaben, RDD-Größen und Speichernutzung, Umgebungsinformationen und Informationen zu den laufenden Executoren. Persistente Anwendungs-UIs werden außerhalb des Clusters ausgeführt, sodass Clusterinformationen und -protokolle für 30 Tage nach dem Beenden einer Anwendung verfügbar sind. Im Gegensatz zu Anwendungsbenutzeroberflächen auf dem Cluster erfordern persistente Anwendungs-UIs nicht, dass Sie einen Web-Proxy über eine SSH-Verbindung einrichten.

- Anwendungsbenutzeroberflächen innerhalb des Clusters – Es gibt eine Vielzahl von Anwendungsverlauf-Benutzeroberflächen, die auf einem Cluster ausgeführt werden können. Benutzeroberflächen innerhalb eines Clusters werden auf dem Master-Knoten gehostet und erfordern, dass Sie eine SSH-Verbindung zum Webserver einrichten. Anwendungsbenutzeroberflächen innerhalb eines Clusters speichern den Anwendungsverlauf für eine Woche nach dem Beenden einer Anwendung. Weitere Informationen und Anweisungen zum Einrichten eines SSH-Tunnels finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

  Mit Ausnahme von Spark History Server-, YARN Timeline Server- und Hive-Anwendungen kann der Anwendungsverlauf innerhalb eines Clusters nur angezeigt werden, während der Cluster ausgeführt wird.
- Anwendungsverlauf auf hoher Ebene – In den Versionen 5.8.0 bis 5.36.0 und 6.x bis 6.8.0 von Amazon EMR können Sie sich in der alten Amazon-EMR-Konsole eine Zusammenfassung des Anwendungsverlaufs anzeigen lassen, einschließlich wichtiger Kennzahlen für Aufgaben und Ausführende in der Phase. Mit Wirkung zum 23. Januar 2023 wird Amazon EMR den Anwendungsverlauf auf hoher Ebene für alle Versionen einstellen. Wenn Sie Amazon-EMR-Version 5.25.0 oder höher verwenden, empfehlen wir, stattdessen die persistente Anwendungsbenutzeroberfläche zu verwenden.

Persistente Anwendungsbenutzeroberflächen anzeigen

Ab Amazon EMR Version 5.25.0 können Sie eine Verbindung zu den persistenten Spark History Server-Anwendungsdetails herstellen, die außerhalb des Clusters gehostet werden, indem Sie die Seite Zusammenfassung des Clusters oder die Registerkarte Anwendungsbenutzeroberflächen in der Konsole verwenden. Persistente Anwendungsoberflächen für Tez UI und YARN Timeline Server sind ab Amazon-EMR-Version 5.30.1 verfügbar. Der Zugriff auf den persistenten Anwendungsverlauf mit einem Klick bietet folgende Vorteile:

- Sie können aktive Aufgaben und den Aufgabenverlauf schnell analysieren und Probleme damit beheben, ohne einen Web-Proxy über eine SSH-Verbindung einzurichten.
- Sie können auf den Anwendungsverlauf und relevante Protokolldateien für aktive und beendete Cluster zugreifen. Die Protokolle stehen nach dem Ende der Anwendung 30 Tage lang zur Verfügung.

Wählen Sie auf der Registerkarte Anwendungsbenutzeroberflächen oder auf der Cluster-Übersichtsseite für Ihren Cluster in der alten Konsole für Amazon EMR 5.30.1 oder 6.x den Link YARN Timeline Server, Tez UI oder Spark History Server aus.

Das Anwendungs-UI wird in einer neuen Browserregisterkarte geöffnet. Weitere Informationen finden Sie unter Überwachung und Instrumentierung.

Sie können YARN-Containerprotokolle über die Links auf dem Spark History Server, YARN Timeline Server und Tez UI anzeigen.

> **Note**
>
> Um über Spark History Servers, YARN Timeline Server und Tez UI auf YARN-Container-Protokolle zugreifen zu können, müssen Sie die Protokollierung in Amazon S3 für Ihren Cluster aktivieren. Wenn die Protokollierung nicht aktiviert ist, funktionieren die Links zu den YARN Container-Protokollen nicht.

Protokollsammlung

Um den Zugriff auf persistente Anwendungsbenutzeroberflächen mit einem Klick zu ermöglichen, werden von Amazon EMR zwei Arten von Protokollen gesammelt:

- Anwendungsereignisprotokolle werden in einem EMR-System-Bucket erfasst. Die Ereignisprotokolle werden im Ruhezustand mittels serverseitiger Verschlüsselung mit Amazon S3 Managed Keys (SSE-S3) verschlüsselt. Wenn Sie ein privates Subnetz für Ihren Cluster verwenden, stellen Sie sicher, dass Sie `“arn:aws:s3:::prod.MyRegion.appinfo.src/*”` in die Ressourcenliste der Amazon S3-Richtlinie für das private Subnetz aufnehmen. Weitere Informationen finden Sie unter Amazon-S3-Mindestrichtlinie für privates Subnetz.
- YARN-Container-Protokolle werden in einem Amazon-S3-Bucket gesammelt, den Sie besitzen. Sie müssen die Protokollierung für Ihren Cluster aktivieren, um auf YARN-Container-Protokolle zugreifen zu können. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings.

Wenn Sie diese Funktion aus Datenschutzgründen deaktivieren müssen, können Sie den Daemon mithilfe eines Bootstrap-Skripts beim Erstellen eines Clusters stoppen, wie im folgenden Beispiel gezeigt wird.

```
aws emr create-cluster --name "Stop Application UI Support" --release-label emr-5.36.1
 \
--applications Name=Hadoop Name=Spark --ec2-attributes KeyName=<myEMRKeyPairName> \
--instance-groups InstanceGroupType=MASTER,InstanceCount=1,InstanceType=m3.xlarge
 InstanceGroupType=CORE,InstanceCount=1,InstanceType=m3.xlarge
 InstanceGroupType=TASK,InstanceCount=1,InstanceType=m3.xlarge \
--use-default-roles --bootstrap-actions Path=s3://region.elasticmapreduce/bootstrap-
actions/run-if,Args=["instance.isMaster=true","echo Stop Application UI | sudo tee /
etc/apppusher/run-apppusher; sudo systemctl stop apppusher || exit 0"]
```

Nachdem Sie dieses Bootstrap-Skript ausgeführt haben, sammelt Amazon EMR keine Spark-History-Server- oder YARN-Timeline-Server-Ereignisprotokolle im EMR-System-Bucket. Auf der Registerkarte Application user interfaces (Anwendungsbenutzeroberflächen) werden keine Informationen zum Anwendungsverlauf verfügbar sein und Sie verlieren den Zugriff auf alle Anwendungsbenutzeroberflächen über die Konsole.

Große Spark-Ereignisprotokolldateien

In einigen Fällen können Spark-Jobs mit langer Laufzeit, wie Spark-Streaming, und große Jobs, wie Spark-SQL-Abfragen, große Ereignisprotokolle generieren. Bei umfangreichen Ereignisprotokollen können Sie schnell Festplattenspeicher auf Rechen-Instances verbrauchen und beim Laden persistenter Benutzeroberflächen auf `OutOfMemory`-Fehler stoßen. Um diese Probleme zu vermeiden, wird empfohlen, dass Sie das Feature zum Rollen und Verdichten von Spark-Ereignisprotokollen aktivieren. Dieses Feature ist nur in Amazon EMR ab Version emr-6.1.0 oder höher verfügbar. Weitere Informationen zum Rollen und Verdichten finden Sie in der Spark-Dokumentation unter Anwenden der Komprimierung auf Protokolldateien für rollende Ereignisse.

Um das Feature zum Rollen und Verdichten des Spark-Ereignisprotokolls zu aktivieren, aktivieren Sie die folgenden Spark-Konfigurationseinstellungen.

- `spark.eventLog.rolling.enabled` – Aktiviert das Rolling des Ereignisprotokolls je nach Größe. Diese Einstellung ist standardmäßig deaktiviert.
- `spark.eventLog.rolling.maxFileSize` – Wenn das Rolling aktiviert ist, gibt dies die maximale Größe der Ereignisprotokolldatei an, bevor ein Rollover ausgeführt wird. Der Standardwert ist 128 MB.
- `spark.history.fs.eventLog.rolling.maxFilesToRetain`– Gibt die maximale Anzahl nicht komprimierter Ereignisprotokolldateien an, die aufbewahrt werden sollen. Standardmäßig werden alle Ereignisprotokolldateien aufbewahrt. Stellen Sie einen niedrigeren Wert ein, um ältere Ereignisprotokolle zu komprimieren. Der niedrigste Wert ist 1.

Beachten Sie, dass bei der Komprimierung versucht wird, Ereignisse mit veralteten Ereignisprotokolldateien auszuschließen, wie z. B. die folgenden. Wenn dabei Ereignisse verworfen werden, werden sie nicht mehr auf der Benutzeroberfläche des Spark History Servers angezeigt.

- Ereignisse für abgeschlossene Aufträge und zugehörige Phasen- oder Aufgabenereignisse.
- Ereignisse für beendete Exekutoren.
- Ereignisse für abgeschlossene SQL-Anfragen und zugehörige Aufgaben-, Phasen- und Aufgabenereignisse.

So starten Sie einen Cluster mit aktiviertem Rollen und Komprimieren

1. Erstellen Sie eine Konfigurationsdatei `spark-configuration.json` mit der folgenden Konfiguration.

```
[
   {
     "Classification": "spark-defaults",
        "Properties": {
           "spark.eventLog.rolling.enabled": true,
           "spark.history.fs.eventLog.rolling.maxFilesToRetain": 1
        }
   }
]
```

2. Erstellen Sie den Cluster mit der Spark-Rolling-Compaction-Konfiguration wie folgt.

```
aws emr create-cluster \
--release-label emr-6.6.0 \
--instance-type m4.large \
--instance-count 2 \
--use-default-roles \
--configurations file://spark-configuration.json
```

Überlegungen und Einschränkungen

Der Ein-Klick-Zugriff auf persistente Anwendungsbenutzeroberflächen hat derzeit folgende Einschränkungen.

- Es wird mindestens zwei Minuten dauern, bis die Anwendungsdetails auf der Benutzeroberfläche des Spark History Servers angezeigt werden.
- Diese Funktion funktioniert nur, wenn sich das Ereignisprotokollverzeichnis für die Anwendung in HDFS befindet. Amazon EMR speichert Ereignisprotokolle standardmäßig in einem Verzeichnis von HDFS. Wenn Sie das Standardverzeichnis in ein anderes Dateisystem ändern, beispielsweise Amazon S3, funktioniert das Feature nicht.
- Diese Funktion ist derzeit nicht für EMR-Cluster mit mehreren Master-Knoten oder für EMR-Cluster mit AWS Lake Formation-Integration verfügbar.
- Um den Zugriff auf persistente Anwendungsbenutzeroberflächen mit einem Klick zu ermöglichen, müssen Sie über die Berechtigung für die `DescribeCluster`-Aktion für Amazon EMR verfügen. Wenn Sie die Berechtigung eines IAM-Prinzipals für diese Aktion verweigern, dauert es etwa fünf Minuten, bis die Berechtigungsänderung propagiert wird.
- Wenn Sie Anwendungen in einem laufenden Cluster neu konfigurieren, ist der Anwendungsverlauf nicht über das Anwendungs-UI verfügbar.
- Für jede AWS-Konto-Anwendung liegt das Standardlimit für aktive Anwendungs-Benutzeroberflächen bei 200.
- Sie können über die Konsole in der Region USA Ost (Nord-Virginia), der Region USA West (Nordkalifornien), der Region Kanada (Zentral), der Europa (Frankfurt, Irland, London, Paris, Stockholm) und in der Region Asien-Pazifik (Mumbai, Seoul, Singapur, Sydney und Tokio), Südamerika (São Paulo), China (Peking), betrieben von Sinnet, und China (Ningxia), betrieben von NWCD, auf Anwendungs-Benutzeroberflächen zugreifen.

Einen übergeordneten Anwendungsverlauf anzeigen

> **Note**
>
> Wir empfehlen Ihnen, die persistente Anwendungsoberfläche zu verwenden, um eine bessere Benutzererfahrung zu erzielen. Dabei wird der Anwendungsverlauf bis zu 30 Tage lang gespeichert. Der auf dieser Seite beschriebene allgemeine Anwendungsverlauf ist in der neuen Amazon-EMR-Konsole (https://console.aws.amazon.com/emr) nicht verfügbar. Weitere Informationen finden Sie unter Persistente Anwendungsbenutzeroberflächen anzeigen.

Mit den Amazon-EMR-Versionen 5.8.0 bis 5.36.0 und 6.x-Versionen bis 6.8.0 können Sie auf der Registerkarte Anwendungsbenutzeroberflächen in der alten Amazon-EMR-Konsole einen allgemeinen Anwendungsverlauf anzeigen. Eine Amazon-EMR-Anwendungsbenutzeroberfläche speichert die Zusammenfassung des Anwendungsverlaufs für 7 Tage nach Abschluss eines Antrags.

Überlegungen und Einschränkungen

Berücksichtigen Sie die folgenden Einschränkungen, wenn Sie die Registerkarte Benutzeroberflächen von Anwendungen in der alten Amazon-EMR-Konsole verwenden.

- Sie können nur auf das allgemeine Anwendungsverlaufsfeature zugreifen, wenn Sie die Amazon-EMR-Versionen 5.8.0 bis 5.36.0 und 6.x-Versionen bis 6.8.0 verwenden. Mit Wirkung zum 23. Januar 2023 wird Amazon EMR den Anwendungsverlauf auf hoher Ebene für alle Versionen einstellen. Wenn Sie Amazon-EMR-Version 5.25.0 oder höher verwenden, empfehlen wir, stattdessen die persistente Anwendungsbenutzeroberfläche zu verwenden.
- Das Feature zum Anwendungsverlauf auf hoher Ebene unterstützt keine Spark-Streaming-Anwendungen.
- Der Ein-Klick-Zugriff auf persistente Anwendungsbenutzeroberflächen ist derzeit nicht für Amazon-EMR-Cluster mit mehreren Hauptknoten oder für AWS Lake Formation integrierte Amazon-EMR-Cluster verfügbar.

Beispiel: Einen übergeordneten Anwendungsverlauf anzeigen

In der folgenden Abfolge wird ein Drilldown durch eine Spark- oder YARN-Anwendung in die Aufgabendetails unter Verwendung von Anwendungsbenutzeroberflächen auf einer Clusterdetailseite in der alten Konsole veranschaulicht.

Sie können in der Liste Cluster die Option Name für einen Cluster auswählen, um Details zu diesem anzuzeigen. Um Informationen zu YARN-Container-Protokollen anzeigen zu können, müssen Sie die Protokollierung für Ihren Cluster aktivieren. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings. Für den Spark-Anwendungsverlauf sind die in der Zusammenfassungstabelle bereitgestellten Informationen nur eine Teilmenge der Informationen, die über die Benutzeroberfläche des Spark-History-Servers verfügbar sind.

Auf der Registerkarte Anwendungsbenutzeroberflächen unter Anwendungsverlauf auf hoher Ebene können Sie eine Zeile erweitern, um die Diagnoseübersicht für eine Spark-Anwendung anzuzeigen, oder einen Anwendungs-ID-Link auswählen, um Details zu einer anderen Anwendung anzuzeigen.

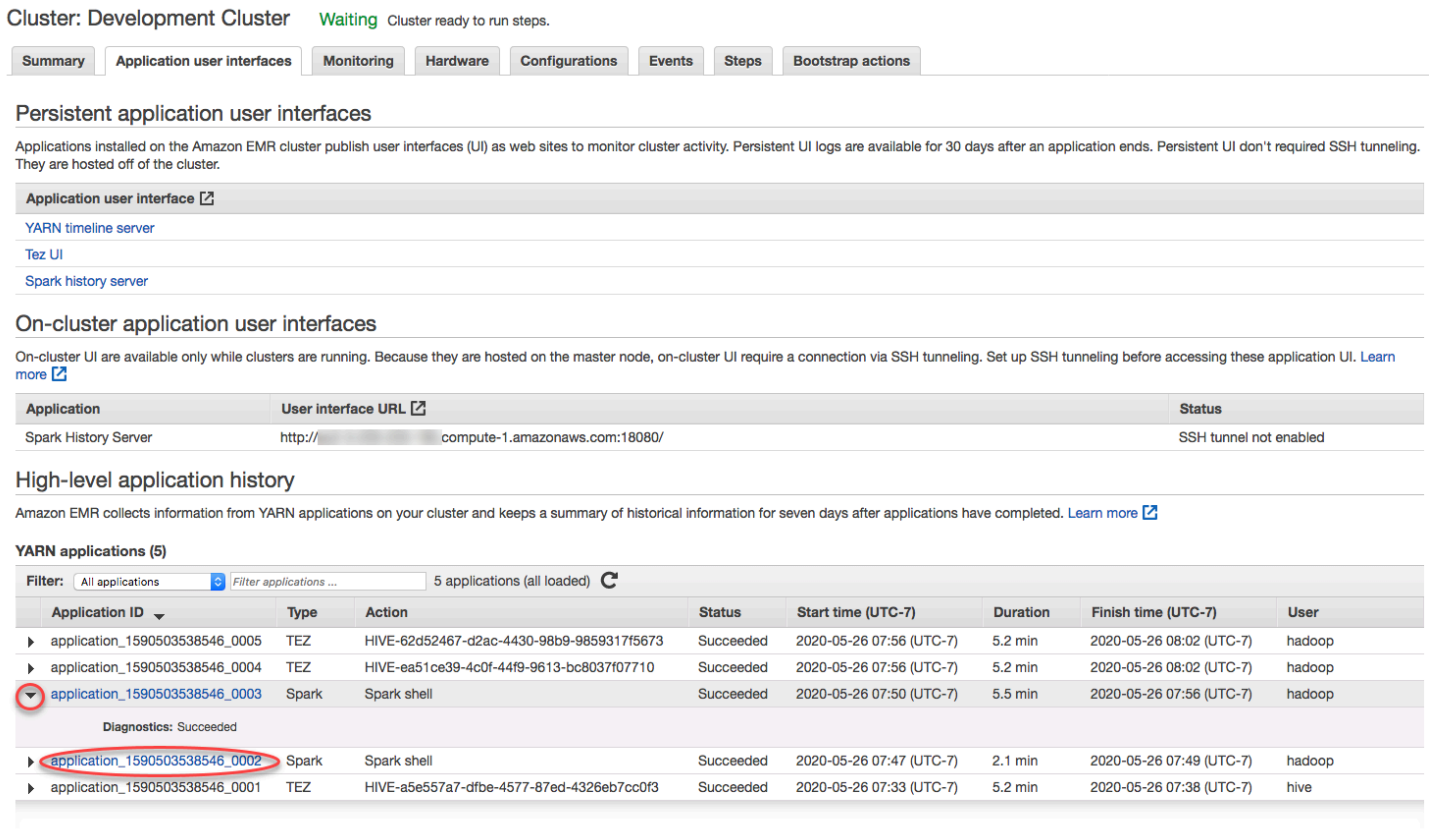

Wenn Sie einen Anwendungs-ID-Link auswählen, ändert sich die Benutzeroberfläche und zeigt die YARN-Anwendungsdetails für diese Anwendung an. Auf der Registerkarte Aufträge der YARN-Anwendungsdetails können Sie den Link Beschreibung für einen Auftrag auswählen, um Details für diesen Auftrag anzuzeigen.

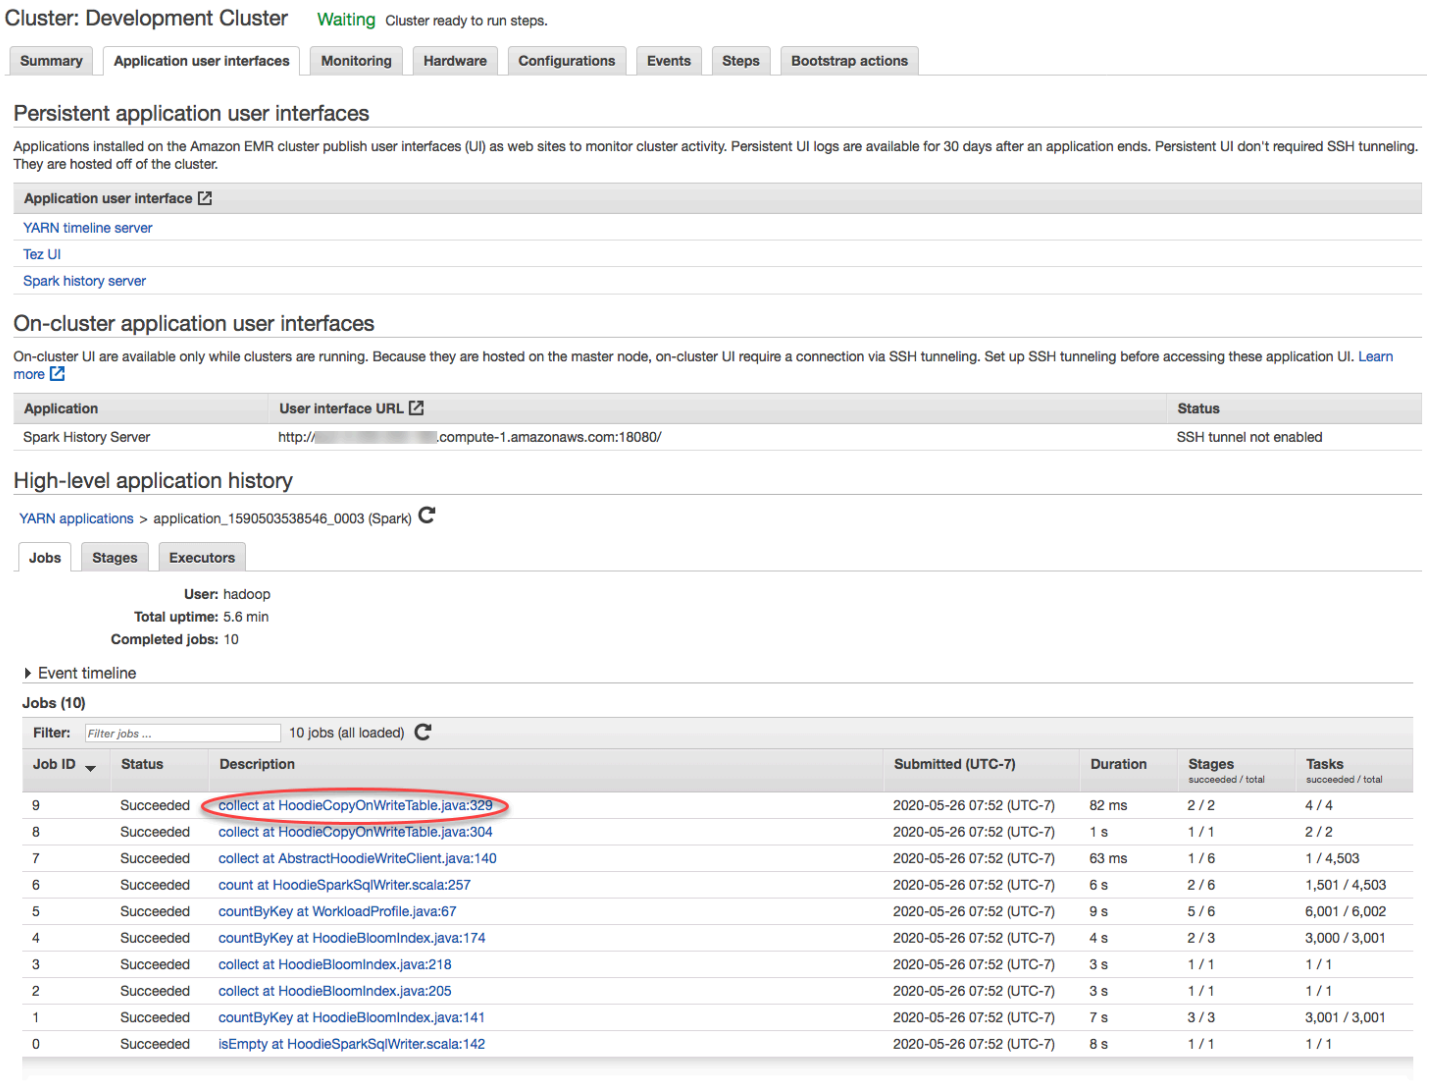

Auf der Seite der Auftragsdetails können Sie Informationen zu einzelnen Auftragsphasen erweitern und dann auf den Link Beschreibung klicken, um die Phasendetails anzuzeigen.

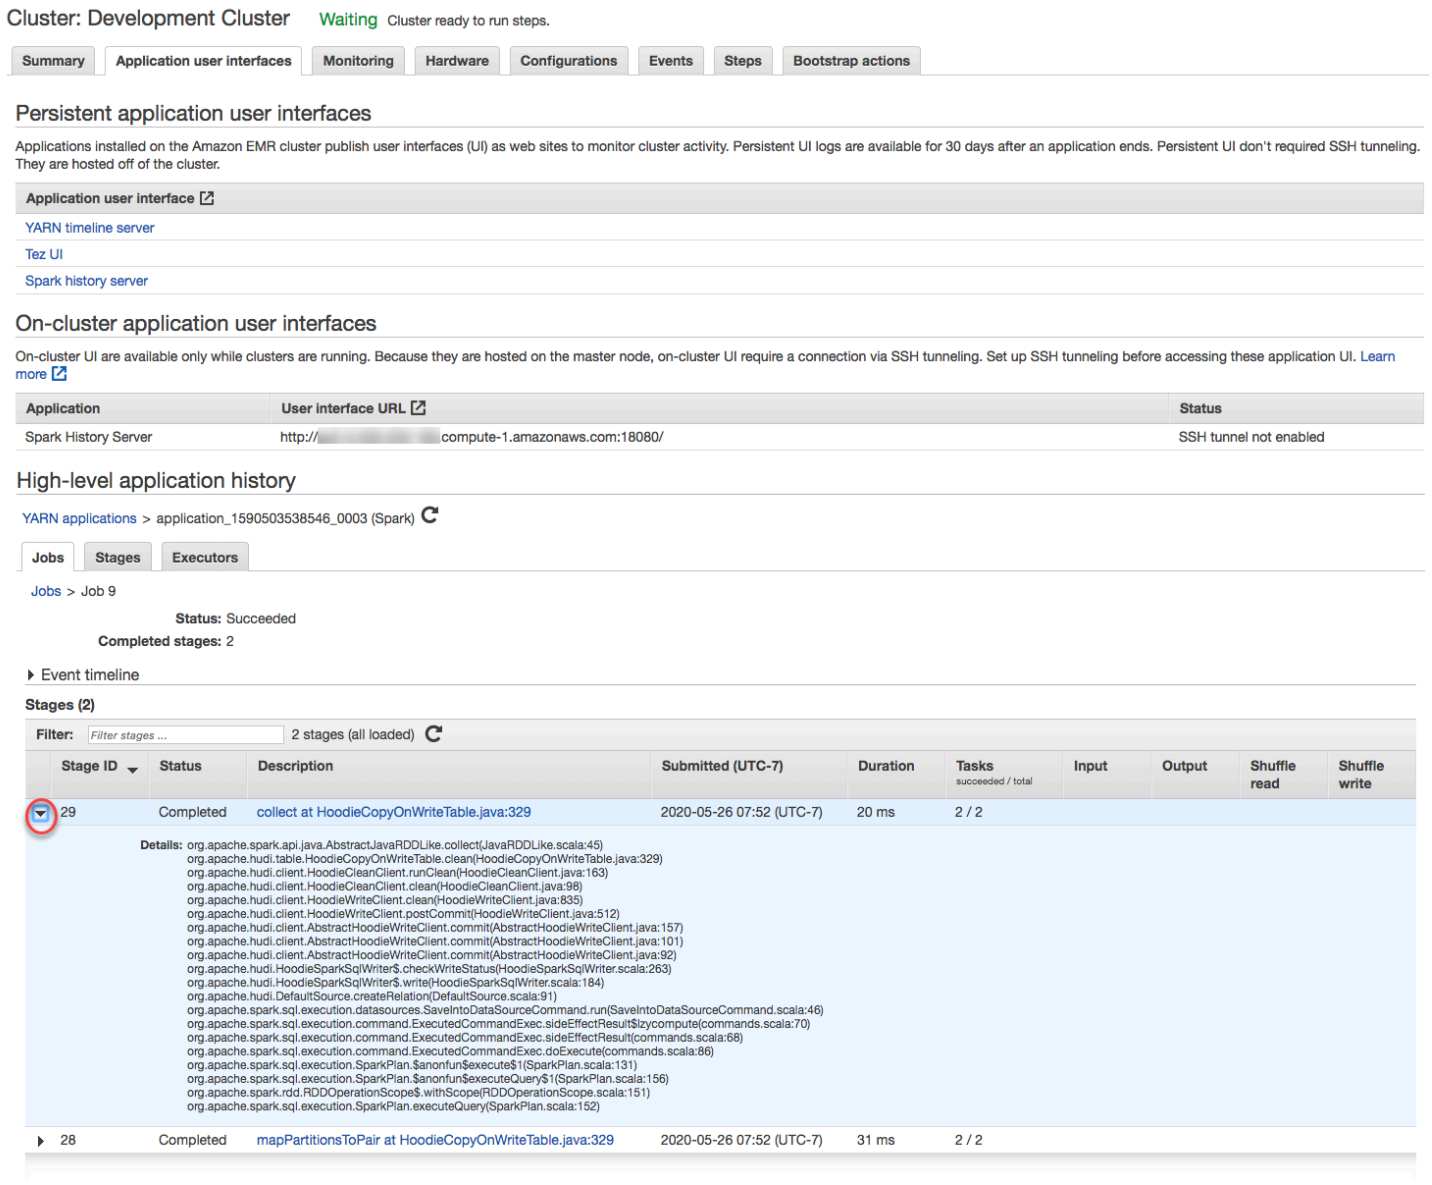

Auf der Seite mit den Phasendetails können Sie die wichtigsten Kennzahlen für die Aufgaben und Ausführenden der Phase einsehen. Sie können Aufgaben- und Ausführungsprotokolle auch über die Links Protokolle anzeigen ansehen.

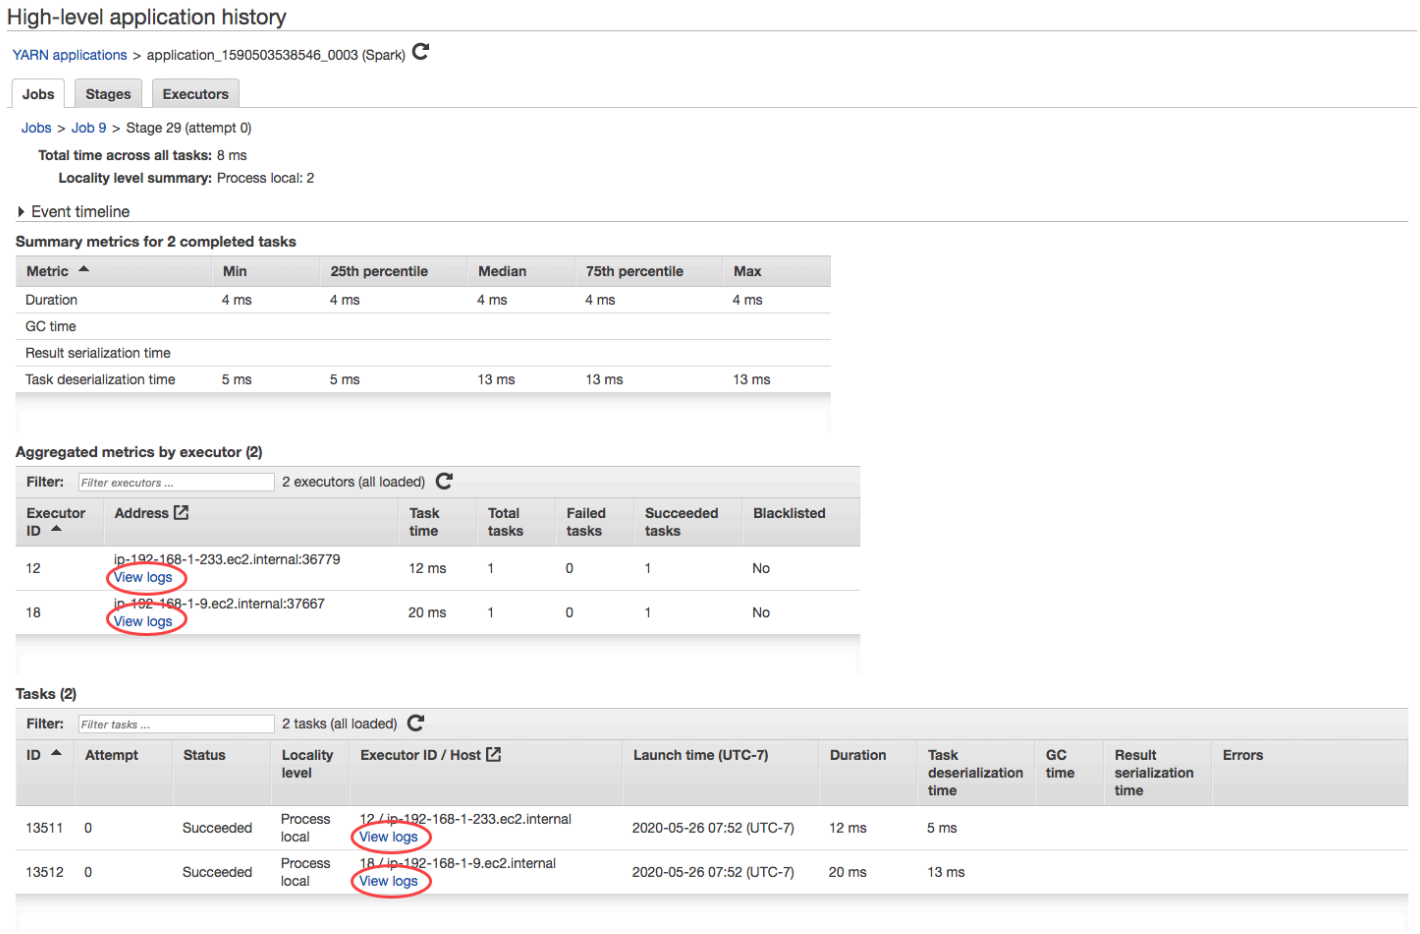

Anzeige von -Protokolldateien

Sowohl Amazon EMR als auch Hadoop erstellen Protokolldateien, die Aufschluss über den jeweiligen Status des Clusters geben. Standardmäßig werden diese Dateien im Primärknoten im `/mnt/var/log/`-Verzeichnis gespeichert. Abhängig von der Konfiguration Ihres Clusters beim Start können diese Protokolle auch in Amazon S3 archiviert und über das grafische Debugging-Tool angezeigt werden.

Es gibt viele Arten von Protokollen, die auf dem Primärknoten gespeichert werden. Amazon EMR schreibt Schritt- und Bootstrap-Aktions- und Instance-Status-Protokolle. Apache Hadoop erstellt Protokolle mit Daten zur Verarbeitung von Aufträgen, Aufgaben und versuchten Aufgaben. Hadoop protokolliert außerdem Protokolle seiner Daemons. Weitere Informationen zu den von Hadoop erstellten Protokollen finden Sie unter http://hadoop.apache.org/docs/stable/hadoop-project-dist/hadoop-common/ClusterSetup.html.

Protokolldateien auf dem Primärknoten anzeigen

Die folgende Tabelle listet einige der Protokolldateien auf, die auf dem Primärknoten zu finden sind.

Ort	Beschreibung
/emr/instance-controller/log/bootstrap-actions	Protokolle, die bei der Verarbeitung von Bootstrap-Aktionen geschrieben werden.
/mnt/var/log/hadoop-state-pusher	Protokolle, die vom Hadoop-Status-Push-Prozess geschrieben werden.
/emr/instance-controller/log	Instance-Controller-Protokolle.
/emr/instance-state	instance-Statusprotokolle. Diese enthalten Informationen über die CPU, den Arbeitsspeicher und Garbage Collector-Threads des Knotens.
/emr/service-nanny	Protokolle, die vom Service-Nanny-Prozess geschrieben werden.
/mnt/var/log/*Anwendung*	Protokolle, die sich auf eine bestimmte Anwendung beziehen, wie z. B. Hadoop, Spark oder Hive.
/mnt/var/log/hadoop/steps/*N*	Schrittprotokolle, die Informationen über die Verarbeitung des Schritts enthalten. Der Wert *N* gibt den von Amazon EMR zugewiesenen stepId-Wert an. Beispiel: Ein Cluster verfügt über zwei Schritte: `s-1234ABCDEFGH` und `s-5678IJKLMNOP`. Der erste Schritt befindet sich in `/mnt/var/log/hadoop/steps/s-1234ABCDEFGH/` und der zweite in `/mnt/var/log/hadoop/steps/s-5678IJKLMNOP/`. Die von Amazon EMR geschriebenen Schrittprotokolle lauten wie folgt.

Ort	Beschreibung
	• controller – Informationen zur Verarbeitung des Schritts. Wenn Ihr Schritt beim Laden fehlschlägt, finden Sie den Stack-Trace in diesem Protokoll. • syslog – Beschreibt die Ausführung von Hadoop-Jobs in diesem Schritt. • stderr – Der Standardfehlerkanal von Hadoop bei der Verarbeitung des Schritts. • stdout – Der Standardausgabekanal von Hadoop während der Verarbeitung des Schritts.

So zeigen Sie Protokolldateien auf dem Primärknoten mit dem AWS CLI an.

1. Verwenden Sie SSH für die Verbindung mit dem Primärknoten wie in Mit dem Primärknoten über SSH verbinden beschrieben.
2. Navigieren Sie zu dem Verzeichnis mit den Protokolldateiinformationen, die Sie anzeigen möchten. Die oben stehenden Tabelle gibt eine Liste der verfügbaren Protokolldateien mit dem entsprechenden Speicherort an. Das folgende Beispiel zeigt den Befehl für die Navigation zum Schrittprotokoll mit einer ID, `s-1234ABCDEFGH`.

   ```
   cd /mnt/var/log/hadoop/steps/s-1234ABCDEFGH/
   ```

3. Verwenden Sie einen Datei-Viewer Ihrer Wahl, um die Protokolldatei anzuzeigen. Im folgenden Beispiel wird der Linux-Befehl `less` verwendet, um die Protokolldatei `controller` anzuzeigen.

   ```
   less controller
   ```

In Amazon S3 archivierte Protokolldateien anzeigen

Standardmäßig archivieren mit der Konsole gestartete Amazon-EMR-Cluster Protokolldateien in Amazon S3 automatisch. Sie können einen eigenen Protokollpfad angeben, und zulassen, dass die Konsole automatisch einen Protokollpfad generiert. Für Cluster, die mit der CLI oder API gestartet wurden, müssen Sie die Archivierung des Amazon-S3-Protokolls manuell konfigurieren.

Wenn Amazon EMR so konfiguriert ist, dass Protokolldateien in Amazon S3 archiviert werden, werden die Dateien an dem von Ihnen angegebenen S3-Speicherort im Ordner /*cluster-id*/ abgelegt, wobei *cluster-id* die Cluster-ID ist.

Die folgende Tabelle listet einige der Protokolldateien auf, die in Amazon S3 zu finden sind.

Ort	Beschreibung
/*cluster-id* /node/	Knotenprotokolle, einschließlich Bootstrap -Aktion, Instance-Status und Anwendung sprotokollen für den Knoten. Die Protokolle für jeden Knoten werden in einem Ordner mit der Bezeichnung der Kennung der EC2 Instance dieses Knotens gespeichert.
/*cluster-id* /node/*instance-id* /*application*	Die Protokolle, die von einzelnen Anwendung en oder Daemons, die einer Anwendung zugeordnet sind, erstellt wurden. Das Hive-Server-Protokoll befindet sich beispielsweise im Verzeichnis *cluster-id* /node/*instance-id* /hive/hive-server.log .
/*cluster-id* /steps/*step-id*/	Schrittprotokolle, die Informationen über die Verarbeitung des Schritts enthalten. Der Wert *step-id* gibt den von Amazon EMR zugewiesenen Schritt–ID-Wert an. Beispiel: Ein Cluster verfügt über zwei Schritte: s-1234ABC DEFGH und s-5678IJKLMNOP . Der erste Schritt befindet sich in /mnt/var/log/ hadoop/steps/s-1234ABCDEFGH/ und der zweite in /mnt/var/log/hadoop/ steps/s-5678IJKLMNOP/ . Die von Amazon EMR geschriebenen Schrittpr otokolle lauten wie folgt. • controller – Informationen zur Verarbeitung des Schritts. Wenn Ihr Schritt beim Laden

Ort	Beschreibung
	fehlschlägt, finden Sie den Stack-Trace in diesem Protokoll. • syslog – Beschreibt die Ausführung von Hadoop-Jobs in diesem Schritt. • stderr – Der Standardfehlerkanal von Hadoop bei der Verarbeitung des Schritts. • stdout – Der Standardausgabekanal von Hadoop während der Verarbeitung des Schritts.
/*cluster-id* /containers	Anwendungscontainerprotokolle. Die Protokolle für jede YARN-Anwendung werden an diesen Speicherorten abgelegt.
/*cluster-id* /hadoop-mapreduce/	Die Protokolle, die Informationen zu Konfigurationsdetails und Auftragsverlauf von MapReduce-Aufträgen enthalten.

So zeigen Sie Protokolldateien an, die mit der Amazon-S3-Konsole in Amazon S3 archiviert wurden

1. Melden Sie sich bei der AWS Management Console an und öffnen Sie die Amazon-S3-Konsole unter https://console.aws.amazon.com/s3/.
2. Öffnen Sie den S3-Bucket, den Sie angegeben haben, als Sie den Cluster für die Archivierung von Protokolldateien in Amazon S3 konfiguriert haben.
3. Navigieren Sie zu der Protokolldatei, die die Informationen enthält, die angezeigt werden sollen. Die oben stehenden Tabelle gibt eine Liste der verfügbaren Protokolldateien mit dem entsprechenden Speicherort an.
4. Laden Sie das Protokolldateiobjekt herunter, um es anzuzeigen. Anweisungen finden Sie unter Objekt herunterladen.

Protokolldateien im Debugging-Tool anzeigen

Amazon EMR aktiviert das Debugging-Tool nicht automatisch. Sie müssen diese Funktion beim Starten des Clusters konfigurieren. Beachten Sie, dass die neue Amazon-EMR-Konsole das Debugging-Tool nicht bietet.

So zeigen Sie Cluster-Protokolle mit der alten Konsole an

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie auf der Seite Cluster-Liste das Detailsymbol neben dem Cluster aus, den Sie anzeigen möchten.

   Dadurch wird die Cluster-Detailseite geöffnet. Im Abschnitt Schritte werden in den Links rechts neben jedem Schritt die verschiedenen Protokolltypen angezeigt, die für den Schritt verfügbar sind. Diese Protokolle werden von Amazon EMR generiert.
3. Um eine Liste der mit einem bestimmten Schritt verknüpften Hadoop-Aufträge anzuzeigen, klicken Sie rechts neben dem Schritt auf den Link Aufträge anzeigen.
4. Um eine Liste der mit einem bestimmten Auftrag verknüpften Hadoop-Aufgaben anzuzeigen, klicken Sie rechts neben dem Job auf den Link Aufgaben anzeigen.
5. Um eine Liste der Versuche anzuzeigen, die eine bestimmte Aufgabe ausgeführt hat, während sie versucht hat, sie abzuschließen, klicken Sie auf den Link Versuche anzeigen rechts neben der Aufgabe.
6. Um die bei einem Task-Versuch generierten Protokolle anzuzeigen, wählen Sie die Links stderr, stdout und syslog, die sich rechts neben dem Aufgabenversuch befinden.

Das Debugging-Tool zeigt Links zu den Protokolldateien an, nachdem Amazon EMR die Protokolldateien in Ihren Bucket in Amazon S3 hochgeladen hat. Da Protokolldateien in Amazon S3 alle 5 Minuten hochgeladen werden, kann es einige Minuten dauern, bis das Hochladen der Protokolldatei abgeschlossen ist, nachdem der Schritt abgeschlossen wurde.

Amazon EMR aktualisiert regelmäßig den Status von Hadoop-Aufträgen, Aufgaben und versuchten Aufgaben im Debugging-Tool. Sie können auf Refresh List (Liste aktualisieren) in den Debugging-Bereichen klicken, um den aktuellen Status dieser Elemente abzurufen.

Anzeigen von Cluster-Instances in Amazon EC2

Um Ihnen bei der Verwaltung Ihrer Ressourcen zu unterstützen, ermöglicht Amazon EC2 es Ihnen, Ihren Ressourcen Metadaten in Form von Tags zuzuweisen. Jedes Amazon EC2-Tag besteht aus einem Schlüssel und einem Wert. Mit Tags können Sie Ihre Amazon EC2-Ressourcen auf unterschiedliche Weise kategorisieren: beispielsweise nach Zweck, Eigentümer oder Umgebung.

Sie können die Ressourcen auf Grundlage der Tags suchen und filtern. Die Tags, die Sie Ressourcen über Ihr AWS-Konto zuweisen, stehen nur Ihnen zur Verfügung. Andere Konten, die dieselbe Ressource nutzen, können Ihre Tags nicht sehen.

Amazon EMR kennzeichnet automatisch jede EC2-Instance, die es startet, mit Schlüssel-Wert-Paaren. Die Schlüssel identifizieren den Cluster und die Instance-Gruppe, zu der die Instance gehört. Dies erleichtert das Filtern Ihrer EC2-Instances, um beispielsweise nur die Instances anzuzeigen, die zu einem bestimmten Cluster gehören, oder alle aktuell ausgeführten Instances in der Instance-Gruppe für die Aufgabe anzuzeigen. Dies ist besonders nützlich, wenn Sie mehrere Cluster gleichzeitig betreiben oder eine große Anzahl von EC2-Instances verwalten.

Dies sind die vordefinierten Schlüssel-Wert-Paare, die Amazon EMR zuordnet:

Schlüssel	Value (Wert)	Wert-Definition
aws:elasticmapreduce:job-flow-id	*job-flow-identifier*	Die ID des Clusters, für den die Instance bereitgestellt wird. Es wird im folgenden Format `j-XXXXXXXXXXXXX` angezeigt und kann bis zu 256 Zeichen lang sein.
aws:elasticmapreduce:instance-group-role	*group-role*	Der Typ der Instance-Gruppe, eingegeben als einer der folgenden Werte: `master`, `core` oder `task`.

Sie können das Anzeigen und Filtern anhand der Tags ausführen, die Amazon EMR hinzufügt. Weitere Informationen dazu finden Sie unter Verwenden von Tags im Amazon-EC2-Benutzerhandbuch für Linux-Instances. Da es sich bei den Tags von Amazon EMR um System-Tags handelt, können sie weder bearbeitet oder gelöscht werden. Aus diesem Grund sind die Abschnitte zum Anzeigen und Filtern von Tags am wichtigsten.

> **Note**
>
> Amazon EMR fügt der EC2-Instance dann Tags hinzu, wenn ihr Status auf In Ausführung aktualisiert wird. Wenn zwischen dem Zeitpunkt, an dem die EC2-Instance bereitgestellt wird, und dem Zeitpunkt, an dem ihr Status auf In Ausführung gesetzt wird, Latenz auftritt, werden die von Amazon EMR festgelegten Tags angezeigt, sobald die Instance gestartet wird. Wenn keine Tags angezeigt werden, warten Sie einige Minuten und aktualisieren Sie die Ansicht.

CloudWatch-Ereignisse und Metriken

Verwenden Sie Ereignisse und Metriken, um die Aktivität und den Zustand eines Amazon-EMR-Clusters zu verfolgen. Ereignisse sind nützlich zur Überwachung bestimmter Vorgänge in einem Cluster, beispielsweise wenn sich der Zustand eines Clusters vom Starten zum Ausführen ändert. Metriken sind nützlich, um einen bestimmten Wert zu überwachen – beispielsweise den Prozentsatz des verfügbaren Speicherplatzes, den HDFS innerhalb eines Clusters verwendet.

Weitere Informationen über CloudWatch Events finden Sie im Amazon-CloudWatch-Events-Benutzerhandbuch. Weitere Informationen zu CloudWatch-Metriken finden Sie unter Verwenden von Amazon-CloudWatch-Metriken und Erstellen von Amazon CloudWatch-Alarmen im Amazon-CloudWatch-Benutzerhandbuch.

Themen

- Überwachung von Amazon-EMR-Metriken mit CloudWatch
- Überwachung von Amazon-EMR-Ereignissen mit CloudWatch
- Reagieren auf CloudWatch-Ereignisse

Überwachung von Amazon-EMR-Metriken mit CloudWatch

Metriken werden alle fünf Minuten aktualisiert, automatisch gesammelt und mithilfe von Push an CloudWatch übertragen, um an jeden Amazon-EMR-Cluster verteilt zu werden. Dieses Intervall kann nicht konfiguriert werden. Für Amazon-EMR-Metriken, die über CloudWatch gemeldet werden, fallen keine Gebühren an. Diese fünfminütigen Datenpunktmetriken werden 63 Tage lang archiviert. Danach werden die Daten verworfen.

Wie verwende ich die Amazon-EMR-Metriken?

Die folgende Tabelle zeigt die häufigsten Verwendungen von Metriken, die von Amazon EMR gemeldet werden. Es handelt sich dabei um Vorschläge für den Einstieg und nicht um eine umfassende Liste. Eine Liste der gesamten Metriken, die von Amazon EMR gemeldet werden, finden Sie unter Von Amazon EMR in CloudWatch gemeldete Metriken.

Wie gehe ich vor?	Relevante Metriken
Verfolgen des Cluster-Fortschritts	Sehen Sie sich die Metriken `RunningMapTasks` , `RemainingMapTasks` , `RunningReduceTasks` und `RemainingReduceTasks` an.
Erkennen von Clustern im Leerlauf	Die `IsIdle`-Metrik verfolgt, ob ein Cluster verfügbar ist, aber aktuell keine Aufgaben ausführt. Sie können einen Alarm einrichten, wenn sich der Cluster für einen bestimmten Zeitraum im Leerlauf befunden hat z. B. 30 Minuten.
Erkennen, wenn ein Knoten zu wenig Speicherplatz hat	Die `MRUnhealthyNodes` -Metrik verfolgt, wann einem oder mehreren Core- oder Aufgabenknoten der lokale Festplattenspeicher ausgeht und sie in einen `UNHEALTHY` -YARN-Status übergehen. Zum Beispiel haben Core- oder Aufgabenknoten nur noch wenig Speicherplatz zur Verfügung und sie können keine Aufgaben ausführen.
Erkennen, wenn ein Cluster zu wenig Speicherplatz hat	Die `HDFSUtilization` -Metrik überwacht die kombinierte HDFS-Kapazität des Clusters und kann eine Größenänderung des Clusters erfordern, um weitere Core-Knoten hinzuzufügen. Beispielsweise ist die HDFS-Auslastung hoch, was sich auf Aufträge und den Zustand des Clusters auswirken kann.

Wie gehe ich vor?	Relevante Metriken
Erkennt, wenn ein Cluster mit reduzierter Kapazität läuft	Die `MRLostNodes` -Metrik verfolgt, wann ein oder mehrere Core- oder Aufgabenknoten nicht mit dem Hauptknoten kommunizieren können. Beispielsweise ist der Core- oder Aufgabenk noten für den Hauptknoten nicht erreichbar.

Weitere Informationen finden Sie unter Cluster wird mit NO_SLAVE_LEFT und Core-Knoten mit FAILED_BY_MASTER beendet und AWSSupport-AnalyzeEMRLogs.

Für Amazon-CloudWatch-Metriken für Amazon EMR zugreifen

Sie können die Metriken, die Amazon EMR an CloudWatch meldet, über die Amazon-EMR-Konsole oder die CloudWatch-Konsole anzeigen. Sie können Metriken auch mit dem CloudWatch-CLI-Befehl `mon-get-stats` oder der CloudWatch-API `GetMetricStatistics` abrufen. Weitere Informationen zum Anzeigen oder Abrufen von Metriken für Amazon EMR mit CloudWatch finden Sie im Amazon-CloudWatch-Benutzerhandbuch.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So zeigen Sie Metriken in der neuen Konsole an

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, für den Sie die Metriken anzeigen möchten. Dadurch wird die Cluster-Detailseite geöffnet.
3. Wählen Sie auf der Cluster-Detailseite die Registerkarte Überwachung aus. Wählen Sie eine der Optionen Clusterstatus, Knotenstatus oder Ein- und Ausgaben aus, um die Berichte über den Fortschritt und den Zustand des Clusters zu laden.

4. Nachdem Sie eine Metrik zur Anzeige ausgewählt haben, können Sie jedes Diagramm vergrößern. Um den Zeitrahmen Ihres Diagramms zu filtern, wählen Sie eine vorausgefüllte Option oder wählen Sie Benutzerdefiniert.

Old console

So zeigen Sie Metriken in der alten Konsole an

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/.
2. Um die Metriken für einen Cluster anzuzeigen, wählen Sie einen Cluster aus, sodass der Bereich Summary (Übersicht) angezeigt wird.
3. Wählen Sie Monitoring (Überwachung) aus, um Informationen zu diesem Cluster anzuzeigen. Wählen Sie eine der Registerkarten mit den Namen Clusterstatus, Zuordnen/Reduzieren, Knotenstatus oder EA, um die Berichte über den Fortschritt und den Zustand des Clusters zu laden.
4. Nachdem Sie die gewünschte Metrik ausgewählt haben, können Sie ein Diagramm auswählen. Bearbeiten Sie die Felder Start und End (Ende), um die Metriken auf einen bestimmbaren Zeitrahmen zu filtern.

Von Amazon EMR in CloudWatch gemeldete Metriken

Die folgenden Tabellen listen alle Metriken auf, die Amazon EMR in der Konsole meldet und per Push an CloudWatch überträgt.

Amazon-EMR-Metriken

Amazon EMR sendet Daten für verschiedene Metriken an CloudWatch. Alle Amazon-EMR-Cluster senden automatisch Metriken in Intervallen von fünf Minuten. Die Metriken werden für zwei Wochen archiviert. Nach Ablauf dieses Zeitraums werden die Daten verworfen.

Der `AWS/ElasticMapReduce`-Namespace enthält die folgenden Metriken.

> **Note**
>
> Amazon EMR ruft Metriken aus einem Cluster ab. Wenn die Verbindung zu einem Cluster verloren geht, werden keine Metriken gemeldet, bis der Cluster wieder verfügbar ist.

Die folgenden Metriken sind für Cluster mit Hadoop 2.x -Versionen verfügbar.

Metrik	Beschreibung
Cluster-Status	
IsIdle	Gibt an, dass ein Cluster keine Arbeiten mehr ausführt, aber unverändert aktiv ist und Kosten verursacht. Der Wert beträgt 1, wenn weder Tasks noch Aufträge ausgeführt werden, andernfalls beträgt der Wert 0. Dieser Wert wird in 5-Minuten-Intervallen geprüft. Wenn der Wert 1 beträgt, bedeutet dies, dass der Cluster zum Zeitpunkt der Prüfung ungenutzt war, aber nicht die gesamten fünf Minuten. Um Falschmeldungen zu vermeiden, sollten Sie einen Alarm auslösen, wenn dieser Wert in mehreren aufeinand er folgenden 5-Minuten-Prüfungen 1 beträgt. Sie können zum Beispiel einen Alarm auslösen, wenn dieser Wert 30 Minuten oder länger 1 beträgt. Anwendungsfall: Cluster-Leistung überwachen Einheiten: boolescher Wert
ContainerAllocated	Anzahl der vom ResourceManager zugeordneten Ressourcen-Container. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
ContainerReserved	Anzahl der reservierten Container. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
ContainerPending	Anzahl der Container in der Warteschlange, die noch nicht zugeordnet worden sind. Anwendungsfall: Cluster-Fortschritt überwachen

Metrik	Beschreibung
	Einheiten: Anzahl
ContainerPendingRatio	Verhältnis von ausstehenden Containern zu zugeordneten Containern (ContainerPendingRatio = ContainerPending / ContainerAllocated). Wenn ContainerAllocated = 0, dann ContainerPendingRatio = ContainerPending. Der Wert von ContainerPendingRatio ist eine Zahl, kein Prozentsatz. Dieser Wert ist zum Skalieren von Cluster-Ressourcen anhand des Zuordnungsverhaltens des Containers hilfreich. Einheiten: Anzahl
AppsCompleted	Anzahl der an YARN übermittelten abgeschlossenen Anwendungen. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
AppsFailed	Anzahl der an YARN übermittelten Anwendungen, deren Abschluss fehlgeschlagen ist. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl
AppsKilled	Anzahl der an YARN übermittelten Anwendungen, die beendet worden sind. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl

Metrik	Beschreibung
AppsPending	Anzahl der an YARN übermittelten Anwendungen, die sich im ausstehenden Zustand befinden. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
AppsRunning	Anzahl der an YARN übermittelten Anwendungen, die ausgeführt werden. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
AppsSubmitted	Anzahl der an YARN übermittelten Anwendungen. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
Knotenstatus	
CoreNodesRunning	Anzahl der arbeitenden Core-Knoten. Die Datenpunkte dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl

Metrik	Beschreibung
CoreNodesPending	Anzahl der Core-Knoten, die auf eine Zuordnung warten. Es müssen nicht alle angeforderten Core-Knoten sofort verfügbar sein. Diese Metrik gibt die ausstehenden Anforderungen an. Die Datenpunkte dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
LiveDataNodes	Prozentsatz der Datenknoten, die Arbeit von Hadoop empfangen. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Prozent
MRTotalNodes	Anzahl der Knoten, die gegenwärtig für MapReduce-Aufträge verfügbar sind. Entspricht der YARN-Metrik `mapred.resourcemanager.TotalNodes` . Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
MRActiveNodes	Anzahl der Knoten, die gegenwärtig MapReduce-Tasks oder -Aufträge ausführen. Entspricht der YARN-Metrik `mapred.resourcemanager.NoOfActiveNodes` . Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
MRLostNodes	Anzahl der MapReduce zugeordneten Knoten, die mit dem Zustand "LOST" gekennzeichnet worden sind. Entspricht der YARN-Metrik `mapred.resourcemanager.NoOf LostNodes` . Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Z ustand überwachen Einheiten: Anzahl
MRUnhealthyNodes	Anzahl der MapReduce-Aufträgen zur Verfügung stehenden Knoten, die mit dem Zustand "UNHEALTHY" gekennzei chnet sind. Entspricht der YARN-Metrik `mapred.re sourcemanager.NoOfUnhealthyNodes` . Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
MRDecommissionedNodes	Anzahl der MapReduce-Anwendungen zugeordneten Knoten, die mit dem Zustand "DECOMISSIONED" gekennzeichnet worden sind. Entspricht der YARN-Metr ik `mapred.resourcemanager.NoOfDecommiss ionedNodes` . Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Z ustand überwachen Einheiten: Anzahl

Metrik	Beschreibung
MRRebootedNodes	Anzahl der MapReduce zur Verfügung stehenden Knoten, die neu gebootet und mit dem Zustand "REBOOTED" gekennzeichnet worden sind. Entspricht der YARN-Metrik `mapred.resourcemanager.NoOfRebootedNodes` . Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl
MultiMasterInstanceGroupNodesRunning	Die Anzahl der zurzeit ausgeführten Master-Knoten. Anwendungsfall: Überwachen von Ausfall und Ersetzung eines Master-Knotens Einheiten: Anzahl
MultiMasterInstanceGroupNodesRunningPercentage	Der Prozentsatz der zurzeit im Verhältnis zur angeforderten Instance-Zahl für Master-Knoten ausgeführten Master-Knoten. Anwendungsfall: Überwachen von Ausfall und Ersetzung eines Master-Knotens Einheiten: Prozent
MultiMasterInstanceGroupNodesRequested	Die Anzahl der angeforderten Master-Knoten. Anwendungsfall: Überwachen von Ausfall und Ersetzung eines Master-Knotens Einheiten: Anzahl
IO	

Metrik	Beschreibung
S3ByteWritten	Anzahl der auf Amazon S3 geschriebenen Bytes. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-F ortschritt überwachen Einheiten: Anzahl
S3ByteRead	Anzahl der von Amazon S3 gelesenen Bytes. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-F ortschritt überwachen Einheiten: Anzahl
HDFSUtilization	Prozentsatz des gegenwärtig benutzten HDFS-Speichers. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Prozent
HDFSByteRead	Anzahl der von HDFS gelesenen Byte. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-F ortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
HDFSByteWritten	Anzahl der auf HDFS geschriebenen Byte. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-Fortschritt überwachen Einheiten: Anzahl
MissingBlocks	Anzahl der Blöcke, in denen HDFS keine Replicas hat. Hierbei kann es sich um beschädigte Blöcke handeln. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
CorruptBlocks	Anzahl der Blöcke, die von HDFS als beschädigt angegeben werden. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
TotalLoad	Gesamtanzahl der gleichzeitigen Datenübertragungen. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
MemoryTotalMB	Gesamtgröße des Speichers im Cluster. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
MemoryReservedMB	Größe des reservierten Speichers. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
MemoryAvailableMB	Verfügbarer zuzuordnender Speicher. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
YARNMemoryAvailablePercentage	Prozentsatz des für YARN verbleibenden verfügbaren Speichers (YARNMemoryAvailablePercentage = MemoryAvailableMB / MemoryTotalMB). Dieser Wert ist zum Skalieren von Cluster-Ressourcen anhand der YARN-Speichernutzung hilfreich. Einheiten: Prozent
MemoryAllocatedMB	Menge des dem Cluster zugeordneten Speichers. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
PendingDeletionBlocks	Anzahl der zum Löschen gekennzeichneten Blöcke. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl
UnderReplicatedBlocks	Anzahl der Blöcke, die nochmals repliziert werden müssen. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl

Metrik	Beschreibung
DfsPendingReplicationBlocks	Status der Blockreplikation: replizierte Blöcke, Alter der Replikationsanforderung und nicht erfolgreiche Replikationsanforderungen. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl
CapacityRemainingGB	Gesamtbetrag der verbleibenden HDFS-Festplattenkapazität. Anwendungsfall: Cluster-Fortschritt überwachen, Cluster-Zustand überwachen Einheiten: Anzahl

Nachfolgend sind die Hadoop 1-Metriken aufgeführt:

Metrik	Beschreibung
Cluster-Status	
IsIdle	Gibt an, dass ein Cluster keine Arbeiten mehr ausführt, aber unverändert aktiv ist und Kosten verursacht. Der Wert beträgt 1, wenn weder Tasks noch Aufträge ausgeführt werden, andernfalls beträgt der Wert 0. Dieser Wert wird in 5-Minuten-Intervallen geprüft. Wenn der Wert 1 beträgt, bedeutet dies, dass der Cluster zum Zeitpunkt der Prüfung ungenutzt war, aber nicht die gesamten fünf Minuten. Um Falschmeldungen zu vermeiden, sollten Sie einen Alarm auslösen, wenn dieser Wert in mehreren aufeinander folgenden 5-Minuten-Prüfungen 1 beträgt. Sie können zum Beispiel einen Alarm auslösen, wenn dieser Wert 30 Minuten oder länger 1 beträgt.

Metrik	Beschreibung
	Anwendungsfall: Cluster-Leistung überwachen Einheiten: boolescher Wert
JobsRunning	Anzahl der Aufträge im Cluster, die gegenwärtig ausgeführt werden. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
JobsFailed	Anzahl der fehlgeschlagenen Aufträge im Cluster. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
Map/Reduce	
MapTasksRunning	Anzahl der Map-Tasks für jeden Auftrag. Wenn Sie einen Scheduler installiert haben und mehrere Aufträge ausführen, werden mehrere Grafiken erstellt. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
MapTasksRemaining	Anzahl der verbleibenden Map-Tasks für jeden Auftrag. Wenn Sie einen Scheduler installiert haben und mehrere Aufträge ausführen, werden mehrere Grafiken erstellt. Eine verbleibende Map-Task ist eine Task, die sich in keinem der folgenden Zustände befindet: Running, Killed oder Completed. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
MapSlotsOpen	Ungenutzte Kapazität für Map-Tasks. Dies wird als die maximale Anzahl von Map-Tasks für einen bestimmte n Cluster abzüglich der Gesamtanzahl der gegenwärtig ausgeführten Map-Tasks in diesem Cluster berechnet. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Anzahl
RemainingMapTasksPerSlot	Das Verhältnis der insgesamt verbleibenden Map-Tasks , bezogen auf die insgesamt verfügbaren Map-Slots im Cluster. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Verhältnis
ReduceTasksRunning	Anzahl der laufenden Reduce-Tasks für jeden Auftrag. Wenn Sie einen Scheduler installiert haben und mehrere Aufträge ausführen, werden mehrere Grafiken erstellt. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
ReduceTasksRemaining	Anzahl der verbleibenden Reduce-Tasks für jeden Auftrag. Wenn Sie einen Scheduler installiert haben und mehrere Aufträge ausführen, werden mehrere Grafiken erstellt. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
ReduceSlotsOpen	Ungenutzte Kapazität für Reduce-Tasks. Dies wird als die maximale Anzahl von Reduce-Tasks für einen bestimmte n Cluster abzüglich der Gesamtanzahl der gegenwärtig ausgeführten Reduce-Tasks in diesem Cluster berechnet. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Anzahl
Knotenstatus	
CoreNodesRunning	Anzahl der arbeitenden Core-Knoten. Die Datenpunk te dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
CoreNodesPending	Anzahl der Core-Knoten, die auf eine Zuordnung warten. Es müssen nicht alle angeforderten Core-Knoten sofort verfügbar sein. Diese Metrik gibt die ausstehenden Anforderungen an. Die Datenpunkte dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
LiveDataNodes	Prozentsatz der Datenknoten, die Arbeit von Hadoop empfangen. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Prozent

Metrik	Beschreibung
TaskNodesRunning	Anzahl der arbeitenden Aufgabenknoten. Die Datenpunkte dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
TaskNodesPending	Anzahl der Aufgabenknoten, die auf eine Zuordnung warten. Es müssen nicht alle angeforderten Aufgabenknoten sofort verfügbar sein. Diese Metrik gibt die ausstehenden Anforderungen an. Die Datenpunkte dieser Metrik werden nur dann angegeben, wenn die zugehörige Instance-Gruppe existiert. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl
LiveTaskTrackers	Prozentsatz der funktionierenden Task-Tracker. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Prozent
IO	
S3ByteWritten	Anzahl der auf Amazon S3 geschriebenen Bytes. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
S3ByteRead	Anzahl der von Amazon S3 gelesenen Bytes. Mit dieser Metrik werden nur MapReduce-Aufträge aggregiert und sie gilt nicht für andere Workloads unter Amazon EMR. Anwendungsfall: Cluster-Leistung analysieren, Cluster-Fortschritt überwachen Einheiten: Anzahl
HDFSUtilization	Prozentsatz des gegenwärtig benutzten HDFS-Speichers. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Prozent
HDFSByteRead	Anzahl der von HDFS gelesenen Byte. Anwendungsfall: Cluster-Leistung analysieren, Cluster-Fortschritt überwachen Einheiten: Anzahl
HDFSByteWritten	Anzahl der auf HDFS geschriebenen Byte. Anwendungsfall: Cluster-Leistung analysieren, Cluster-Fortschritt überwachen Einheiten: Anzahl
MissingBlocks	Anzahl der Blöcke, in denen HDFS keine Replicas hat. Hierbei kann es sich um beschädigte Blöcke handeln. Anwendungsfall: Cluster-Zustand überwachen Einheiten: Anzahl

Metrik	Beschreibung
TotalLoad	Die aktuelle Gesamtzahl an Lesern und Schreibern, die von allen DataNodes in einem Cluster gemeldet werden. Anwendungsfall: Diagnose des Grads, in dem ein hoher E/A-Wert zu einer schlechten Leistung bei der Job-Ausführung beitragen könnte. Worker-Knoten, die den DataNode-Daemon ausführen, müssen auch Zuordnung s- und Reduzierungsaufgaben ausführen. Dauerhaft hohe TotalLoad-Werte können darauf hinweisen, dass ein hoher E/A-Wert einer der Faktoren für eine schlechte Leistung sein könnte. Gelegentliche Spitzen in diesem Wert sind typisch und weisen in der Regel nicht auf ein Problem hin. Einheiten: Anzahl

Cluster-Kapazitätsmetriken

Die folgenden Metriken geben die aktuelle oder Zielkapazitäten eines Clusters an. Diese Metriken sind nur verfügbar, wenn verwaltete Skalierung oder automatische Beendigung aktiviert ist.

Bei Clustern, die aus Instance-Flotten bestehen, werden die Cluster-Kapazitätsmetriken in `Units` gemessen. Bei Clustern, die aus Instance-Gruppen bestehen, werden die Clusterkapazitätsmetriken in `Nodes` oder `VCPU` basierend auf dem Einheitentyp gemessen, der in der Richtlinie für verwaltete Skalierung verwendet wird. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung im Amazon-EMR-Managementhandbuch.

Metrik	Beschreibung
• `TotalUnitsRequested` • `TotalNodesRequested` • `TotalVCPURequested`	Die Gesamtzahl von Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl

Metrik	Beschreibung
• `TotalUnitsRunning` • `TotalNodesRunning` • `TotalVCPURunning`	Die aktuelle Gesamtzahl der Einheiten/Knoten/vCPUs, die in einem ausgeführten Cluster verfügbar sind. Wenn eine Clustergrößenänderung angefordert wird, wird diese Metrik aktualisiert, nachdem die neuen Instances hinzugefügt oder aus dem Cluster entfernt wurden. Einheiten: Anzahl
• `CoreUnitsRequested` • `CoreNodesRequested` • `CoreVCPURequested`	Die Zielnummer der CORE-Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl
• `CoreUnitsRunning` • `CoreNodesRunning` • `CoreVCPURunning`	Die aktuelle Anzahl von CORE-Einheiten/Knoten/vCPUs, die in einem Cluster ausgeführt werden. Einheiten: Anzahl
• `TaskUnitsRequested` • `TaskNodesRequested` • `TaskVCPURequested`	Die Zielnummer der AUFGABEN-Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl

Metrik	Beschreibung
• `TaskUnitsRunning` • `TaskNodesRunning` • `TaskVCPURunning`	Die aktuelle Anzahl von AUFGABEN-Einheiten/Knoten/v CPUs, die in einem Cluster ausgeführt werden. Einheiten: Anzahl

Amazon EMR gibt die folgenden Metriken mit einer Granularität von einer Minute aus, wenn Sie die automatische Kündigung mithilfe einer Richtlinie zur automatischen Kündigung aktivieren. Einige Metriken sind nur für Amazon-EMR-Versionen 6.4.0 und höher verfügbar. Weitere Informationen zur automatischen Beendigung finden Sie unter Verwenden einer Richtlinie zur automatischen Beendigung.

Metrik	Beschreibung
`TotalNotebookKernels`	Die Gesamtzahl der laufenden und inaktiven Notebook-Kernel auf dem Cluster. Diese Metrik ist nur für Amazon-EMR-Version en 6.4.0 und höher verfügbar.
`AutoTerminationIsClusterIdle`	Gibt an, ob der Cluster verwendet wird. Der Wert 0 gibt an, dass der Cluster von einer der folgenden Komponenten aktiv verwendet wird: • Eine YARN-Anwendung • HDFS • Ein Notebook •

Metrik	Beschreibung
	Eine Cluster-Benutzeroberfläche, z. B. der Spark History Server Ein Wert von 1 gibt an, dass sich der Cluster im Leerlauf befindet. Amazon EMR prüft, ob der Cluster kontinuierlich inaktiv ist (`AutoTerminationIsClusterIdle = 1`). Wenn die Leerlaufzeit eines Clusters dem `IdleTimeout` -Wert in Ihrer Richtlinie zur automatischen Kündigung entspricht, beendet Amazon EMR den Cluster.

Dimensionen für Amazon-EMR-Metriken

Die Amazon-EMR-Daten können mithilfe der folgenden Dimensionen in der folgenden Tabelle gefiltert werden.

Dimension	Beschreibung
JobFlowId	Entspricht der Cluster-ID, der eindeutigen Kennung eines Clusters mit dem Format `j-XXXXXXXXXXXXX` . Sie können diesen Wert durch Klicken auf den Cluster in der Amazon-EMR-Konsole anzeigen.

Überwachung von Amazon-EMR-Ereignissen mit CloudWatch

Amazon EMR verfolgt Ereignisse und speichert die Informationen für bis zu sieben Tage. Amazon EMR zeichnet Ereignisse auf, wenn sich der Status von Clustern, Instance-Gruppen, Instance-Flotten, automatischen Skalierungsrichtlinien oder Schritten ändert. Ereignisse erfassen Datum und Uhrzeit des Ereignisses, Details zu den betroffenen Elementen und andere wichtige Datenpunkte.

In der folgenden Tabelle sind Amazon-EMR-Ereignisse aufgeführt, zusammen mit dem Status oder der Statusänderung, die das Ereignis anzeigt, dem Schweregrad des Ereignisses, dem Ereignistyp,

dem Ereigniscode und den Ereignismeldungen. Amazon EMR stellt Ereignisse als JSON-Objekte dar und sendet sie automatisch an einen Event-Stream. Das JSON-Objekt ist wichtig, wenn Sie für die Verarbeitung von Ereignissen Regeln mit CloudWatch Events festlegen, da die Regeln versuchen, den Mustern im JSON-Objekt zu entsprechen. Weitere Informationen finden Sie unter Ereignisse und Ereignismuster sowie Amazon-EMR-Ereignisse im Amazon-CloudWatch-Events-Benutzerhandbuch.

> **Note**
>
> Um sicherzustellen, dass wir Ihnen die relevantesten Informationen zur Verfügung stellen, verfeinern wir unsere Fehlermeldungen kontinuierlich. Aus diesem Grund wird empfohlen, dass Sie den Text der Nachrichten nicht analysieren, um die nächsten Aktionen in Ihrem Workflow einzuleiten.

Cluster-Startereignisse

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`CREATING`	`WARN`	Bereitstellung von Amazon-EMR-Instance-Flotten	EC2-Bereitstellung – Unzureichende Instance-Kapazität	Wir können Ihren Amazon-EMR-Cluster `ClusterId (ClusterName)` für die Instance-Flotte nicht erstellen. `InstanceFleetID` Amazon EC2 hat nicht genügend Spot-Kapazität für den Instance-Typ `[Instancetype1, Instancetype2]` und

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
				nicht genügend On-Demand-Kapazität für den Instance-Typ `[Instancetype3, Instancetype4]` in der Availability Zone `[AvailabilityZone1, AvaliabilityZone2]` . Weitere Informationen darüber, wie Sie auf dieses Ereignis reagieren können, finden Sie in der Dokumentation.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`CREATING`	`WARN`	Bereitstellung von Amazon-EMR-Instance-Gruppen	EC2-Bereitstellung – Unzureichende Instance-Kapazität	Wir können Ihren Amazon-EMR-Cluster `ClusterId (ClusterName)` für die Instance-Gruppe nicht erstellen. `InstanceGroupID` Amazon EC2 hat nicht genügend `[Spot or On-Demand] -` Kapazität für den Instance-Typ `Instancetype` in der Availability Zone `AvailabilityZone`. Weitere Informationen darüber, wie Sie auf dieses Ereignis reagieren können, finden Sie in der Dokumentation.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`STARTING`	`INFO`	Änderung des EMR-Cluster-Zustands	Keine	Der Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde am `Time` angefordert und wird gerade erstellt.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`STARTING`	`INFO`	Änderung des EMR-Cluster-Zustands	Keine	**Note** Gilt nur für Cluster mit der Instance-Flottenkonfiguration und mehreren Availability Zones, die innerhalb Amazon EC2 ausgewählt wurden. Der Amazon-EMR-Cluster `ClusterId (ClusterName)` wird in Zone (`AvailabilityZoneID`) erstellt, die aus den angegebenen Availability-

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
				Zone-Optionen ausgewählt wurde.
`STARTING`	`INFO`	Änderung des EMR-Cluster-Zustands	Keine	Der Amazon-EMR-Cluster `ClusterId (ClusterName)` begann mit der Ausführung von Schritten am `Time`.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`WAITING`	`INFO`	Änderung des EMR-Cluster-Zustands	Keine	Der Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde am `Time` erstellt und ist einsatzbereit. – oder – Der Amazon-EMR-Cluster `ClusterId (ClusterName)` hat die Ausführung aller ausstehenden Schritte unter `Time` abgeschlossen. **Note** Ein Cluster im `WAITING`-Status kann trotzdem Aufträge bearbeiten.

> **Note**
>
> Die Ereignisse mit dem Ereigniscode `EC2 provisioning - Insufficient Instance Capacity` werden regelmäßig ausgelöst, wenn Ihr EMR-Cluster während der Cluster-Erstellung oder Größenänderung auf einen Kapazitätsfehler von Amazon EC2 für Ihre Instance-Flotte oder Instance-Gruppe stößt. Weitere Informationen zum Umgang mit diesen Ereignissen finden Sie unter Reaktion auf Ereignisse mit unzureichender Instance-Kapazität im Amazon-EMR-Cluster.

Cluster-Abbruchsereignisse

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`TERMINATED`	Der Schweregrad ist abhängig vom Grund für die Statusänderung, wie nachfolgend dargestellt: • **`CRITICAL`** wenn der Cluster aufgrund einer der folgenden Statusänderungen beendet wurde: `INTERNAL_ERROR` , `VALIDATION_ERROR` ,	Änderung des EMR-Cluster-Zustands	Keine	Amazon EMR Cluster `ClusterId (ClusterName)` wurde am `Time` aufgrund von `StateChangeReason: Code` beendet.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
	`INSTANCE_FAILURE` , `BOOTSTRAP_FAILURE` oder `STEP_FAILURE` . • **`INFO`** wenn der Cluster aufgrund einer der folgenden Statusänderungen beendet wurde: `USER_REQUEST` oder `ALL_STEPS_COMPLETED` .			
`TERMINATED_WITH_ERRORS`	`CRITICAL`	Änderung des EMR-Cluster-Zustands	Keine	Amazon EMR Cluster `ClusterId (ClusterName)` wurde mit Fehlern am `Time` aufgrund von `StateChangeReason: Code` beendet.

Ereignisse zur Änderung des Status der Instance-Flotte

> **Note**
>
> Die Konfiguration der Instance-Flotten ist nur in den Amazon-EMR-Versionen 4.8.0 und höher verfügbar, mit Ausnahme von 5.0.0 und 5.0.3.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
Von `PROVISIONING` bis `WAITING`	`INFO`		Keine	Bereitstellung für die Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` ist abgeschlossen. Die Bereitstellung startete um `Time` und dauerte `Num` Minuten. Die Instance-Flotte verfügt jetzt über eine On-Demand-Kapazität von `Num` und eine Spot-Kapazität von `Num`. Die anvisierte On-Demand-Kapazität betrug

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
				Num und die anvisierte Spot-Kapazität betrug Num.
Von WAITING bis RESIZING	INFO		Keine	Die Größenänderung für Instance-Flotte InstanceFleetID im Amazon-EMR-Cluster ClusterId (ClusterName) begann um Time. Die Instance-Flotte verändert ihre Größe von einer On-Demand-Kapazität von Num auf eine Zielkapazität von Num und von einer Spot-Kapazität von Num auf eine Zielkapazität von Num.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
Von `RESIZING` bis `WAITING`	`INFO`		Keine	Die Größenänderung für die Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` ist abgeschlossen. Die Größenänderung startete um `Time` und dauerte `Num` Minuten. Die Instance-Flotte verfügt jetzt über eine On-Demand-Kapazität von `Num` und eine Spot-Kapazität von `Num`. Die anvisierte On-Demand-Kapazität betrug `Num` und die anvisierte Spot-Kapazität betrug `Num`.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
Von `RESIZING` bis `WAITING`	`INFO`		Keine	Die Größenänderung der Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` hat das Zeitlimit erreicht und wurde gestoppt. Die Größenänderung startete um `Time` und wurde nach `Num` Minuten gestoppt. Die Instance-Flotte verfügt jetzt über eine On-Demand-Kapazität von `Num` und eine Spot-Kapazität von `Num`. Die anvisierte On-Demand-Kapazität betrug `Num` und die anvisierte Spot-Kapazität betrug `Num`.

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
SUSPENDED	ERROR		Keine	Die Instance-Flotte InstanceFleetID im Amazon-EMR-Cluster ClusterId (ClusterName) wurde am Time aus dem folgenden Grund gesperrt: ReasonDesc .
RESIZING	WARNING		Keine	Die Größenänderung für die Instance-Flotte InstanceFleetID im Amazon-EMR-Cluster ClusterId (ClusterName) ist aus dem folgenden Grund blockiert: ReasonDesc .

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
`WAITING` oder `Running`	`INFO`		Keine	Die Größenänderung für die Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` konnte nicht abgeschlossen werden, während Amazon EMR Spot-Kapazität in der Availability Zone `AvailabilityZone` hinzufügte. Wir haben Ihre Anfrage zur Bereitstellung zusätzlicher Spot-Kapazität storniert. Die empfohlenen Maßnahmen finden Sie unter Bewährte Methoden für Instance- und Availability Zone-

Status oder Statusänderung	Schweregrad	Ereignistyp	Ereigniscode	Fehlermeldung
				Flexibilität. Bitte versuchen Sie es erneut.
`WAITING` oder `Running`	`INFO`		Keine	Eine Größenänderung für beispielsweise eine Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde von `Entity` auf `Time` initiiert.

Ereignisse zur Änderung der Größe der Instance-Flotte

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Flotte ändern	`ERROR`	Spot-Provisioning-Timeout	Der Vorgang zur Größenänderung für die Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` konnte beim Erwerb von Spot-Kapazität in AZ `Availabil`

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
			ityZone nicht abgeschlossen werden. Wir haben jetzt Ihre Anfrage storniert und den Versuch beendet, zusätzliche Spot-Kapazität bereitzustellen, und die Instance-Flotte hat Spot-Kapazität von num bereitgestellt. Die Ziel-Spot-Kapazität war num. Weitere Informationen und Handlungsempfehlungen finden Sie auf der Dokumentationsseite hier. Bitte versuchen Sie es erneut.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Flotte ändern	ERROR	Timeout für die On-Demand-Bereitstellung	Der Vorgang zur Größenänderung für die Instance-Flotte `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (Cluster Name)` konnte beim Erwerb von On-Demand-Kapazität in AZ `AvailabilityZone` nicht abgeschlossen werden. Wir haben jetzt Ihre Anfrage storniert und den Versuch beendet, zusätzliche On-Demand-Kapazität bereitzustellen, und die Instance-Flotte hat On-Demand-Kapazität von `num` bereitgestellt. Die gewünschte On-Demand-Kapazität war `num`. Weitere Informationen und Handlungsempfehlungen finden Sie auf der Dokumentationsseite hier. Bitte versuchen Sie es erneut.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Flotte ändern	`WARNING`	EC2-Bereitstellung – Unzureichende Instance-Kapazität	Wir können den Größenänderungsvorgang für die Instance-Flotte `InstanceFleetID` im EMR-Cluster `ClusterId (ClusterName)` nicht abschließen, da Amazon EC2 nicht über ausreichende Spot-Kapazität für `[Instancetype1, Instancetype2]` - Instance-Typen und unzureichende On-Demand-Kapazität für `[Instancetype3, Instancetype4]` - Instance-Typen in der Availability Zone `[AvailabilityZone1]` verfügt. Bisher hat die Instance-Flotte On-Demand-Kapazität von num bereitgestellt und die angestrebte On-Demand-Kapazität war num. Die bereitgestellte Spot-Kapazität ist num und die Ziel-Spot-Kapazität war num.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
			Weitere Informationen darüber, wie Sie auf dieses Ereignis reagieren können, finden Sie in der Dokumentation.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Flotte ändern	WARNING	Zeitlimit für Spot-Bereitstellung – Fortsetzung der Größenänderung	Wir stellen immer noch Spot-Kapazität für den Vorgang zur Größenänderung der Instance-Flotte bereit, der mit der time für Instance-Flotte-ID InstanceFleetID im Amazon-EMR-Cluster ClusterId (ClusterName) für [Instancetype1, Instancetype2] in AZ AvailabilityZone gestartet wurde. Für den vorherigen Vorgang zur Größenänderung, der am time gestartet wurde, ist der Timeout-Zeitraum abgelaufen, sodass Amazon EMR die Bereitstellung von Spot-Kapazität eingestellt hat, nachdem num der angeforderten num Instances zu Ihrer Instance-Flotte hinzugefügt wurden. Weitere Informationen finden Sie auf der

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
			Dokumentationsseite hier.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Flotte ändern	`WARNING`	Timeout für On-Demand-Bereitstellung – Fortsetzung der Größenänderung	Wir stellen weiterhin On-Demand-Kapazität für den Vorgang zur Größenänderung der Instance-Flotte bereit, der mit der `time` für Instance-Flotte-ID `InstanceFleetID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` für `[Instance type1, Instancetype2]` in AZ `AvailabilityZone` gestartet wurde. Für den vorherigen Vorgang zur Größenänderung, der am `time` gestartet wurde, ist der Timeout-Zeitraum abgelaufen, sodass Amazon EMR die Bereitstellung von On-Demand-Kapazität eingestellt hat, nachdem `num` der angeforderten `num` Instances zu Ihrer Instance-Flotte hinzugefügt wurden. Weitere Informationen finden Sie auf der

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
			Dokumentationsseite hier.

> **Note**
>
> Die Timeout-Ereignisse für die Bereitstellung werden ausgelöst, wenn Amazon EMR die Bereitstellung von Spot- oder On-Demand-Kapazität für die Flotte nach Ablauf des Timeouts beendet. Weitere Informationen zum Umgang mit diesen Ereignissen finden Sie unter Reaktion auf Timeout-Ereignisse zur Größenänderung der Amazon-EMR-Cluster-Instance-Flotte.

Instance-Gruppen-Ereignisse

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Von `RESIZING` bis `Running`	`INFO`	Keine	Die Größenänderung für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` ist abgeschlossen. Sie verfügt jetzt über eine Instance-Anzahl von `Num`. Die Größenänderung startete um `Time` und dauerte `Num` Minuten bis zum Abschluss.
Von `RUNNING` bis `RESIZING`	`INFO`	Keine	Eine Größenänderung für die Instance-Gruppe

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
			`InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` begann bei `Time`. Die Größenänderung erfolgt von einer Instance-Anzahl von `Num` auf `Num`.
`SUSPENDED`	`ERROR`	Keine	Die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde am `Time` aus dem folgenden Grund gesperrt: `ReasonDesc` .
`RESIZING`	`WARNING`	Keine	Die Größenänderung für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` ist aus dem folgenden Grund blockiert: `ReasonDesc` .

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Größe der Amazon-EMR-Instance-Gruppe ändern	WARNING	EC2-Bereitstellung – Unzureichende Instance-Kapazität	Wir können den Größenänderungsvorgang, der bei time für die Instance-Gruppe InstanceGroupID im EMR-Cluster ClusterId (ClusterName) gestartet wurde, nicht abschließen, da Amazon EC2 nicht über ausreichende Spot/On Demand-Kapazität für den Instance-Typ [Instancetype] in der Availability Zone [AvailabilityZone1] verfügt. Bisher hatte die Instancegruppe eine Anzahl laufender Instances von num und die Anzahl der angeforderten Instances betrug num. Weitere Informationen darüber, wie Sie auf dieses Ereignis reagieren können, finden Sie in der Dokumentation.

Ereignistyp	Schweregrad	Ereigniscode	Fehlermeldung
Von `RUNNING` bis `RESIZING`	`INFO`	Keine	Eine Größenänderung für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde von `Entity` auf `Time` initiiert.

> **Note**
>
> Ab Amazon-EMR-Version 5.21.0 können Sie Cluster-Konfigurationen überschreiben und zusätzliche Konfigurationsklassifikationen für jede Instance-Gruppe in einem ausgeführten Cluster angeben. Dies erfolgt über die Amazon-EMR-Konsole, die AWS Command Line Interface (AWS CLI) oder das AWS SDK. Weitere Informationen finden Sie unter Angeben einer Konfiguration für eine Instance-Gruppe in einem aktiven Cluster.

In der folgenden Tabelle sind die Amazon-EMR-Ereignisse für den Rekonfigurationsvorgang aufgeführt, zusammen mit dem Zustand oder der Zustandsänderung, die das Ereignis anzeigt, dem Schweregrad des Ereignisses und den Ereignismeldungen.

Status oder Statusänderung	Schweregrad	Fehlermeldung
`RUNNING`	`INFO`	Eine Neukonfiguration für die Instancegruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde vom Benutzer um `Time` initiiert. Die Version der angeforderten Konfiguration ist `Num`.

Status oder Statusänderung	Schweregrad	Fehlermeldung
Von `RECONFIGURING` bis `Running`	`INFO`	Der Neukonfigurationsvorgang für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` ist abgeschlossen. Die Rekonfiguration startete um `Time` und benötigte `Num` Minuten bis zum Abschluss. Die aktuelle Konfigurationsversion ist `Num`.
Von `RUNNING` bis `RECONFIGURING` in	`INFO`	Eine Neukonfiguration für die Instancegruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` begann um `Time`. Sie konfiguriert von Versionsnummer `Num` bis Versionsnummer `Num`.
`RESIZING`	`INFO`	Die Rekonfigurationsoperation auf Konfigurationsversion `Num` für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (ClusterName)` wurde vorübergehend gesperrt, da sich die Instance-Gruppe `Time` in `State` befindet.

Status oder Statusänderung	Schweregrad	Fehlermeldung
RECONFIGURING	INFO	Die Größenänderungsoperation auf Instance-Anzahl Num für die Instance-Gruppe InstanceGroupID im Amazon-EMR-Cluster ClusterId (ClusterName) wurde vorübergehend auf Time gesperrt, da die Instance-Gruppe sich in State befindet.
RECONFIGURING	WARNING	Die Rekonfigurationsoperation für die Instance-Gruppe InstanceGroupID im Amazon EMR-Cluster ClusterId (ClusterName) schlug um Time fehl. Bis zum Fehlschlagen dauerte es Num Minuten. Die fehlgeschlagene Konfigurationsversion ist Num.
RECONFIGURING	INFO	Konfigurationen werden in der zuvor funktionierenden Version Num für die Instance-Gruppe InstanceGroupID im Amazon-EMR-Cluster ClusterId (ClusterName) auf Time wiederhergestellt. Die neue Konfigurationsversion ist Num.

Status oder Statusänderung	Schweregrad	Fehlermeldung
Von RECONFIGURING bis Running	INFO	Konfigurationen wurden in der zuvor funktionierenden Version Num für die Instance-Gruppe InstanceGroupID im Amazon EMR-Cluster ClusterId (ClusterName) auf Time wiederherstellt. Die neue Konfigurationsversion ist Num.
Von RECONFIGURING bis SUSPENDED	CRITICAL	Fehler beim Zurücksetzen auf die vorherige erfolgreiche Version Num für die Instance-Gruppe InstanceGroupID im Amazon-EMR-Cluster ClusterId (ClusterName) unter Time.

Auto-Scaling-Richtlinienereignisse

Status oder Statusänderung	Schweregrad	Fehlermeldung
PENDING	INFO	Der Instancegruppe InstanceGroupID in Amazon-EMR-Cluster ClusterId (ClusterName) wurde um Time eine Auto Scaling-Richtlinie hinzugefügt. Die Ausrüstung der Richtlinie ist noch anhängig. – oder –

Status oder Statusänderung	Schweregrad	Fehlermeldung
		Die Auto Scaling-Richtlinie für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (Cluster Name)` wurde um `Time` aktualisiert. Die Ausrüstung der Richtlinie ist noch anhängig.
`ATTACHED`	`INFO`	Die Auto Scaling-Richtlinie für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (Cluster Name)` wurde um `Time` angefügt.
`DETACHED`	`INFO`	Die Auto Scaling-Richtlinie für die Instance-Gruppe `InstanceGroupID` im Amazon-EMR-Cluster `ClusterId (Cluster Name)` wurde um `Time` getrennt.

Status oder Statusänderung	Schweregrad	Fehlermeldung
FAILED	ERROR	Die Auto Scaling-Richtlinie für die Instance-Gruppe InstanceGroupID im Amazon EMR-Cluster ClusterId (Cluster Name) konnte nicht angefügt werden und schlug um Time fehl. – oder – Die Auto Scaling-Richtlinie für die Instance-Gruppe InstanceGroupID im Amazon-EMR-Cluster ClusterId (Cluster Name) konnte nicht getrennt werden und schlug um Time fehl.

Schritt-Ereignisse

Status oder Statusänderung	Schweregrad	Fehlermeldung
PENDING	INFO	Der Schritt StepID (StepName) wurde dem Amazon-EMR-Cluster ClusterId (ClusterName) um Time hinzugefügt und seine Ausführung steht noch aus.
CANCEL_PENDING	WARN	Der Schritt StepID (StepName) im Amazon-EMR-Cluster ClusterId

Status oder Statusänderung	Schweregrad	Fehlermeldung
		(ClusterName) wurde um Time storniert und die Stornierung steht noch aus.
RUNNING	INFO	Schritt StepID (StepName) im Amazon-EMR-Cluster ClusterId (ClusterName) wurde um Time gestartet.
COMPLETED	INFO	Die Ausführung des Schritts StepID (StepName) im Amazon-EMR-Cluster ClusterId (ClusterName) wurde um Time abgeschlossen. Der Schritt begann um Time mit der Ausführung und dauerte Num Minuten bis zum Abschluss.
CANCELLED	WARN	Die Abbruchsaufforderung war für den Cluster-Schritt StepID (StepName) im Amazon-EMR-Cluster ClusterId (ClusterName) um Time erfolgreich und der Schritt wurde abgebrochen.
FAILED	ERROR	Der Schritt StepID (StepName) im Amazon-EMR-Cluster ClusterId (ClusterName) ist um Time fehlgeschlagen.

Ereignisse mit der Amazon-EMR-Konsole anzeigen

Für jeden Cluster können Sie eine einfache Liste der Ereignisse im Detailbereich anzeigen, der die Ereignisse in der Reihenfolge ihres Auftretens auflistet. Sie können auch alle Ereignisse für alle Cluster in einer Region in absteigender Reihenfolge ihres Auftretens anzeigen.

Wenn Sie nicht möchten, dass ein Benutzer alle Cluster-Ereignisse für eine Region sehen kann, erstellen Sie eine Anweisung, die die Berechtigung (`"Effect": "Deny"`) für die Aktion `elasticmapreduce:ViewEventsFromAllClustersInConsole` ablehnt. Fügen Sie diese Anweisung einer Richtlinie hinzu, die dem Benutzer zugeordnet ist.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

Um Ereignisse für alle Cluster in einer Region mit der neuen Konsole anzuzeigen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR auf EC2 die Option Ereignisse aus.

Anzeigen von Ereignissen eines bestimmten Clusters in einer neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann ein Cluster aus.
3. Um alle Ihre Ereignisse anzuzeigen, wählen Sie auf der Cluster-Detailseite die Registerkarte Ereignisse aus.

Old console

Um Ereignisse für alle Cluster in einer Region mit der alten Konsole anzuzeigen

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/.
2. Wählen Sie Events (Ereignisse).

Um Ereignisse für einen bestimmten Cluster mit der alten Konsole anzuzeigen

1. Öffnen Sie die Amazon-EMR-Konsole unterhttps://console.aws.amazon.com/elasticmapreduce/.
2. Klicken Sie auf Cluster List (Cluster-Liste), wählen Sie einen Cluster und anschließend View details (Details anzeigen) aus.
3. Wählen Sie im Cluster-Detailbereich die Option Events (Ereignisse) aus.

Reagieren auf CloudWatch-Ereignisse

In diesem Abschnitt werden verschiedene Möglichkeiten beschrieben, wie Sie auf umsetzbare Ereignisse reagieren können, die Amazon EMR als CloudWatch-Ereignisnachrichten ausgibt.

Themen

- Erstellen von Regeln für Amazon-EMR-Ereignisse mit CloudWatch
- Einrichten von Alarmen für CloudWatch-Metriken
- Reaktion auf Ereignisse mit unzureichender Instance-Kapazität im Amazon-EMR-Cluster
- Reaktion auf Timeout-Ereignisse zur Größenänderung der Amazon-EMR-Cluster-Instance-Flotte

Erstellen von Regeln für Amazon-EMR-Ereignisse mit CloudWatch

Amazon EMR sendet Ereignisse automatisch an einen CloudWatch Ereignis-Stream. Sie können Regeln erstellen, die nach einem bestimmten Muster auf Ereignisse zutreffen, und Sie können die Ereignisse an Ziele weiterleiten, um entsprechende Maßnahmen zu ergreifen, z. B. E-Mail-Benachrichtigungen senden. Muster werden mit dem JSON-Objekt abgeglichen. Weitere Informationen über Amazon EMR Ereignismuster finden Sie unter Amazon EMR Ereignisse im Amazon-CloudWatch-Events-Benutzerhandbuch.

Informationen zum Einrichten von CloudWatch-Ereignisregeln finden Sie unter Erstellen einer CloudWatch-Regel, die bei einem Ereignis ausgelöst wird.

Einrichten von Alarmen für CloudWatch-Metriken

Amazon EMR sendet Metriken an Amazon CloudWatch. Als Reaktion darauf können Sie CloudWatch verwenden, um Alarme für Ihre Amazon-EMR-Metriken einzustellen. So können Sie beispielsweise in CloudWatch einen Alarm konfigurieren, damit Ihnen eine E-Mail gesendet wird, sobald die HDFS-Auslastung 80 % übersteigt. Weitere detaillierte Anweisungen finden Sie unter Erstellen oder Bearbeiten von CloudWatch-Alarmen im Amazon-CloudWatch-Benutzerhandbuch.

Reaktion auf Ereignisse mit unzureichender Instance-Kapazität im Amazon-EMR-Cluster

Übersicht

Amazon-EMR-Cluster geben den Ereigniscode `EC2 provisioning - Insufficient Instance Capacity` zurück, wenn die ausgewählte Availability Zone nicht über genügend Kapazität verfügt, um Ihre Anfrage zum Clusterstart oder zur Größenänderung zu erfüllen. Das Ereignis wird regelmäßig sowohl bei Instance-Gruppen als auch bei Instance-Flotten ausgelöst, wenn Amazon EMR wiederholt auf Ausnahmen mit unzureichender Kapazität stößt und Ihre Bereitstellungsanforderung für einen Cluster-Start oder eine Cluster-Größenänderung nicht erfüllen kann.

Auf dieser Seite wird beschrieben, wie Sie am besten auf diesen Ereignistyp reagieren können, wenn er für Ihren EMR-Cluster auftritt.

Empfohlene Reaktion auf ein Ereignis mit unzureichender Kapazität

Es wird empfohlen, dass Sie auf ein Ereignis mit unzureichender Kapazität mit einer der folgenden Methoden reagieren:

- Warten Sie, bis die Kapazität wiederhergestellt ist. Die Kapazität ändert sich häufig, sodass sich eine Ausnahme mit unzureichender Kapazität von selbst erholen kann. Ihre Cluster beginnen oder beenden die Größenänderung, sobald Amazon-EC2-Kapazität verfügbar ist.
- Alternativ können Sie Ihren Cluster beenden, Ihre Instance-Typ-Konfigurationen ändern und einen neuen Cluster mit der aktualisierten Cluster-Konfigurationsanforderung erstellen. Weitere Informationen finden Sie unter Bewährte Methoden für Instance- und Availability Zone-Flexibilität.

Sie können auch Regeln oder automatische Reaktionen auf ein Ereignis mit unzureichender Kapazität einrichten, wie im nächsten Abschnitt beschrieben.

Automatisierte Wiederherstellung nach einem Ereignis mit unzureichender Kapazität

Sie können eine Automatisierung als Reaktion auf Amazon-EMR-Ereignisse erstellen, z. B. solche mit Ereigniscode `EC2 provisioning - Insufficient Instance Capacity`. Die folgende AWS Lambda-Funktion beendet beispielsweise einen EMR-Cluster mit einer Instance-Gruppe, die On-Demand-Instances verwendet, und erstellt dann einen neuen EMR-Cluster mit einer Instance-Gruppe, die andere Instance-Typen als die ursprüngliche Anfrage enthält.

Die folgenden Bedingungen lösen den automatisierten Prozess aus:

- Das Ereignis „unzureichende Kapazität“ wird seit mehr als 20 Minuten für Primär- oder Core-Knoten ausgelöst.
- Der Cluster befindet sich nicht im Status READY oder WAITING. Weitere Informationen zu EMR-Cluster-Status finden Sie unter Verstehen des Cluster-Lebenszyklus.

> **Note**
>
> Wenn Sie einen automatisierten Prozess für eine Ausnahme mit unzureichender Kapazität erstellen, sollten Sie berücksichtigen, dass das Ereignis „unzureichende Kapazität“ wiederherstellbar ist. Die Kapazität verschiebt sich häufig und Ihre Cluster setzen die Größenänderung fort oder starten den Betrieb, sobald Amazon-EC2-Kapazität verfügbar ist.

Example Funktion zur Reaktion auf ein Ereignis mit unzureichender Kapazität

```
// Lambda code with Python 3.10 and handler is lambda_function.lambda_handler
// Note: related IAM role requires permission to use Amazon EMR

import json
import boto3
import datetime
from datetime import timezone

INSUFFICIENT_CAPACITY_EXCEPTION_DETAIL_TYPE = "EMR Instance Group Provisioning"
INSUFFICIENT_CAPACITY_EXCEPTION_EVENT_CODE = (
    "EC2 provisioning - Insufficient Instance Capacity"
)
ALLOWED_INSTANCE_TYPES_TO_USE = [
    "m5.xlarge",
    "c5.xlarge",
```

```
    "m5.4xlarge",
    "m5.2xlarge",
    "t3.xlarge",
]
CLUSTER_START_ACCEPTABLE_STATES = ["WAITING", "RUNNING"]
CLUSTER_START_SLA = 20

CLIENT = boto3.client("emr", region_name="us-east-1")

# checks if the incoming event is 'EMR Instance Fleet Provisioning' with eventCode 'EC2
 provisioning - Insufficient Instance Capacity'
def is_insufficient_capacity_event(event):
    if not event["detail"]:
        return False
    else:
        return (
            event["detail-type"] == INSUFFICIENT_CAPACITY_EXCEPTION_DETAIL_TYPE
            and event["detail"]["eventCode"]
            == INSUFFICIENT_CAPACITY_EXCEPTION_EVENT_CODE
        )


# checks if the cluster is eligible for termination
def is_cluster_eligible_for_termination(event, describeClusterResponse):
    # instanceGroupType could be CORE, MASTER OR TASK
    instanceGroupType = event["detail"]["instanceGroupType"]
    clusterCreationTime = describeClusterResponse["Cluster"]["Status"]["Timeline"][
        "CreationDateTime"
    ]
    clusterState = describeClusterResponse["Cluster"]["Status"]["State"]

    now = datetime.datetime.now()
    now = now.replace(tzinfo=timezone.utc)
    isClusterStartSlaBreached = clusterCreationTime < now - datetime.timedelta(
        minutes=CLUSTER_START_SLA
    )

    # Check if instance group receiving Insufficient capacity exception is CORE or
 PRIMARY (MASTER),
    # and it's been more than 20 minutes since cluster was created but the cluster
 state and the cluster state is not updated to RUNNING or WAITING
    if (
        (instanceGroupType == "CORE" or instanceGroupType == "MASTER")
        and isClusterStartSlaBreached
```

```
        and clusterState not in CLUSTER_START_ACCEPTABLE_STATES
    ):
        return True
    else:
        return False


# Choose item from the list except the exempt value
def choice_excluding(exempt):
    for i in ALLOWED_INSTANCE_TYPES_TO_USE:
        if i != exempt:
            return i


# Create a new cluster by choosing different InstanceType.
def create_cluster(event):
    # instanceGroupType cloud be CORE, MASTER OR TASK
    instanceGroupType = event["detail"]["instanceGroupType"]

    # Following two lines assumes that the customer that created the cluster already
 knows which instance types they use in original request
    instanceTypesFromOriginalRequestMaster = "m5.xlarge"
    instanceTypesFromOriginalRequestCore = "m5.xlarge"

    # Select new instance types to include in the new createCluster request
    instanceTypeForMaster = (
        instanceTypesFromOriginalRequestMaster
        if instanceGroupType != "MASTER"
        else choice_excluding(instanceTypesFromOriginalRequestMaster)
    )
    instanceTypeForCore = (
        instanceTypesFromOriginalRequestCore
        if instanceGroupType != "CORE"
        else choice_excluding(instanceTypesFromOriginalRequestCore)
    )

    print("Starting to create cluster...")
    instances = {
        "InstanceGroups": [
            {
                "InstanceRole": "MASTER",
                "InstanceCount": 1,
                "InstanceType": instanceTypeForMaster,
                "Market": "ON_DEMAND",
```

```
                "Name": "Master",
            },
            {
                "InstanceRole": "CORE",
                "InstanceCount": 1,
                "InstanceType": instanceTypeForCore,
                "Market": "ON_DEMAND",
                "Name": "Core",
            },
        ]
    }
    response = CLIENT.run_job_flow(
        Name="Test Cluster",
        Instances=instances,
        VisibleToAllUsers=True,
        JobFlowRole="EMR_EC2_DefaultRole",
        ServiceRole="EMR_DefaultRole",
        ReleaseLabel="emr-6.10.0",
    )

    return response["JobFlowId"]


# Terminated the cluster using clusterId received in an event
def terminate_cluster(event):
    print("Trying to terminate cluster, clusterId: " + event["detail"]["clusterId"])
    response = CLIENT.terminate_job_flows(JobFlowIds=[event["detail"]["clusterId"]])
    print(f"Terminate cluster response: {response}")


def describe_cluster(event):
    response = CLIENT.describe_cluster(ClusterId=event["detail"]["clusterId"])
    return response


def lambda_handler(event, context):
    if is_insufficient_capacity_event(event):
        print(
            "Received insufficient capacity event for instanceGroup, clusterId: "
            + event["detail"]["clusterId"]
        )

        describeClusterResponse = describe_cluster(event)
```

```
        shouldTerminateCluster = is_cluster_eligible_for_termination(
            event, describeClusterResponse
        )
        if shouldTerminateCluster:
            terminate_cluster(event)

            clusterId = create_cluster(event)
            print("Created a new cluster, clusterId: " + clusterId)
        else:
            print(
                "Cluster is not eligible for termination, clusterId: "
                + event["detail"]["clusterId"]
            )

    else:
        print("Received event is not insufficient capacity event, skipping")
```

Reaktion auf Timeout-Ereignisse zur Größenänderung der Amazon-EMR-Cluster-Instance-Flotte

Übersicht

Amazon-EMR-Cluster senden Ereignisse aus, während sie die Größenänderung für z. B. Flottencluster ausführen. Die Timeout-Ereignisse für die Bereitstellung werden ausgelöst, wenn Amazon EMR die Bereitstellung von Spot- oder On-Demand-Kapazität für die Flotte nach Ablauf des Timeouts beendet. Die Dauer des Timeouts kann vom Benutzer im Rahmen der Größenänderungsspezifikationen für die Instance-Flotten konfiguriert werden. In Szenarien mit aufeinanderfolgenden Größenänderungen für dieselbe Instance-Flotte gibt Amazon EMR die Ereignisse `Spot provisioning timeout - continuing resize` oder `On-Demand provisioning timeout - continuing resize` aus, wenn das Timeout für den aktuellen Größenänderungsvorgang abläuft. Dann beginnt es mit der Bereitstellung von Kapazität für die nächste Größenänderung der Flotte.

Reagieren auf Timeout-Ereignisse zur Größenänderung der Instanceflotte

Es wird empfohlen, dass Sie auf ein Bereitstellungs-Timeout-Ereignis mit einer der folgenden Methoden reagieren:

- GreifenSie die Größenänderungsspezifikationen wieder auf und versuchen Sie erneut, die Größe zu ändern. Da sich die Kapazität häufig ändert, wird die Größe Ihrer Cluster erfolgreich angepasst, sobald Amazon-EC2-Kapazität verfügbar ist. Wir empfehlen Kunden, niedrigere Werte für die Timeout-Dauer für Aufträge zu konfigurieren, die strengere SLAs erfordern.

- Alternativ können Sie entweder:
  - Einen neuen Cluster mit diversifizierten Instance-Typen auf der Grundlage von bewährten Methoden wie der Flexibilität von Instances und Availability Zones starten oder
  - Einen Cluster mit On-Demand-Kapazität starten
- Für das Ereignis „Timeout bei der Bereitstellung – Fortsetzung der Größenänderung“ können Sie zusätzlich warten, bis die Größenänderungsvorgänge verarbeitet sind. Amazon EMR verarbeitet weiterhin sequentiell die für die Flotte ausgelösten Größenänderungsvorgänge, wobei die konfigurierten Größenänderungsspezifikationen eingehalten werden.

Sie können auch Regeln oder automatische Reaktionen auf dieses Ereignis einrichten, wie im nächsten Abschnitt beschrieben.

Automatisierte Wiederherstellung nach einem Bereitstellungs-Timeout-Ereignis

Mit dem `Spot Provisioning timeout`-Ereigniscode können Sie als Reaktion auf Amazon-EMR-Ereignisse eine Automatisierung erstellen. Die folgende AWS Lambda-Funktion fährt beispielsweise einen EMR-Cluster mit einer Instance-Flotte herunter, die Spot Instances für Aufgabenknoten verwendet, und erstellt dann einen neuen EMR-Cluster mit einer Instance-Flotte, die vielfältigere Instance-Typen als die ursprüngliche Anfrage enthält. In diesem Beispiel löst das für Aufgabenknoten ausgegebene `Spot Provisioning timeout` Ereignis die Ausführung der Lambda-Funktion aus.

Example Beispielfunktion zur Reaktion auf ein **`Spot Provisioning timeout`**-Ereignis

```
// Lambda code with Python 3.10 and handler is lambda_function.lambda_handler
// Note: related IAM role requires permission to use Amazon EMR

import json
import boto3
import datetime
from datetime import timezone

SPOT_PROVISIONING_TIMEOUT_EXCEPTION_DETAIL_TYPE = "EMR Instance Fleet Resize"
SPOT_PROVISIONING_TIMEOUT_EXCEPTION_EVENT_CODE = (
    "Spot Provisioning timeout"
)

CLIENT = boto3.client("emr", region_name="us-east-1")

# checks if the incoming event is 'EMR Instance Fleet Resize' with eventCode 'Spot
 provisioning timeout'
```

```
def is_spot_provisioning_timeout_event(event):
    if not event["detail"]:
        return False
    else:
        return (
            event["detail-type"] == SPOT_PROVISIONING_TIMEOUT_EXCEPTION_DETAIL_TYPE
            and event["detail"]["eventCode"]
            == SPOT_PROVISIONING_TIMEOUT_EXCEPTION_EVENT_CODE
        )


# checks if the cluster is eligible for termination
def is_cluster_eligible_for_termination(event, describeClusterResponse):
    # instanceFleetType could be CORE, MASTER OR TASK
    instanceFleetType = event["detail"]["instanceFleetType"]

    # Check if instance fleet receiving Spot provisioning timeout event is TASK
    if (instanceFleetType == "TASK"):
        return True
    else:
        return False


# create a new cluster by choosing different InstanceType.
def create_cluster(event):
    # instanceFleetType cloud be CORE, MASTER OR TASK
    instanceFleetType = event["detail"]["instanceFleetType"]

    # the following two lines assumes that the customer that created the cluster
 already knows which instance types they use in original request
    instanceTypesFromOriginalRequestMaster = "m5.xlarge"
    instanceTypesFromOriginalRequestCore = "m5.xlarge"

    # select new instance types to include in the new createCluster request
    instanceTypesForTask = [
        "m5.xlarge",
        "m5.2xlarge",
        "m5.4xlarge",
        "m5.8xlarge",
        "m5.12xlarge"
    ]

    print("Starting to create cluster...")
    instances = {
```

```
        "InstanceFleets": [
            {
                "InstanceFleetType":"MASTER",
                "TargetOnDemandCapacity":1,
                "TargetSpotCapacity":0,
                "InstanceTypeConfigs":[
                    {
                        'InstanceType': instanceTypesFromOriginalRequestMaster,
                        "WeightedCapacity":1,
                    }
                ]
            },
            {
                "InstanceFleetType":"CORE",
                "TargetOnDemandCapacity":1,
                "TargetSpotCapacity":0,
                "InstanceTypeConfigs":[
                    {
                        'InstanceType': instanceTypesFromOriginalRequestCore,
                        "WeightedCapacity":1,
                    }
                ]
            },
            {
                "InstanceFleetType":"TASK",
                "TargetOnDemandCapacity":0,
                "TargetSpotCapacity":100,
                "LaunchSpecifications":{},
                "InstanceTypeConfigs":[
                    {
                        'InstanceType': instanceTypesForTask[0],
                        "WeightedCapacity":1,
                    },
                    {
                        'InstanceType': instanceTypesForTask[1],
                        "WeightedCapacity":2,
                    },
                    {
                        'InstanceType': instanceTypesForTask[2],
                        "WeightedCapacity":4,
                    },
                    {
                        'InstanceType': instanceTypesForTask[3],
                        "WeightedCapacity":8,
```

```
                    },
                    {
                        'InstanceType': instanceTypesForTask[4],
                        "WeightedCapacity":12,
                    }
                ],
                "ResizeSpecifications": {
                    "SpotResizeSpecification": {
                        "TimeoutDurationMinutes": 30
                    }
                }
            }
        ]
    }
    response = CLIENT.run_job_flow(
        Name="Test Cluster",
        Instances=instances,
        VisibleToAllUsers=True,
        JobFlowRole="EMR_EC2_DefaultRole",
        ServiceRole="EMR_DefaultRole",
        ReleaseLabel="emr-6.10.0",
    )

    return response["JobFlowId"]


# terminated the cluster using clusterId received in an event
def terminate_cluster(event):
    print("Trying to terminate cluster, clusterId: " + event["detail"]["clusterId"])
    response = CLIENT.terminate_job_flows(JobFlowIds=[event["detail"]["clusterId"]])
    print(f"Terminate cluster response: {response}")


def describe_cluster(event):
    response = CLIENT.describe_cluster(ClusterId=event["detail"]["clusterId"])
    return response


def lambda_handler(event, context):
    if is_spot_provisioning_timeout_event(event):
        print(
            "Received spot provisioning timeout event for instanceFleet, clusterId: "
            + event["detail"]["clusterId"]
        )
```

```
        describeClusterResponse = describe_cluster(event)

        shouldTerminateCluster = is_cluster_eligible_for_termination(
            event, describeClusterResponse
        )
        if shouldTerminateCluster:
            terminate_cluster(event)

            clusterId = create_cluster(event)
            print("Created a new cluster, clusterId: " + clusterId)
        else:
            print(
                "Cluster is not eligible for termination, clusterId: "
                + event["detail"]["clusterId"]
            )

    else:
        print("Received event is not spot provisioning timeout event, skipping")
```

Anzeigen von Cluster-Anwendungsmetriken mit Ganglia

Ganglia ist mit den Amazon-EMR-Versionen 4.2 und höher verfügbar. Ganglia ist ein Open-Source-Projekt. Es handelt sich um ein skalierbares, verteiltes System zur Überwachung von Clustern und Grids, das zugleich die Auswirkungen auf die Leistung minimiert. Wenn Sie Ganglia in Ihrem Cluster aktivieren, können Sie Berichte erstellen und die Leistung des Clusters als Ganzes betrachten. Ebenso können Sie die Leistung einzelner Knoten-Instances überprüfen. Ganglia ist außerdem zur Aufnahme und Visualisierung von Hadoop- und Spark-Metriken konfiguriert. Weitere Informationen finden Sie unter Ganglia im Handbuch zu Amazon-EMR-Versionen.

Protokollieren von Amazon-EMR-API-Aufrufen mit AWS CloudTrail

Amazon EMR ist in AWS CloudTrail integriert, der eine Aufzeichnung der von einem Benutzer, einer Rolle oder einem AWS-Service in Amazon EMR durchgeführten Aktionen bietet. CloudTrail erfasst alle API-Aufrufe für Amazon EMR als Ereignisse. Zu den erfassten Aufrufen gehören Aufrufe von der Amazon-EMR-Konsole und Code-Aufrufe der Amazon-EMR-API-Operationen. Wenn Sie einen Trail erstellen, können Sie die kontinuierliche Bereitstellung von CloudTrail-Ereignissen an einen Amazon-S3-Bucket, einschließlich Ereignissen für Amazon EMR, aktivieren. Wenn Sie keinen Trail konfigurieren, können Sie die neuesten Ereignisse in der CloudTrail-Konsole trotzdem in Event history (Ereignisverlauf) anzeigen. Mit den von CloudTrail gesammelten Informationen können Sie die

an Amazon EMR gestellte Anfrage, die IP-Adresse, von der die Anfrage gestellt wurde, den Initiator der Anfrage, den Zeitpunkt der Anfrage und zusätzliche Details bestimmen.

Weitere Informationen zu CloudTrail finden Sie im AWS CloudTrail-Benutzerhandbuch.

Amazon-EMR-Informationen in CloudTrail

CloudTrail wird beim Erstellen Ihres AWS-Kontos für Sie aktiviert. Wenn in Amazon EMR eine Aktivität auftritt, wird sie in einem CloudTrail-Ereignis zusammen mit anderen AWS-Service-Ereignissen im Ereignisverlauf aufgezeichnet. Sie können die neusten Ereignisse in Ihr AWS-Konto herunterladen und dort suchen und anzeigen. Weitere Informationen finden Sie unter Anzeigen von Ereignissen mit dem CloudTrail-API-Ereignisverlauf.

Für eine fortlaufende Aufzeichnung der Ereignisse in Ihrem AWS-Konto, darunter Ereignisse für Amazon EMR, können Sie einen Trail erstellen. Ein Trail ermöglicht es CloudTrail, Protokolldateien in einem Amazon-S3-Bucket bereitzustellen. Wenn Sie einen Trail in der Konsole anlegen, gilt dieser für alle AWS-Regionen. Der Trail protokolliert Ereignisse aus allen Regionen in der AWS-Partition und stellt die Protokolldateien in dem von Ihnen angegebenen Amazon S3 Bucket bereit. Darüber hinaus können Sie andere AWS-Services konfigurieren, um die in den CloudTrail-Protokollen erfassten Ereignisdaten weiter zu analysieren und entsprechend zu agieren. Weitere Informationen finden Sie unter:

- Übersicht zum Erstellen eines Trails
- In CloudTrail unterstützte Services und Integrationen
- Konfigurieren von Amazon SNS-Benachrichtigungen für CloudTrail
- Empfangen von CloudTrail-Protokolldateien aus mehreren Regionen und Empfangen von CloudTrail-Protokolldateien aus mehreren Konten

Alle Amazon-EMR-Aktionen werden von CloudTrail protokolliert und sind in der Amazon-EMR-API-Referenz dokumentiert. Zum Beispiel generieren Aufrufe der Aktionen `RunJobFlow`, `ListCluster` und `DescribeCluster` Einträge in den CloudTrail-Protokolldateien.

Jeder Ereignis- oder Protokolleintrag enthält Informationen zu dem Benutzer, der die Anforderung generiert hat. Anhand der Identitätsinformationen zur Benutzeridentität können Sie Folgendes bestimmen:

- Ob die Anfrage mit Stammbenutzer- oder AWS Identity and Access Management (IAM)-Anmeldeinformationen ausgeführt wurde.

- Ob die Anforderung mit temporären Sicherheitsanmeldeinformationen für eine Rolle oder einen Verbundbenutzer ausgeführt wurde.
- Gibt an, ob die Anforderung aus einem anderen AWS-Service gesendet wurde

Falls ein Prozess und nicht ein Benutzer einen Cluster erstellt, können Sie anhand der `principalId` ID den Benutzer ermitteln, der mit der Clustererstellung verknüpft ist. Weitere Informationen finden Sie unter CloudTrail-Element userIdentity.

Beispiel: Einträge in der Amazon-EMR-Protokolldatei

Ein Trail ist eine Konfiguration, durch die Ereignisse als Protokolldateien an den von Ihnen angegebenen Amazon-S3-Bucket übermittelt werden. CloudTrail-Protokolldateien können einen oder mehrere Einträge enthalten. Ein Ereignis stellt eine einzelne Anfrage aus einer beliebigen Quelle dar und enthält unter anderem Informationen über die angeforderte Aktion, das Datum und die Uhrzeit der Aktion sowie über die Anfrageparameter. CloudTrail-Protokolleinträge sind kein geordnetes Stack-Trace der öffentlichen API-Aufrufe und erscheinen daher in keiner bestimmten Reihenfolge.

Das folgende Beispiel zeigt einen CloudTrail-Protokolleintrag, der die Aktion RunJobFlow demonstriert.

```
{
 "Records": [
 {
         "eventVersion":"1.01",
         "userIdentity":{
            "type":"IAMUser",
            "principalId":"EX_PRINCIPAL_ID",
            "arn":"arn:aws:iam::123456789012:user/temporary-user-xx-7M",
            "accountId":"123456789012",
            "userName":"temporary-user-xx-7M"
         },
         "eventTime":"2018-03-31T17:59:21Z",
         "eventSource":"elasticmapreduce.amazonaws.com",
         "eventName":"RunJobFlow",
         "awsRegion":"us-west-2",
         "sourceIPAddress":"192.0.2.1",
         "userAgent":"aws-sdk-java/unknown-version Linux/xx Java_HotSpot(TM)_64-
Bit_Server_VM/xx",
         "requestParameters":{
```

```
            "tags":[
               {
                  "value":"prod",
                  "key":"domain"
               },
               {
                  "value":"us-west-2",
                  "key":"realm"
               },
               {
                  "value":"VERIFICATION",
                  "key":"executionType"
               }
            ],
            "instances":{
               "slaveInstanceType":"m5.xlarge",
               "ec2KeyName":"emr-integtest",
               "instanceCount":1,
               "masterInstanceType":"m5.xlarge",
               "keepJobFlowAliveWhenNoSteps":true,
               "terminationProtected":false
            },
            "visibleToAllUsers":false,
            "name":"MyCluster",
            "ReleaseLabel":"emr-5.16.0"
         },
         "responseElements":{
            "jobFlowId":"j-2WDJCGEG4E6AJ"
         },
         "requestID":"2f482daf-b8fe-11e3-89e7-75a3d0e071c5",
         "eventID":"b348a38d-f744-4097-8b2a-e68c9b424698"
      },
  ...additional entries
   ]
}
```


Clusterskalierung verwenden

Als Reaktion auf Workloads mit unterschiedlichen Anforderungen können Sie die Anzahl der für einen Amazon-EMR-Cluster verfügbaren Amazon-EC2-Instances automatisch oder manuell festlegen. Um die automatische Skalierung zu verwenden, haben Sie zwei Optionen. Sie können Amazon EMR

Managed Scaling aktivieren oder eine benutzerdefinierte Richtlinie für Auto Scaling erstellen. Die folgende Tabelle beschreibt die Unterschiede zwischen den Optionen.

	Amazon EMR Managed Scaling	Benutzerdefinierte automatische Skalierung
Skalieren von Richtlinien und Regeln	Keine Richtlinie erforderlich. Amazon EMR verwaltet die Aktivität von Auto Scaling durch kontinuierliche Auswertung von Cluster-Metriken und optimierte Skalierungsentscheidungen.	Sie müssen die Richtlinien und Regeln für das Auto Scaling definieren und verwalten, z. B. die spezifischen Bedingungen, die Skalierungsaktivitäten, Evaluierungszeiträume, Ruhephasen usw. auslösen.
Unterstützte Versionen für Amazon EMR	Amazon-EMR-Version 5.30.0 und höher (außer Amazon-EMR-Version 6.0.0)	Amazon-EMR-Version 4.0.0 und höher
Unterstützte Clusterzusammenstellung	Instance-Gruppen oder Instance-Flotten	Nur Instance-Gruppen
Konfiguration von Skalierungsgrenzen	Skalierungsgrenzwerte werden für den gesamten Cluster konfiguriert.	Skalierungslimits können nur für jede Instance-Gruppe konfiguriert werden.
Häufigkeit der Auswertung von Metriken	Alle 5 bis 10 Sekunden Eine häufigere Auswertung von Metriken ermöglicht es Amazon EMR, präzisere Skalierungsentscheidungen zu treffen.	Sie können die Auswertungszeiträume nur in Fünf-Minuten-Schritten definieren.
Unterstützte Anwendungen	Es werden nur YARN-Anwendungen wie Spark, Hadoop, Hive, Flink unterstützt. Amazon EMR Managed Scaling unterstützt keine	Sie können auswählen, welche Anwendungen unterstützt werden, wenn Sie die Regeln für eine automatische Skalierung definieren.

	Amazon EMR Managed Scaling	Benutzerdefinierte automatische Skalierung
	Anwendungen, die nicht auf YARN basieren, wie Presto oder HBase.	

Überlegungen

- Ein Amazon-EMR-Cluster besteht immer aus einem oder drei Primärknoten. Sobald Sie den Cluster zum ersten Mal konfiguriert haben, können Sie nur Core- und Aufgabenknoten skalieren. Sie können die Anzahl der Primärknoten für den Cluster nicht skalieren.
- Bei Instancegruppen werden Rekonfigurations- und Größenänderungsvorgänge nacheinander und nicht gleichzeitig ausgeführt. Wenn Sie eine Neukonfiguration initiieren, während die Größe einer Instancegruppe geändert wird, beginnt die Neukonfiguration, sobald die Instancegruppe die laufende Größenänderung abgeschlossen hat. Umgekehrt, wenn Sie eine Größenänderung einleiten, während eine Instancegruppe ihre Neukonfiguration durchführt.

Verwenden der verwalteten Skalierung in Amazon EMR

> **Important**
>
> Wir empfehlen dringend, die neueste Amazon-EMR-Version (Amazon EMR 6.14.0) für verwaltete Skalierung zu verwenden. In einigen frühen Versionen kann es zu zeitweiligen Anwendungsausfällen oder Verzögerungen bei der Skalierung kommen. Amazon EMR hat dieses Problem mit den 5.x-Versionen 5.30.2, 5.31.1, 5.32.1, 5.33.1 und höher sowie mit den 6.x-Versionen 6.1.1, 6.2.1, 6.3.1 und höher behoben. Weitere Informationen zur Region und Release-Verfügbarkeit finden Sie unter Verwaltete Skalierungsverfügbarkeit

Übersicht

Mit den Amazon-EMR-Versionen 5.30.0 und höher (außer Amazon EMR 6.0.0) können Sie die von Amazon EMR Managed Scaling aktivieren. Managed Scaling hilft Ihnen, die Anzahl der Instances oder Einheiten in Ihrem Cluster basierend auf der Workload automatisch zu erhöhen oder zu verringern. Amazon EMR wertet Cluster-Metriken kontinuierlich aus, um Skalierungsentscheidungen

zu treffen, die Ihre Cluster für Kosten und Geschwindigkeit optimieren. Verwaltete Skalierung ist für Cluster verfügbar, die entweder aus Instance-Gruppen oder Instance-Flotten bestehen.

Verwaltete Skalierungsverfügbarkeit

- In Asien-Pazifik (Jakarta) ist Amazon EMR Managed Scaling mit Amazon EMR 6.14.0 und höher verfügbar.
- Im Folgenden AWS-Regionen ist Amazon EMR Managed Scaling mit Amazon EMR 5.30.0 und 6.1.0 und höher verfügbar:

  USA Ost (Nord-Virginia und Ohio), USA West (Oregon und Nord-Kalifornien), Südamerika (São Paulo), Europa (Frankfurt, Irland, London, Mailand, Paris und Stockholm), Kanada (Zentral), Asien-Pazifik (Hongkong, Mumbai, Seoul, Singapur, Sydney und Tokio), Naher Osten (Bahrain), Afrika (Kapstadt), AWS GovCloud (US-Ost), AWS GovCloud (US-West), China (Peking) betrieben von Sinnet, China (Ningxia), betrieben von NWCD.
- Amazon EMR Managed Scaling funktioniert nur mit YARN-Anwendungen wie Spark, Hadoop, Hive und Flink. Es werden keine Anwendungen unterstützt, die nicht auf YARN basieren, wie Presto und HBase.

Verwaltete Skalierungsparameter

Sie müssen die folgenden Parameter für die verwaltete Skalierung konfigurieren. Das Limit gilt nur für die Kern- und Aufgabenknoten. Der Primärknoten kann nach der Erstkonfiguration nicht skaliert werden.

- Minimum (`MinimumCapacityUnits`) – Die untere Grenze der zulässigen EC2-Kapazität in einem Cluster. Sie wird durch vCPU-Kerne oder Instances für Instance-Gruppen gemessen. Sie wird in Einheiten für Instance-Flotten gemessen.
- Maximum (`MaximumCapacityUnits`) – Die Obergrenze der zulässigen EC2-Kapazität in einem Cluster. Sie wird durch vCPU-Kerne oder Instances für Instance-Gruppen gemessen. Sie wird in Einheiten für Instance-Flotten gemessen.
- On-Demand-Limit (`MaximumOnDemandCapacityUnits`) (optional) – Die Obergrenze der zulässigen EC2-Kapazität für den On-Demand-Markttyp in einem Cluster. Wenn dieser Parameter nicht angegeben wird, wird der Standardwert `MaximumCapacityUnits` verwendet.
  - Dieser Parameter wird verwendet, um die Kapazitätszuweisung zwischen On-Demand- und Spot Instances aufzuteilen. Wenn Sie beispielsweise den Minimalparameter auf 2 Instances, den Maximalparameter auf 100 Instances und das On-Demand-Limit auf 10 Instances

festlegen, skaliert Amazon EMR Managed Scaling auf bis zu 10 On-Demand-Instances und weist die verbleibende Kapazität Spot Instances zu. Weitere Informationen finden Sie unter Knotenzuweisungsszenarien.

- Maximale Core-Knoten (`MaximumCoreCapacityUnits`) (optional) – Die Obergrenze der zulässigen EC2-Kapazität für den Core-Knotentyp in einem Cluster. Wenn dieser Parameter nicht angegeben wird, wird der Standardwert `MaximumCapacityUnits` verwendet.
  - Dieser Parameter wird verwendet, um die Kapazitätszuweisung zwischen Core- und Aufgabenknoten aufzuteilen. Wenn Sie beispielsweise den Minimalparameter auf 2 Instances, das Maximum auf 100 Instances und den maximalen Core-Knoten auf 17 Instances festlegen, skaliert Amazon EMR Managed Scaling auf bis zu 17 Core-Knoten und weist die verbleibenden 83 Instances Aufgabenknoten zu. Weitere Informationen finden Sie unter Knotenzuweisungsszenarien.

Weitere Informationen zu verwalteten Skalierungsparametern finden Sie unter `ComputeLimits`.

Hinweise zu Amazon EMR Managed Scaling

- Verwaltete Skalierung wird in limitierten AWS-Regionen und Amazon-EMR-Versionen unterstützt. Weitere Informationen finden Sie unter Verwaltete Skalierungsverfügbarkeit.
- Sie müssen die folgenden Parameter für die Amazon EMR Managed Scaling konfigurieren. Weitere Informationen finden Sie unter Verwaltete Skalierungsparameter.
- Um verwaltete Skalierung verwenden zu können, muss der Metrics-Collector-Prozess in der Lage sein, eine Verbindung zum öffentlichen API-Endpunkt für die verwaltete Skalierung in API Gateway herzustellen. Wenn Sie einen privaten DNS-Namen mit Amazon Virtual Private Cloud verwenden, funktioniert verwaltetes Scaling nicht ordnungsgemäß. Um sicherzustellen, dass die verwaltete Skalierung funktioniert, empfehlen wir, dass Sie eine der folgenden Aktionen ausführen:
  - Entfernen Sie den VPC-Endpunkt der API-Gateway-Schnittstelle aus Ihrer Amazon VPC.
  - Folgen Sie den Anweisungen unter Warum erhalte ich den Fehler HTTP 403 Forbidden, wenn ich von einer VPC aus eine Verbindung zu meinen API-Gateway-APIs herstelle?, um die Einstellung des privaten DNS-Namens zu deaktivieren.
  - Starten Sie Ihren Cluster stattdessen in einem privaten Subnetz. Weitere Informationen finden Sie im Thema Private Subnetze.
- Wenn Ihre YARN-Jobs während des Herunterskalierens zeitweise langsam sind und die YARN Ressource Manager-Protokolle zeigen, dass die meisten Ihrer Knoten während dieser Zeit auf der Negativliste standen, können Sie den Schwellenwert für die Außerbetriebnahme anpassen.

Reduzieren Sie den `spark.blacklist.decommissioning.timeout` von einer Stunde auf eine Minute, um den Knoten für andere ausstehende Container verfügbar zu machen, um die Aufgabenverarbeitung fortzusetzen.

Sie sollten auch einen höheren Wert `YARN.resourcemanager.nodemanager-graceful-decommission-timeout-secs` festlegen, um sicherzustellen, dass Amazon EMR das Beenden des Knotens nicht erzwingt, solange die längste „Spark-Task“ noch auf dem Knoten läuft. Die aktuelle Standardeinstellung ist 60 Minuten, was bedeutet, dass YARN den Container nach 60 Minuten auf jeden Fall beendet, sobald der Knoten in den Stilllegungszustand übergeht.

Die folgende Protokollzeile von YARN Resource Manager zeigt Knoten, die dem Status „Außerbetriebnahme“ hinzugefügt wurden:

```
2021-10-20 15:55:26,994 INFO
 org.apache.hadoop.YARN.server.resourcemanager.DefaultAMSProcessor
 (IPC Server handler 37 on default port 8030): blacklist are updated in
 Scheduler.blacklistAdditions: [ip-10-10-27-207.us-west-2.compute.internal,
 ip-10-10-29-216.us-west-2.compute.internal, ip-10-10-31-13.us-
west-2.compute.internal, ... , ip-10-10-30-77.us-west-2.compute.internal],
 blacklistRemovals: []
```

Erfahren Sie mehr darüber wie Amazon EMR bei der Außerbetriebnahme von Knoten mit YARN Ablehnungsliste integriert wird, zu Fällen, in denen Knoten in Amazon EMR abgelehnt werden können, und zur Konfiguration des Verhaltens bei der Außerbetriebnahme von Spark-Knoten.

- Eine übermäßige Auslastung von EBS-Volumes kann zu Problemen bei der verwalteten Skalierung führen. Wir empfehlen, das EBS-Volumen unter einer Auslastung 90 % zu halten. Weitere Informationen finden Sie unter Instance-Speicher.
- Amazon-CloudWatch-Metriken sind entscheidend für den Betrieb von Amazon EMR Managed Scaling. Wir empfehlen Ihnen, die Amazon-CloudWatch-Metriken genau zu überwachen, um sicherzustellen, dass keine Daten fehlen. Weitere Informationen darüber, wie Sie CloudWatch-Alarme konfigurieren können, um fehlende Metriken zu erkennen, finden Sie unter Amazon-CloudWatch-Alarme verwenden.
- Verwaltete Skalierungsvorgänge auf Clustern der Versionen 5.30.0 und 5.30.1, ohne dass Presto installiert ist, können zu Anwendungsausfällen führen oder dazu führen, dass eine einheitliche Instance-Gruppe oder Instance-Flotte unverändert im Status `ARRESTED` bleibt, insbesondere wenn auf einen Herunterskalierungsvorgang schnell ein Skalierungsvorgang folgt.

Um dieses Problem zu umgehen, wählen Sie Presto als zu installierende Anwendung, wenn Sie einen Cluster mit den Amazon-EMR-Versionen 5.30.0 und 5.30.1 erstellen, auch wenn Ihr Auftrag Presto nicht benötigt.

- Wenn Sie den maximalen Core-Knoten und das On-Demand-Limit für Amazon EMR Managed Scaling festlegen, sollten Sie die Unterschiede zwischen Instance-Gruppen und Instance-Flotten berücksichtigen. Jede Instance-Gruppenkonfiguration besteht jeder Knotentyp aus demselben Instance-Typ und derselben Kaufoption für Instances: On-Demand oder Spot. Für jede Instance-Flotte geben Sie bis zu fünf Instance-Typen an, die als On-Demand- und Spot Instances bereitgestellt werden können. Weitere Informationen finden Sie unter Erstellen eines Clusters mit Instance-Flotten oder einheitlichen Instance-Gruppen, Instance Flotten Optionen und Knotenzuweisungsszenarien.
- Wenn Sie bei Amazon EMR 5.30.0 und höher die standardmäßige ausgehende Regel Alle zulassen auf 0.0.0.0/ für die Master-Sicherheitsgruppe entfernen, müssen Sie eine Regel hinzufügen, die ausgehende TCP-Konnektivität zu Ihrer Sicherheitsgruppe für den Servicezugriff am Port 9443 zulässt. Ihre Sicherheitsgruppe für den Servicezugang muss auch eingehenden TCP-Verkehr auf Port 9443 von der Master-Sicherheitsgruppe zulassen. Weitere Informationen über die Konfiguration von Sicherheitsgruppen finden Sie unter Von Amazon EMR verwaltete Sicherheitsgruppe für die primäre Instance (private Subnetze).
- Die verwaltete Skalierung unterstützt das Feature YARN-Knotenbeschriftungen nicht. Vermeiden Sie die Verwendung von Knotenbezeichnungen auf Clustern mit verwalteter Skalierung. Erlauben Sie beispielsweise nicht, dass Executors nur auf Aufgabenknoten ausgeführt werden. Wenn Sie Knotenbezeichnungen in Ihren Amazon-EMR-Clustern verwenden, stellen Sie möglicherweise fest, dass Ihr Cluster nicht hochskaliert wird, was zu einer Verlangsamung Ihrer Anwendung führen kann.
- Sie können AWS CloudFormation verwenden, um Amazon EMR Managed Scaling zu konfigurieren. Weitere Informationen finden Sie unter AWS::EMR::Cluster im AWS CloudFormation-Benutzerhandbuch.

Feature-Verlauf

In dieser Tabelle sind Aktualisierungen zur Funktion Amazon EMR Managed Scaling aufgeführt.

Datum der Veröffentlichung	Funktion	Versionen für Amazon EMR
10. Oktober 2023	Managed Scaling ist in der `ap-southeast-3` -Region Asien-Pazifik (Jakarta) verfügbar.	6.14.0 und höher
28. Juli 2023	Verbesserte verwaltete Skalierung, um beim hochskalieren zu einer anderen Aufgaben-Instance-Gruppe zu wechseln, wenn es bei Amazon EMR beim hochskalieren mit der aktuellen Instance-Gruppe zu Verzögerungen kommt.	5.34.0 und höher, 6.4.0 und höher
16. Juni 2023	Verbesserte verwaltete Skalierung, sodass erkannt wird, auf welchen Knoten der Application Master ausgeführt wird, sodass diese Knoten nicht herunterskaliert werden. Weitere Informationen finden Sie unter Grundlegendes zu Strategien und Szenarien für die Knotenzuweisung.	5.34.0 und höher, 6.4.0 und höher
21. März 2022	Spark Shuffle Data Awareness wurde hinzugefügt, das beim Herunterskalieren von Clustern verwendet wird. Für Amazon-EMR-Cluster mit Apache Spark und aktiviertem verwaltetem Skalierungsfeature überwacht Amazon EMR kontinuierlich Spark-	5.34.0 und höher, 6.4.0 und höher

Datum der Veröffentlichung	Funktion	Versionen für Amazon EMR
	Executoren und Zwischens peicherorte für Shuffle-D aten. Anhand dieser Informati onen skaliert Amazon EMR nur ungenutzte Instances herunter, die keine aktiv genutzten Shuffle-Daten enthalten. Dadurch wird eine Neuberechnung verloren gegangener Shuffle-Daten verhindert, was zur Senkung der Kosten und zur Verbesser ung der Arbeitsleistung beiträgt. Weitere Informati onen finden Sie unter im Spark-Programmierhandbuch.	

Konfigurieren der verwalteten Skalierung für Amazon EMR

In den folgenden Abschnitten wird erklärt, wie Sie einen EMR-Cluster starten, der verwaltete Skalierung mit dem AWS Management Console, dem AWS SDK for Java oder dem AWS Command Line Interface verwendet.

Themen

- AWS Management Console zum Konfigurieren der verwalteten Skalierung verwenden
- AWS CLI zum Konfigurieren der verwalteten Skalierung verwenden
- AWS SDK for Java zum Konfigurieren der verwalteten Skalierung verwenden

AWS Management Console zum Konfigurieren der verwalteten Skalierung verwenden

Sie können die Amazon-EMR-Konsole verwenden, um die verwaltete Skalierung zu konfigurieren, wenn Sie einen Cluster erstellen, oder um eine verwaltete Skalierungsrichtlinie für einen laufenden Cluster zu ändern.

New console

Um die verwaltete Skalierung zu konfigurieren, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Wählen Sie eine Amazon-EMR-Version emr-5.30.0 oder höher, außer Version emr-6.0.0.
4. Wählen Sie unter Option Clusterskalierung und -Bereitstellungsoption EMR-verwaltete Skalierung verwenden aus. Geben Sie das Minimum – und Maximum von Instances, die maximale Anzahl an Core-Knoten-Instances und die maximale Anzahl von On-Demand-Instances an.
5. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
6. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Wie Sie die verwaltete Skalierung auf einem vorhandenen Cluster mit der neuen Konsole ändern

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten.
3. Suchen Sie auf der Registerkarte Instances der Cluster-Detailseite den Abschnitt Instancegruppeneinstellungen. Geben Sie im Abschnitt Clusterskalierung bearbeiten neue Werte für die Minimum- und Maximum-Anzahl von Instances und das On-Demand-Limit an.

Old console

Wenn Sie einen Cluster auf der alten Konsole erstellen, können Sie die verwaltete Skalierung mithilfe der Schnelloption oder der erweiterten Clusterkonfigurationsoptionen konfigurieren. Sie können auch eine Richtlinie für verwaltete Skalierung für einen ausgeführten Cluster erstellen oder ändern, indem Sie die Einstellungen für Verwaltete Skalierung auf der Seite Zusammenfassung oder Hardware ändern.

So verwenden Sie die Schnelloption zum Konfigurieren der verwalteten Skalierung beim Erstellen eines Clusters mit der alten Konsole

1. Öffnen Sie die Amazon-EMR-Konsole, wählen Sie Cluster erstellen und öffnen Sie Cluster erstellen – Schnelloptionen.
2. Aktivieren Sie im Abschnitt Hardwarekonfiguration neben der Option Clusterskalierung und -bereitstellung das Kontrollkästchen, um die Skalierung von Clusterknoten auf der Grundlage des Workloads zu aktivieren.
3. Geben Sie unter Core und Aufgabeneinheiten die Minimum- und Maximum-Anzahl von Core- und Aufgaben-Instances an.

So verwenden Sie die erweiterte Option zum Konfigurieren der verwalteten Skalierung beim Erstellen eines Clusters mit der alten Konsole

1. Wählen Sie in der Amazon EMR-Konsole Cluster erstellen und Gehen Sie zu den erweiterten Optionen, wählen Sie dann Optionen für Schritt 1: Software und Schritte aus und wechseln dann zu Schritt 2: Hardware-Konfiguration.
2. Wählen Sie im Abschnitt Clusterzusammenstellung die Optionen Instance-Flotten oder Einheitliche Instance-Gruppen aus.
3. Wählen Sie unter Option Clusterskalierung und -Bereitstellung die Option Clusterskalierung aktivieren aus. Wählen Sie anschließend EMR-verwaltete Skalierung verwenden aus. Geben Sie unter Core- und Aufgabeneinheiten die minimale und maximale Anzahl von Instances oder Instance-Flotteneinheiten, das On-Demand-Limit und die maximale Anzahl an Core-Knoten an.

   Für Cluster, die aus Instance-Gruppen bestehen, können Sie auch Benutzerdefinierte Richtlinie für automatische Skalierung erstellen auswählen, wenn Sie benutzerdefinierte Richtlinien für die automatische Skalierung für jede Instance-Gruppe definieren möchten. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .

Um die verwaltete Skalierung auf einem vorhandenen Cluster mit der alten Konsole zu ändern

1. Öffnen Sie die Amazon EMR-Konsole, wählen Sie Ihren Cluster aus der Clusterliste aus und wählen Sie dann die Registerkarte Hardware.

2. Wählen Sie im Bereich Clusterskalierung die Option Bearbeiten für Amazon EMR Managed Scaling aus.
3. Geben Sie im Abschnitt Clusterskalierung und Bereitstellung neue Werte für die Minimum- und Maximum-Anzahl von Instances und das On-Demand-Limit an.

AWS CLI zum Konfigurieren der verwalteten Skalierung verwenden

Sie können AWS CLI-Befehle für Amazon EMR verwenden, um die verwaltete Skalierung beim Erstellen eines Clusters zu konfigurieren. Sie können eine Kurzschreibweise mit der passenden JSON-Konfiguration in den entsprechenden Befehlen oder eine Referenzdatei mit der JSON-Konfiguration verwenden. Sie können auch eine Richtlinie für verwaltete Skalierung auf einen vorhandenen Cluster anwenden und eine zuvor angewendete Richtlinie für verwaltete Skalierung entfernen. Darüber hinaus können Sie Details einer Skalierungsrichtlinien-Konfiguration aus einem aktuell ausgeführten Cluster abrufen.

Aktivieren der verwalteten Skalierung während des Clusterstarts

Sie können die verwaltete Skalierung während des Clusterstarts aktivieren, wie im folgenden Beispiel veranschaulicht wird.

```
aws emr create-cluster \
 --service-role EMR_DefaultRole \
 --release-label emr-5.36.1 \
 --name EMR_Managed_Scaling_Enabled_Cluster \
 --applications Name=Spark Name=Hbase \
 --ec2-attributes KeyName=keyName,InstanceProfile=EMR_EC2_DefaultRole \
 --instance-groups InstanceType=m4.xlarge,InstanceGroupType=MASTER,InstanceCount=1
 InstanceType=m4.xlarge,InstanceGroupType=CORE,InstanceCount=2 \
 --region us-east-1 \
 --managed-scaling-policy
 ComputeLimits='{MinimumCapacityUnits=2,MaximumCapacityUnits=4,UnitType=Instances}'
```

Sie können eine verwaltete Richtlinienkonfiguration auch mit der Option „-managed-scaling-policy“ angeben, wenn Sie `create-cluster` verwenden.

Anwenden einer Richtlinie für verwaltete Skalierung auf einen vorhandenen Cluster

Sie können eine Richtlinie für verwaltete Skalierung auf einen vorhandenen Cluster anwenden, wie im folgenden Beispiel veranschaulicht wird.

```
aws emr put-managed-scaling-policy
--cluster-id j-123456
--managed-scaling-policy ComputeLimits='{MinimumCapacityUnits=1,
MaximumCapacityUnits=10,  MaximumOnDemandCapacityUnits=10, UnitType=Instances}'
```

Sie können eine Richtlinie für verwaltete Skalierung auch auf einen vorhandenen Cluster anwenden, indem Sie den Befehl `aws emr put-managed-scaling-policy` verwenden. Im folgenden Beispiel wird ein Verweis auf eine JSON-Datei verwendet, `managedscaleconfig.json`, die die Konfiguration der Richtlinie für verwaltete Skalierung angibt.

```
aws emr put-managed-scaling-policy --cluster-id j-123456 --managed-scaling-policy
 file://./managedscaleconfig.json
```

Das folgende Beispiel zeigt den Inhalt der Datei `managedscaleconfig.json`, in der die Richtlinie für verwaltete Skalierung definiert wird.

```
{
    "ComputeLimits": {
        "UnitType": "Instances",
        "MinimumCapacityUnits": 1,
        "MaximumCapacityUnits": 10,
        "MaximumOnDemandCapacityUnits": 10
    }
}
```

Abrufen einer Richtlinienkonfiguration für verwaltete Skalierung

Der Befehl `GetManagedScalingPolicy` ruft die Richtlinienkonfiguration ab. Mit dem folgenden Befehl wird beispielsweise die Konfiguration für den Cluster mit der Cluster-ID `j-123456` abgerufen.

```
aws emr get-managed-scaling-policy --cluster-id j-123456
```

Der Befehl generiert die folgende Beispielausgabe:

```
{
   "ManagedScalingPolicy": {
      "ComputeLimits": {
         "MinimumCapacityUnits": 1,
         "MaximumOnDemandCapacityUnits": 10,
         "MaximumCapacityUnits": 10,
         "UnitType": "Instances"
```

```
      }
   }
}
```

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Entfernen der Richtlinie für verwaltete Skalierung

Mit dem Befehl `RemoveManagedScalingPolicy` wird die Richtlinienkonfiguration entfernt. Mit dem folgenden Befehl wird beispielsweise die Konfiguration für den Cluster mit der Cluster-ID `j-123456` entfernt.

```
aws emr remove-managed-scaling-policy --cluster-id j-123456
```

AWS SDK for Java zum Konfigurieren der verwalteten Skalierung verwenden

Der folgende Programmausschnitt zeigt, wie die verwaltete Skalierung mit dem AWS SDK for Java konfiguriert wird:

```
package com.amazonaws.emr.sample;

import java.util.ArrayList;
import java.util.List;

import com.amazonaws.AmazonClientException;
import com.amazonaws.auth.AWSCredentials;
import com.amazonaws.auth.AWSStaticCredentialsProvider;
import com.amazonaws.auth.profile.ProfileCredentialsProvider;
import com.amazonaws.regions.Regions;
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduce;
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduceClientBuilder;
import com.amazonaws.services.elasticmapreduce.model.Application;
import com.amazonaws.services.elasticmapreduce.model.ComputeLimits;
import com.amazonaws.services.elasticmapreduce.model.ComputeLimitsUnitType;
import com.amazonaws.services.elasticmapreduce.model.InstanceGroupConfig;
import com.amazonaws.services.elasticmapreduce.model.JobFlowInstancesConfig;
import com.amazonaws.services.elasticmapreduce.model.ManagedScalingPolicy;
import com.amazonaws.services.elasticmapreduce.model.RunJobFlowRequest;
import com.amazonaws.services.elasticmapreduce.model.RunJobFlowResult;

public class CreateClusterWithManagedScalingWithIG {
```

```
public static void main(String[] args) {
 AWSCredentials credentialsFromProfile = getCreadentials("AWS-Profile-Name-Here");

 /**
  * Create an Amazon EMR client with the credentials and region specified in order to
create the cluster
  */
 AmazonElasticMapReduce emr = AmazonElasticMapReduceClientBuilder.standard()
  .withCredentials(new AWSStaticCredentialsProvider(credentialsFromProfile))
  .withRegion(Regions.US_EAST_1)
  .build();

 /**
  * Create Instance Groups - Primary, Core, Task
  */
 InstanceGroupConfig instanceGroupConfigMaster = new InstanceGroupConfig()
   .withInstanceCount(1)
   .withInstanceRole("MASTER")
   .withInstanceType("m4.large")
   .withMarket("ON_DEMAND");

 InstanceGroupConfig instanceGroupConfigCore = new InstanceGroupConfig()
  .withInstanceCount(4)
  .withInstanceRole("CORE")
  .withInstanceType("m4.large")
  .withMarket("ON_DEMAND");

 InstanceGroupConfig instanceGroupConfigTask = new InstanceGroupConfig()
  .withInstanceCount(5)
  .withInstanceRole("TASK")
  .withInstanceType("m4.large")
  .withMarket("ON_DEMAND");

 List<InstanceGroupConfig> igConfigs = new ArrayList<>();
 igConfigs.add(instanceGroupConfigMaster);
 igConfigs.add(instanceGroupConfigCore);
 igConfigs.add(instanceGroupConfigTask);

       /**
        *  specify applications to be installed and configured when Amazon EMR creates
the cluster
        */
 Application hive = new Application().withName("Hive");
 Application spark = new Application().withName("Spark");
```

```
 Application ganglia = new Application().withName("Ganglia");
 Application zeppelin = new Application().withName("Zeppelin");

 /**
  * Managed Scaling Configuration -
        * Using UnitType=Instances for clusters composed of instance groups
  *
        * Other options are:
        * UnitType = VCPU ( for clusters composed of instance groups)
        * UnitType = InstanceFleetUnits ( for clusters composed of instance fleets)
        **/
 ComputeLimits computeLimits = new ComputeLimits()
   .withMinimumCapacityUnits(1)
   .withMaximumCapacityUnits(20)
   .withUnitType(ComputeLimitsUnitType.Instances);

 ManagedScalingPolicy managedScalingPolicy = new ManagedScalingPolicy();
 managedScalingPolicy.setComputeLimits(computeLimits);

 // create the cluster with a managed scaling policy
 RunJobFlowRequest request = new RunJobFlowRequest()
         .withName("EMR_Managed_Scaling_TestCluster")
         .withReleaseLabel("emr-5.36.1")          // Specifies the version label for
the Amazon EMR release; we recommend the latest release
         .withApplications(hive,spark,ganglia,zeppelin)
         .withLogUri("s3://path/to/my/emr/logs")  // A URI in S3 for log files is
required when debugging is enabled.
         .withServiceRole("EMR_DefaultRole")      // If you use a custom IAM service
role, replace the default role with the custom role.
         .withJobFlowRole("EMR_EC2_DefaultRole")  // If you use a custom Amazon EMR
role for EC2 instance profile, replace the default role with the custom Amazon EMR
role.
         .withInstances(new JobFlowInstancesConfig().withInstanceGroups(igConfigs)
             .withEc2SubnetId("subnet-123456789012345")
             .withEc2KeyName("my-ec2-key-name")
             .withKeepJobFlowAliveWhenNoSteps(true))
         .withManagedScalingPolicy(managedScalingPolicy);
    RunJobFlowResult result = emr.runJobFlow(request);

    System.out.println("The cluster ID is " + result.toString());
}

public static AWSCredentials getCredentials(String profileName) {
 // specifies any named profile in .aws/credentials as the credentials provider
```

```
  try {
   return new ProfileCredentialsProvider("AWS-Profile-Name-Here")
     .getCredentials();
        } catch (Exception e) {
            throw new AmazonClientException(
                    "Cannot load credentials from .aws/credentials file. " +
                    "Make sure that the credentials file exists and that the profile
 name is defined within it.",
                    e);
        }
 }

 public CreateClusterWithManagedScalingWithIG() { }
}
```

Grundlegendes zu Strategien und Szenarien für die Knotenzuweisung

Dieser Abschnitt gibt einen Überblick über die Strategie zur Knotenzuweisung und allgemeine Skalierungsszenarien, die Sie mit Amazon EMR Managed Scaling verwenden können.

Knotenzuweisungsstrategie

Amazon EMR Managed Scaling weist Core- und Aufgabenknoten auf der Grundlage der folgenden Strategien zum hochskalieren und herunterskalieren zu:

Strategie zum hochskalieren

- Amazon EMR Managed Scaling fügt zuerst Kapazität zu den Core-Knoten und dann zu den Aufgabenknoten hinzu, bis die maximal zulässige Kapazität erreicht ist oder bis die gewünschte Hochskalierungs-Zielkapazität erreicht ist.
- Wenn Amazon EMR bei der Skalierung mit der aktuellen Instance-Gruppe verzögert wird, wechseln Cluster, die verwaltete Skalierung verwenden, automatisch zu einer anderen Task-Instance-Gruppe.
- Wenn der `MaximumCoreCapacityUnits`-Parameter festgelegt ist, skaliert Amazon EMR die Core-Knoten, bis die Kerneinheiten den maximal zulässigen Grenzwert erreichen. Die gesamte verbleibende Kapazität wird den Aufgabenknoten hinzugefügt.
- Wenn der `MaximumOnDemandCapacityUnits`-Parameter festgelegt ist, skaliert Amazon EMR den Cluster mithilfe der On-Demand-Instances, bis die On-Demand-Einheiten den maximal zulässigen Grenzwert erreichen. Die gesamte verbleibende Kapazität wird mithilfe von Spot Instances hinzugefügt.

- Wenn sowohl `MaximumCoreCapacityUnits` als auch der `MaximumOnDemandCapacityUnits` Parameter festgelegt sind, berücksichtigt Amazon EMR bei der Skalierung beide Grenzwerte.

  Wenn `MaximumCoreCapacityUnits` beispielsweise kleiner als `MaximumOnDemandCapacityUnits` ist, skaliert Amazon EMR zunächst die Core-Knoten, bis die Kernkapazitätsgrenze erreicht ist. Für die verbleibende Kapazität verwendet Amazon EMR zunächst On-Demand-Instances, um Aufgabenknoten zu skalieren, bis das On-Demand-Limit erreicht ist, und verwendet dann Spot Instances für Aufgabenknoten.

Strategie zum herunterskalieren

- Amazon-EMR-Versionen 5.34.0 und höher sowie Amazon-EMR-Versionen 6.4.0 und höher unterstützen verwaltete Skalierung, die Spark-Shuffle-Daten berücksichtigt (Daten, die Spark partitionsübergreifend verteilt, um bestimmte Vorgänge auszuführen). Weitere Informationen zu Shuffle-Vorgängen finden Sie im Spark-Programmierhandbuch. Bei der verwalteten Skalierung werden nur Instances herunterskaliert, die nicht ausreichend ausgelastet sind und keine aktiv genutzten Shuffle-Daten enthalten. Diese intelligente Skalierung verhindert den unbeabsichtigten Verlust von Shuffle-Daten, sodass keine erneuten Versuche und die Neuberechnung von Zwischendaten erforderlich sind.
- Amazon EMR Managed Scaling entfernt zuerst Aufgabenknoten und dann Core-Knoten, bis die gewünschte Herunterskalierungs-Zielkapazität erreicht ist. Der Cluster wird niemals unter die Mindestbeschränkungen in der verwalteten Skalierungsrichtlinie skaliert.
- Innerhalb jedes Knotentyps (entweder Core-Knoten oder Aufgabenknoten) entfernt Amazon EMR Managed Scaling zuerst Spot Instances und dann On-Demand-Instances.
- Bei Clustern, die mit Amazon EMR 5.x-Versionen 5.34.0 und höher und 6.x-Versionen 6.4.0 und höher gestartet werden, skaliert Amazon EMR Managed Scaling keine Knoten, auf denen `ApplicationMaster` für Apache Spark ausgeführt wird. Dadurch werden Fehlschläge und Wiederholungen von Aufträgen minimiert, was zur Verbesserung der Auftragsleistung und zur Senkung der Kosten beiträgt. Um zu überprüfen, welche Knoten in Ihrem Cluster `ApplicationMaster` ausführen, besuchen Sie den Spark History Server und filtern Sie auf der Registerkarte Executors Ihrer Spark-Anwendungs-ID nach dem Treiber.

Wenn der Cluster nicht ausgelastet ist, storniert Amazon EMR das Hinzufügen neuer Instances aus einer früheren Evaluierung und führt Herunterskalierungsvorgänge durch. Wenn der Cluster stark ausgelastet ist, bricht Amazon EMR das Entfernen von Instances ab und führt Hochskalierungsvorgänge durch.

Überlegungen zur Knotenzuweisung

Wir empfehlen, die On-Demand-Kaufoption für Core-Knoten zu verwenden, um HDFS-Datenverlust im Falle einer Spot-Rückforderung zu vermeiden. Sie können die Spot-Kaufoption für Aufgabenknoten verwenden, um die Kosten zu senken und die Auftragsausführung zu beschleunigen, wenn mehr Spot Instances zu Aufgabenknoten hinzugefügt werden.

Knotenzuweisungsszenarien

Sie können je nach Bedarf verschiedene Skalierungsszenarien erstellen, indem Sie die Core-Knotenparameter Maximum, Minimum, On-Demand-Limit und Maximum in unterschiedlichen Kombinationen einrichten.

Szenario 1: Nur Core-Knoten skalieren

Um nur Core-Knoten zu skalieren, müssen die verwalteten Skalierungsparameter die folgenden Anforderungen erfüllen:

- Das On-Demand-Limit entspricht der maximalen Grenze.
- Der maximale Core-Knoten entspricht der maximalen Grenze.

Wenn das On-Demand-Limit und die maximale Anzahl an Core-Knoten nicht angegeben sind, verwenden beide Parameter standardmäßig die maximale Grenze.

Das folgende Beispiele zeigt das Szenario der ausschließlichen Skalierung von Core-Knoten.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Gruppen Core: 1 On-Demand Aufgabe: 1 On-Demand- und 1 Spot	`UnitType`: Instances `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 20	Skalieren Sie mithilfe des On-Demand-Typs zwischen 1 und 20 Instances oder Instance-Flotteneinheiten auf Core-Knoten.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Flotten Core: 1 On-Demand Aufgabe: 1 On-Demand- und 1 Spot	UnitType: InstanceFleetUnits `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 20	Keine Skalierung auf Aufgabenknoten.

Szenario 2: Nur Aufgabenknoten skalieren

Um nur Aufgabenknoten zu skalieren, müssen die verwalteten Skalierungsparameter die folgenden Anforderungen erfüllen:

- Der maximale Core-Knoten muss der Mindestgrenze entsprechen.

Das folgende Beispiele zeigt das Szenario der ausschließlichen Skalierung von Aufgabenknoten.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Gruppen Core: 2 On-Demand Aufgabe: 1 Spot	`UnitType`: Instances `MinimumCapacityUnits` : 2 `MaximumCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 2	Halten Sie die Anzahl der Core-Knoten konstant bei 2 und skalieren Sie nur Aufgabenknoten zwischen 0 und 18 Instances oder Instance-Flotteneinheiten.
Instance-Flotten Core: 2 On-Demand	`UnitType`: InstanceFleetUnits `MinimumCapacityUnits` : 2	

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Aufgabe: 1 Spot	`MaximumCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 2	Die Kapazität zwischen Mindest- und Höchstgrenzen wird nur den Aufgabenknoten hinzugefügt.

Szenario 4: Nur On-Demand-Instance im Cluster

Um nur über On-Demand-Instances zu verfügen, müssen Ihr Cluster und die verwalteten Skalierungsparameter die folgende Anforderung erfüllen:

- Das On-Demand-Limit entspricht der maximalen Grenze.

  Wenn das On-Demand-Limit nicht angegeben ist, entspricht der Parameterwert standardmäßig der Höchstgrenze. Der Standardwert gibt an, dass Amazon EMR nur On-Demand-Instances skaliert.

Wenn die maximale Anzahl an Core-Knoten kleiner als die maximale Grenze ist, kann der Parameter „Maximaler Core-Knoten“ verwendet werden, um die Kapazitätszuweisung zwischen Core- und Aufgabenknoten aufzuteilen.

Um dieses Szenario in einem Cluster zu aktivieren, der aus Instance-Gruppen besteht, müssen alle Knotengruppen im Cluster bei der Erstkonfiguration den Markttyp On-Demand verwenden.

Die folgenden Beispiele veranschaulichen das Szenario, in dem On-Demand-Instances im gesamten Cluster vorhanden sind.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Gruppen Core: 1 On-Demand	`UnitType`: Instances `MinimumCapacityUnits` : 1	Skalieren Sie mithilfe des On-Demand-Typs

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Aufgabe: 1 On-Demand	`MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 12	zwischen 1 und 12 Instances oder Instance-Flotteneinheiten auf Core-Knoten. Skalieren Sie die verbleibende Kapazität mithilfe von On-Demand-Funktion auf Aufgabenknoten. Keine Skalierung mit Spot Instances.
Instance-Flotten Core: 1 On-Demand Aufgabe: 1 On-Demand	`UnitType`: InstanceFleetUnits `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 20 `MaximumCoreCapacityUnits` : 12	

Szenario 4: Nur Spot Instances im Cluster

Um nur Spot Instances zu verwenden, müssen die verwalteten Skalierungsparameter die folgenden Anforderungen erfüllen:

- Das On-Demand-Limit ist auf 0 gesetzt.

Wenn die maximale Anzahl an Core-Knoten kleiner als die maximale Grenze ist, kann der Parameter „Maximaler Core-Knoten“ verwendet werden, um die Kapazitätszuweisung zwischen Core- und Aufgabenknoten aufzuteilen.

Um dieses Szenario in einem Cluster zu aktivieren, der aus Instancegruppen besteht, muss die Kerninstancegruppe bei der Erstkonfiguration die Spot-Kaufoption verwenden. Wenn in der Aufgaben-Instance-Gruppe keine Spot Instance vorhanden ist, erstellt Amazon EMR Managed Scaling bei Bedarf eine Auftragsgruppe, die Spot Instances verwendet.

Die folgenden Beispiele veranschaulichen das Szenario, in dem Spot Instances im gesamten Cluster vorhanden sind.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Gruppen Core: 1 Spot Aufgabe: 1 Spot	`UnitType`: Instances `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 0	Skalieren Sie mithilfe von Spot zwischen 1 und 20 Instances oder Instance-Flotteneinheiten auf Core-Knoten. Keine Skalierung beim On-Demand-Typ.
Instance-Flotten Core: 1 Spot Aufgabe: 1 Spot	`UnitType`: InstanceFleetUnits `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 0	

Szenario 5: On-Demand-Instances auf Core-Knoten und Spot Instances auf Aufgabenknoten skalieren

Um On-Demand-Instances auf Core-Knoten und Spot Instances auf Aufgabenknoten zu skalieren, müssen die verwalteten Skalierungsparameter die folgenden Anforderungen erfüllen:

- Das On-Demand-Limit muss dem maximalen Core-Knoten entsprechen.
- Sowohl das On-Demand-Limit als auch die maximale Anzahl an Core-Knoten müssen unter der maximalen Grenze liegen.

Um dieses Szenario in einem Cluster zu aktivieren, der aus Instance-Gruppen besteht, muss die Core-Knotengruppe die On-Demand-Kaufoption verwenden.

Die folgenden Beispiele veranschaulichen das Szenario der Skalierung von On-Demand-Instances auf Core-Knoten und Spot Instances auf Aufgabenknoten.

Ausgangszustand des Clusters	Skalierungsparameter	Skalierungs-Verhalten
Instance-Gruppen Core: 1 On-Demand Aufgabe: 1 On-Demand- und 1 Spot	`UnitType`: Instances `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 7 `MaximumCoreCapacityUnits` : 7	Hochskalieren Sie auf bis zu 6 On-Demand -Einheiten auf dem Core-Knoten, da sich bereits 1 On-Demand-Einheit auf dem Aufgabenknoten befindet und die maximale Anzahl für On-Demand -Einheiten 7 beträgt. Hochskalieren Sie anschließend auf bis zu 13 Spot-Einheiten auf Aufgabenknoten.
Instance-Flotten Core: 1 On-Demand Aufgabe: 1 On-Demand- und 1 Spot	`UnitType`: InstanceFleetUnits `MinimumCapacityUnits` : 1 `MaximumCapacityUnits` : 20 `MaximumOnDemandCapacityUnits` : 7 `MaximumCoreCapacityUnits` : 7	

Grundlegendes zu Metriken für verwaltete Skalierung

Amazon EMR veröffentlicht hochaufgelöste Metriken mit Daten mit einer Granularität von einer Minute, wenn die verwaltete Skalierung für einen Cluster aktiviert ist. Sie können Ereignisse für jede Initiierung und Beendigung der Größenänderung anzeigen, die durch verwaltete Skalierung mit der Amazon-EMR-Konsole oder Amazon-CloudWatch-Konsole gesteuert wird. CloudWatch-Metriken sind für den Betrieb von Amazon EMR Managed Scaling von entscheidender Bedeutung. Wir empfehlen Ihnen, die CloudWatch-Metriken genau zu überwachen, um sicherzustellen, dass keine Daten fehlen. Weitere Informationen darüber, wie Sie CloudWatch-Alarme konfigurieren können, um fehlende Metriken zu erkennen, finden Sie unter Amazon-CloudWatch-Alarme verwenden. Weitere

Informationen über CloudWatch Ereignisse mit Amazon EMR finden Sie in CloudWatch-Ereignisse überwachen.

Die folgenden Metriken geben die aktuelle oder Zielkapazitäten eines Clusters an. Diese Metriken sind nur verfügbar, wenn die verwaltete Skalierung aktiviert ist. Bei Clustern, die aus Instance-Flotten bestehen, werden die Cluster-Kapazitätsmetriken in `Units` gemessen. Bei Clustern, die aus Instance-Gruppen bestehen, werden die Clusterkapazitätsmetriken in `Nodes` oder `vCPU` basierend auf dem Einheitentyp gemessen, der in der Richtlinie für verwaltete Skalierung verwendet wird.

Metrik	Beschreibung
• `TotalUnitsRequested` • `TotalNodesRequested` • `TotalVCPURequested`	Die Gesamtzahl von Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl
• `TotalUnitsRunning` • `TotalNodesRunning` • `TotalVCPURunning`	Die aktuelle Gesamtzahl der Einheiten/Knoten/vCPUs, die in einem ausgeführten Cluster verfügbar sind. Wenn eine Clustergrößenänderung angefordert wird, wird diese Metrik aktualisiert, nachdem die neuen Instances hinzugefügt oder aus dem Cluster entfernt wurden. Einheiten: Anzahl
• `CoreUnitsRequested` • `CoreNodesRequested` • `CoreVCPURequested`	Die Zielnummer der CORE-Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl
• `CoreUnitsRunning` • `CoreNodesRunning`	Die aktuelle Anzahl von CORE-Einheiten/Knoten/vCPUs, die in einem Cluster ausgeführt werden. Einheiten: Anzahl

Metrik	Beschreibung
• `CoreVCPURunning`	
• `TaskUnitsRequested` • `TaskNodesRequested` • `TaskVCPURequested`	Die Zielnummer der AUFGABEN-Einheiten/Knoten/vCPUs in einem Cluster, die durch die verwaltete Skalierung bestimmt wird. Einheiten: Anzahl
• `TaskUnitsRunning` • `TaskNodesRunning` • `TaskVCPURunning`	Die aktuelle Anzahl von AUFGABEN-Einheiten/Knoten/v CPUs, die in einem Cluster ausgeführt werden. Einheiten: Anzahl

Die folgenden Metriken geben den Verwendungsstatus von Clustern und Anwendungen an. Diese Metriken sind für alle Amazon-EMR-Features verfügbar, werden jedoch mit einer höheren Auflösung mit Daten in einer einminütigen Granularität veröffentlicht, wenn die verwaltete Skalierung für einen Cluster aktiviert ist. Sie können die folgenden Metriken mit den Clusterkapazitätsmetriken in der vorherigen Tabelle korrelieren, um die Entscheidungen bezüglich der verwalteten Skalierung zu verständlich zu machen.

Metrik	Beschreibung
`AppsCompleted`	Anzahl der an YARN übermittelten abgeschlossenen Anwendungen. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`AppsPending`	Anzahl der an YARN übermittelten Anwendungen, die sich im ausstehenden Zustand befinden.

Metrik	Beschreibung
	Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`AppsRunning`	Anzahl der an YARN übermittelten Anwendungen, die ausgeführt werden. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`ContainerAllocated`	Anzahl der vom ResourceManager zugeordneten Ressourcen-Container. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`ContainerPending`	Anzahl der Container in der Warteschlange, die noch nicht zugeordnet worden sind. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`ContainerPendingRatio`	Verhältnis von ausstehenden Containern zu zugeordneten Containern (ContainerPendingRatio = ContainerPending / ContainerAllocated). Wenn ContainerAllocated = 0, dann ContainerPendingRatio = ContainerPending. Der Wert von ContainerPendingRatio ist eine Zahl, kein Prozentsa tz. Dieser Wert ist zum Skalieren von Cluster-Ressourcen anhand des Zuordnungsverhaltens des Containers hilfreich. Einheiten: Anzahl

Metrik	Beschreibung
`HDFSUtilization`	Prozentsatz des gegenwärtig benutzten HDFS-Speichers. Anwendungsfall: Cluster-Leistung analysieren Einheiten: Prozent
`IsIdle`	Gibt an, dass ein Cluster keine Arbeiten mehr ausführt, aber unverändert aktiv ist und Kosten verursacht. Der Wert beträgt 1, wenn weder Tasks noch Aufträge ausgeführt werden, andernfalls beträgt der Wert 0. Dieser Wert wird in 5-Minuten-Intervallen geprüft. Wenn der Wert 1 beträgt, bedeutet dies, dass der Cluster zum Zeitpunkt der Prüfung ungenutzt war, aber nicht die gesamten fünf Minuten. Um Fehlalarme zu vermeiden, sollten Sie einen Alarm auslösen, wenn dieser Wert mehrere aufeinander folgende fünfminüt ige Prüfungen lang 1 beträgt. Sie können zum Beispiel einen Alarm auslösen, wenn dieser Wert 30 Minuten oder länger 1 beträgt. Anwendungsfall: Cluster-Leistung überwachen Einheiten: boolescher Wert
`MemoryAvailableMB`	Verfügbarer zuzuordnender Speicher. Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl

Metrik	Beschreibung
`MRActiveNodes`	Anzahl der Knoten, die gegenwärtig MapReduce-Tasks oder -Aufträge ausführen. Entspricht der YARN-Metrik `mapred.resourcemanager.NoOfActiveNodes` . Anwendungsfall: Cluster-Fortschritt überwachen Einheiten: Anzahl
`YARNMemoryAvailablePercentage`	Prozentsatz des für YARN verbleibenden verfügbaren Speichers (YARNMemoryAvailablePercentage = MemoryAvailableMB / MemoryTotalMB). Dieser Wert ist zum Skalieren von Cluster-Ressourcen anhand der YARN-Speichernutzung hilfreich. Einheiten: Prozent

Grafieren der Metriken für verwaltete Skalierung

Sie können Metriken als Grafiken darstellen, um die Workload-Muster Ihres Clusters und entsprechenden Skalierungsentscheidungen zu visualisieren, die durch Amazon EMR Managed Scaling getroffen werden, wie die folgenden Schritte veranschaulichen.

So grafen Sie Metriken für verwaltete Skalierung in der CloudWatch-Konsole

1. Öffnen Sie die CloudWatch-Konsole.
2. Wählen Sie im Navigationsbereich Amazon EMR aus. Sie können die Cluster-Kennung auch nach dem zu überwachenden Cluster durchsuchen.
3. Scrollen Sie zur Metrik, die grafisch dargestellt werden soll. Öffnen Sie eine Metrik, um das Diagramm anzuzeigen.
4. Um eine oder mehrere Metriken grafisch darzustellen, aktivieren Sie das Kontrollkästchen neben jeder Metrik.

Das folgende Beispiel veranschaulicht die Aktivität von Amazon EMR Managed Scaling eines Clusters. Das Diagramm zeigt drei automatische Scale-Down-Perioden, die Kosten sparen, wenn eine weniger aktive Workload vorliegt.

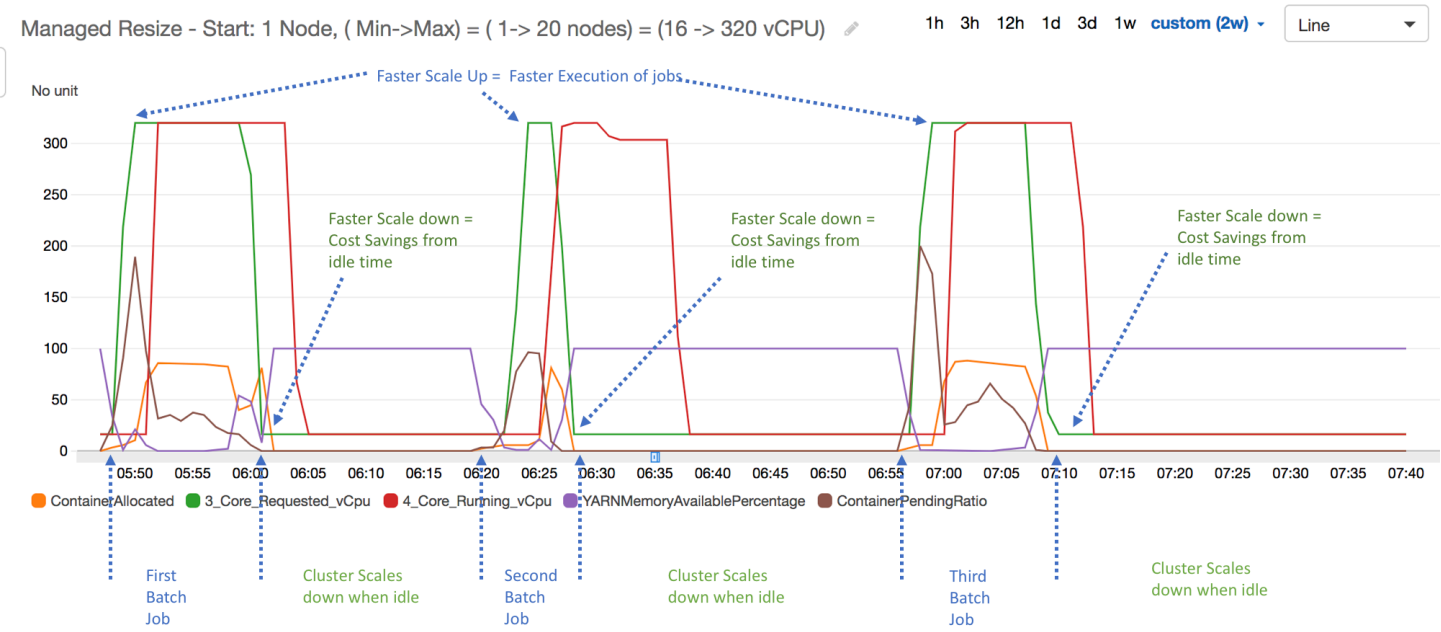

Alle Cluster-Kapazitäts- und Nutzungsmetriken werden in Intervallen von einer Minute veröffentlicht. Zusätzliche statistische Informationen sind auch jeweils mit allen einminütigen Daten verknüpft, sodass Sie verschiedene Funktionen wie `Percentiles`, `Min`, `Max`, `Sum`, `Average`, `SampleCount` darstellen können.

Im folgenden Diagramm wird beispielsweise dieselbe `YARNMemoryAvailablePercentage`-Metrik an verschiedenen Perzentilen (P10, P50, P90, P99) zusammen mit `Sum`, `Average`, `Min`, `SampleCount` dargestellt.

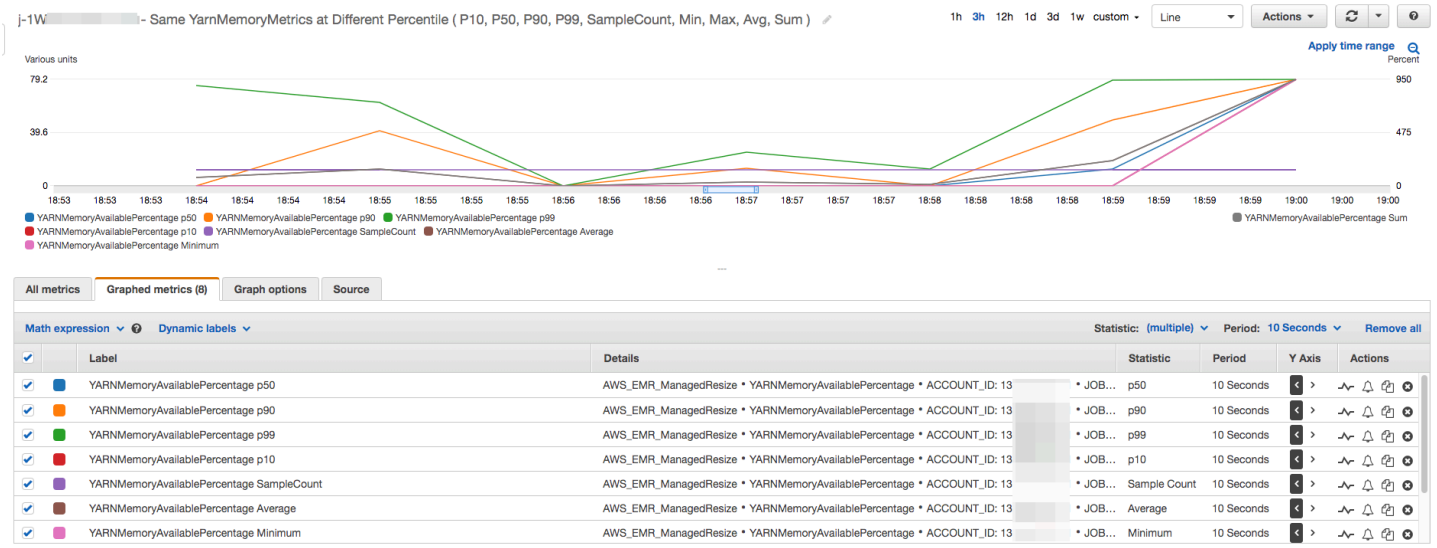

Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen

Das Auto Scaling mit einer benutzerdefinierten Richtlinie in Amazon-EMR-Versionen 4.0 und höher ermöglicht Ihnen die programmgesteuerte Hoch- und Herunter-Skalierung von Core-Knoten und Aufgabenknoten basierend auf einer CloudWatch-Metrik und anderen Parametern, die Sie in einer Skalierungsrichtlinie angeben. Automatische Skalierung mit einer benutzerdefinierten Richtlinie ist bei der Instance-Gruppenkonfiguration verfügbar, aber nicht bei der Verwendung von Instance-Flotten. Weitere Informationen zu Instance-Gruppen und Instance-Flotten finden Sie unter Einen Cluster mit Instance-Flotten oder einheitlichen Instance-Gruppen erstellen.

> **Note**
>
> Um das Auto Scaling mit einem benutzerdefinierten Richtlinienfeature in Amazon EMR zu verwenden, müssen Sie beim Erstellen eines Clusters `true` für den Parameter `VisibleToAllUsers` festlegen. Weitere Informationen finden Sie unter SetVisibleToAllUsers.

Die Skalierungsrichtlinie ist Teil einer Instance-Gruppen-Konfiguration. Sie können eine Richtlinie während der anfänglichen Konfiguration einer Instance-Gruppe oder durch Ändern einer Instance-Gruppe in einer vorhandenen Cluster-Gruppe festlegen (auch wenn die Instance aktiv ist). Jede Instance-Gruppe in einem Cluster,mit Ausnahme der Primär-Instance-Gruppe, kann ihre eigene Skalierungsrichtlinie haben. Diese besteht aus Regeln zur Hoch- und Herunter-Skalierung. Scale-

Out- und Scale-In-Regeln können unabhängig konfiguriert werden. Jede Regel kann andere Parameter haben.

Sie können Skalierungsregeln mit der AWS Management Console, der AWS CLI oder der Amazon-EMR-API konfigurieren. Bei Verwendung der AWS CLI oder der Amazon-EMR-API geben Sie die Skalierungsrichtlinien im JSON-Format an. Außerdem können Sie bei Verwendung mit der AWS CLI oder der Amazon EMR-API benutzerdefinierte CloudWatch-Metriken angeben. Benutzerdefinierte Metriken können nicht über die AWS Management Console ausgewählt werden. Wenn Sie eine Skalierungsrichtlinie zum ersten Mal über die Konsole erstellen, wird eine für viele Anwendungen geeignete Standardrichtlinie erstellt. Diese können Sie als Basis für Ihre eigene Richtlinie nutzen. Sie können die Standardregeln löschen oder ändern.

Zwar können Sie mit der automatischen Skalierung die EMR-Cluster-Kapazität direkt skalieren, Sie sollten jedoch trotzdem grundlegende Workload-Anforderungen definieren und Ihre Knoten- und Instance-Gruppe-Konfigurationen entsprechend planen. Weitere Informationen finden Sie unter Richtlinien zur Cluster-Konfiguration.

> **Note**
>
> Bei den meisten Workloads ist die Einrichtung von Scale-In- und Scale-Out-Regeln zur Optimierung der Ressourcenauslastung erstrebenswert. Wenn Sie eine Regel ohne Gegenstück erstellen, müssen Sie die Größe der Instanz nach einer Skalierung möglicherweise manuell anpassen. In diesem Fall richten Sie sozusagen ein "unidirektionales" Auto Scaling in eine Richtung (Scale-Out oder Scale-In) mit einem manuellen Reset ein.

Erstellen einer IAM-Rolle zur automatischen Skalierung

Auto Scaling in Amazon EMR erfordert eine IAM-Rolle mit Berechtigungen zum Hinzufügen und Beenden von Instances für den Fall, dass die Skalierung ausgelöst wird. Eine Standardrolle, `EMR_AutoScaling_DefaultRole`, mit der entsprechenden Rollen- und Vertrauensrichtlinie, ist für diesen Zweck verfügbar. Wenn Sie zum ersten Mal einen Cluster mit einer Skalierungsrichtlinie unter Verwendung der AWS Management Console erstellen, legt Amazon EMR die Standardrolle an und ordnet ihr die verwaltete Standardrichtlinie `AmazonElasticMapReduceforAutoScalingRole` für Berechtigungen zu.

Wenn Sie einen Cluster mit einer automatischen Skalierung unter Verwendung der AWS CLI erstellen, müssen Sie zunächst sicherstellen, dass entweder die IAM-Standardrolle vorhanden ist,

oder dass Sie eine benutzerdefinierte IAM-Rolle mit einer Richtlinie haben, die die entsprechenden Berechtigungen bereitstellt. Um die Standardrolle zu erstellen, können Sie den Befehl `create-default-roles` ausführen, bevor Sie einen Cluster erstellen. Sie können dann die Option `--auto-scaling-role EMR_AutoScaling_DefaultRole` angeben, wenn Sie einen Cluster erstellen. Alternativ können Sie eine benutzerdefinierte Rolle mit Auto Scaling erstellen und diese angeben, wenn Sie einen Cluster erstellen, zum Beispiel `--auto-scaling-role` *`MyEMRAutoScalingRole`*. Wenn Sie eine benutzerdefinierte Auto-Scaling-Rolle für Amazon EMR erstellen, empfehlen wir Ihnen, die Berechtigungsrichtlinien für Ihre benutzerdefinierte Rolle auf der Grundlage der verwalteten Richtlinie zu erstellen. Weitere Informationen finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.

Grundlegendes zu Auto-Scaling-Regeln

Wenn eine Aufskalierungs-Regel eine Skalierung für eine Instance-Gruppe auslöst, werden entsprechend den Regeln Amazon-EC2-Instances zur Instance-Gruppe hinzugefügt. Neue Knoten können von Anwendungen wie Apache Spark, Apache Hive und Presto genutzt werden, sobald die Amazon-EC2-Instance in den Zustand `InService` übergeht. Sie können außerdem eine Scale-In-Regel erstellen, die Instances beendet und Knoten entfernt. Weitere Informationen über den Lebenszyklus von automatisch skalierten Amazon-EC2-Instances finden Sie unter Auto-Scaling-Lebenszyklus im Benutzerhandbuch für Amazon EC2 Auto Scaling.

Sie können konfigurieren, wie ein Cluster Amazon-EC2-Instances beendet. Sie können die Instance entweder zur Amazon-EC2-Instance-Stundengrenze für die Fakturierung oder nach Abschluss der Aufgabe beenden. Diese Einstellung gilt sowohl für die Auto Scaling- als auch für manuelle Größenanpassungen. Weitere Informationen zu dieser Konfiguration finden Sie unter Cluster-Herunterskalierung.

Die folgenden Parameter für eine Regel in einer Richtlinie bestimmen das Auto Scaling-Verhalten.

> **Note**
>
> Die hier aufgeführten Parameter basieren auf der AWS Management Console für Amazon EMR. Bei Verwendung der AWS CLI oder der Amazon-EMR-API, stehen zusätzliche erweiterte Konfigurationsoptionen zur Verfügung. Weitere Informationen zu den erweiterten Optionen finden Sie unter SimpleScalingPolicyConfiguration in der Amazon-EMR-API-Referenz .

- Maximale und minimale Instances-Anzahl. Die Maximale-Instances-Beschränkung gibt die maximale Anzahl von Amazon-EC2-Instances an, die sich in der Instance-Gruppe befinden können. Sie gilt für alle Aufskalierungs-Regeln. Die Minimale-Instances-Beschränkung gibt die minimale Anzahl von Amazon-EC2-Instances an. Sie gilt für alle Abskalierungs-Regeln.
- Der Rule name (Regelname) muss innerhalb der Richtlinie eindeutig sein.
- Scaling adjustment (Skalierungsanpassung) legt die Anzahl der EC2-Instances fest, die während der durch die Regel ausgelösten Skalierung hinzugefügt (für Scale-Out-Regel) oder beendet (für Scale-In-Regeln) werden.
- Die CloudWatch-Metrik überwacht die Alarmbedingung.
- Ein Comparison operator (Vergleichsoperator) wird zum Vergleich der CloudWatch-Metrik mit dem Threshold (Schwellwert) und zur Bestimmung einer Auslösebedingung verwendet.
- Ein Evaluation period (Auswertungszeitraum) legt in 5-Minuten-Schritten fest, wie lange die CloudWatch-Metrik der Auslösebedingung entsprechen muss, bevor der Skalierung ausgelöst wird.
- Eine Ruhephase in Sekunden legt fest, wie viel Zeit zwischen einer durch eine Regel ausgelösten Skalierung und dem Start der nächsten Skalierung vergehen muss (unabhängig von der auslösenden Regel). Wenn eine Instance-Gruppe eine Skalierung beendet hat und den Nach–Skalierung-Status erreicht hat, bietet die Ruhephase CloudWatch-Metriken die Möglichkeit für nachfolgende Skalierungen zur Stabilisierung. Weitere Informationen finden Sie unter Ruhephasen für das Auto Scaling im Benutzerhandbuch für Amazon EC2 Auto Scaling.

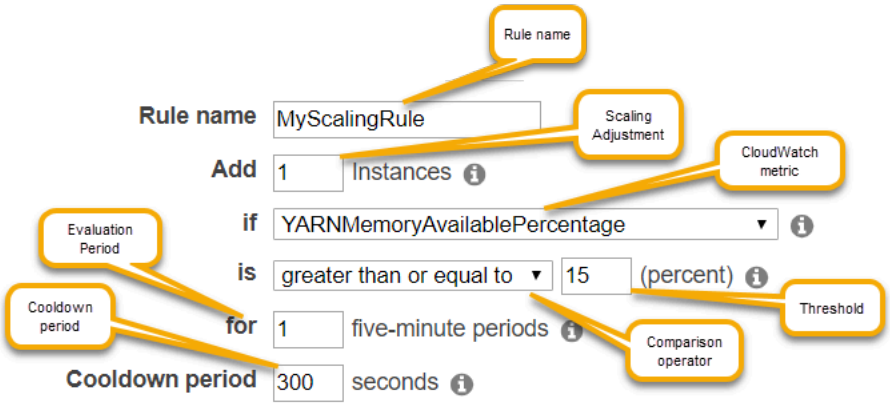

Überlegungen und Einschränkungen

- Amazon-CloudWatch-Metriken sind entscheidend für den Betrieb von Amazon EMR Managed Scaling. Wir empfehlen Ihnen, die Amazon-CloudWatch-Metriken genau zu überwachen, um sicherzustellen, dass keine Daten fehlen. Weitere Informationen darüber, wie Sie Amazon-

CloudWatch-Alarme konfigurieren können, um fehlende Metriken zu erkennen, finden Sie unter Amazon-CloudWatch-Alarme verwenden.

- Eine übermäßige Auslastung von EBS-Volumes kann zu Problemen bei der verwalteten Skalierung führen. Wir empfehlen, die Nutzung des EBS-Volumes genau zu überwachen, um sicherzustellen, dass das EBS-Volume unter 90 % ausgelastet ist. Informationen zur Angabe zusätzlicher EBS-Volumes finden Sie unter Instance-Speicher.
- Bei der automatischen Skalierung mit einer benutzerdefinierten Richtlinie in den Amazon-EMR-Versionen 5.18 bis 5.28 kann es zu Skalierungsfehlern kommen, die dadurch verursacht werden, dass Daten in den Amazon CloudWatch-Metriken zeitweise fehlen. Wir empfehlen, dass Sie die neuesten Amazon-EMR-Versionen verwenden, um das Auto Scaling zu verbessern. Sie können sich auch an den AWS-Support wenden, um einen Patch zu erhalten, wenn Sie eine Amazon-EMR-Version zwischen 5.18 und 5.28 verwenden müssen.

Verwenden von AWS Management Console zur Konfiguration von Auto Scaling

Wenn Sie einen Cluster erstellen, konfigurieren Sie mithilfe der erweiterten Optionen für die Cluster-Konfiguration eine Skalierungsrichtlinie für Instance-Gruppen. Sie können außerdem eine Skalierungsrichtlinie für eine laufende Instance-Gruppe erstellen, indem Sie die Hardware-Einstellungen eines vorhandenen Clusters bearbeiten.

> **Note**
>
> Die neue Amazon-EMR-Konsole (https://console.aws.amazon.com/emr) verwendet verwaltete Skalierung anstelle von automatischer Skalierung. Um das Auto Scaling zu verwenden, stellen Sie sicher, dass Sie bei der alten Konsole unter https://console.aws.amazon.com/elasticmapreduce angemeldet sind.

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wenn Sie einen Cluster in der Amazon-EMR-Konsole erstellen, wählen Sie Cluster erstellen und Zu erweiterten Optionen gehen aus, wählen dann Optionen für Schritt 1: Software und Schritte aus und wechseln dann zu Schritt 2: Hardware-Konfiguration.

   – oder –

Wenn Sie eine Instance-Gruppe in einem ausgeführten Cluster ändern, wählen Sie den Cluster aus der Cluster-Liste aus und erweitern Sie dann den Hardware-Abschnitt.

3. Wählen Sie im Abschnitt Clusterskalierung und Bereitstellungoption die Option Clusterskalierung aktivieren aus. Wählen Sie dann Benutzerdefinierte Richtlinie für automatische Skalierung erstellen aus.

   Klicken Sie in der Tabelle Benutzerdefinierte Richtlinien für automatische Skalierung auf das Stiftsymbol in der Zeile der Instance-Gruppe, die Sie konfigurieren möchten. Die Seite Auto-Scaling-Regeln wird geöffnet.

4. Geben Sie die Maximum instances (maximale Instances)-Anzahl ein, die die Instance-Gruppe nach dem Scale-Out enthalten soll. Geben Sie die Minimum instances (minimale Instances)-Anzahl ein, die die Instance-Gruppe nach dem Scale-In enthalten soll.

5. Klicken Sie auf den Stift, um Regelparameter zu bearbeiten. Klicken Sie auf das X, um eine Regel aus der Richtlinie zu entfernen, und klicken Sie auf Add rule (Regel hinzufügen), um weitere Regeln hinzuzufügen.

6. Wählen Sie die weiter oben in diesem Thema beschriebenen Regelparameter aus. Eine Beschreibung der verfügbaren CloudWatch-Metriken für Amazon EMR finden Sie unter Amazon-EMR-Metriken und -Dimensionen im Amazon-CloudWatch-Benutzerhandbuch.

Verwenden von AWS CLI zur Konfiguration von Auto Scaling

Beim Erstellen eines Clusters und beim Erstellen einer Instance-Gruppe können Sie Auto Scaling mit AWS CLI-Befehlen für Amazon EMR konfigurieren. Sie können eine Kurzschreibweise mit der passenden JSON-Konfiguration in den entsprechenden Befehlen oder eine Referenzdatei mit der JSON-Konfiguration verwenden. Sie können außerdem eine Auto Scaling-Richtlinie auf eine vorhandene Instance-Gruppe anwenden und eine angewendete Auto Scaling-Richtlinie entfernen. Darüber hinaus können Sie Details einer Skalierungsrichtlinien-Konfiguration aus einem aktuell ausgeführten Cluster abrufen.

> **Important**
>
> Wenn Sie einen Cluster erstellen, der eine Richtlinie für automatische Skalierung nutzt, müssen Sie mit dem Befehl `--auto-scaling-role` *`MyAutoScalingRole`* die IAM-Rolle für das Auto Scaling anzugeben. Die Standard-Rolle ist *`EMR_AutoScaling_DefaultRole`* und kann mit dem Befehl `create-default-roles` erstellt werden. Die Rolle kann nur

hinzugefügt werden, wenn der Cluster erstellt wird. Sie kann nicht zu einem vorhandenen Cluster hinzugefügt werden.

Eine detaillierte Beschreibung der verfügbaren Parameter für die Konfiguration einer Auto-Scaling-Richtlinie finden Sie unter PutAutoScalingPolicy in der Amazon-EMR-API-Referenz.

Erstellen eines Clusters mit einer angewendeten Auto-Scaling-Richtlinie in einer Instance-Gruppe

Sie können eine Auto Scaling-Konfiguration innerhalb der Option `--instance-groups` des Befehls `aws emr create-cluster` festlegen. Das folgende Beispiel demonstriert einen create-Cluster-Befehl, in dem eine Auto Scaling-Richtlinie für die Core-Instance-Gruppe enthalten ist. Der Befehl erstellt eine Skalierungskonfiguration, die der standardmäßigen Aufskalierungs-Richtlinie beim Erstellen einer Auto-Scaling-Richtlinie mithilfe der AWS Management Console für Amazon EMR entspricht. Aus Gründen der Übersichtlichkeit verzichten wir auf die Abbildung einer Scale-In-Richtlinie. Das Erstellen einer Scale-Out-Regel ohne Verringern der Scale-In-Regel wird nicht empfohlen.

```
aws emr create-cluster --release-label emr-5.2.0 --service-role
 EMR_DefaultRole --ec2-attributes InstanceProfile=EMR_EC2_DefaultRole
 --auto-scaling-role EMR_AutoScaling_DefaultRole  --instance-groups
 Name=MyMasterIG,InstanceGroupType=MASTER,InstanceType=m5.xlarge,InstanceCount=1
 'Name=MyCoreIG,InstanceGroupType=CORE,InstanceType=m5.xlarge,InstanceCount=2,AutoScalingPolicy
scale-out,Description=Replicates the default scale-out rule in the
 console.,Action={SimpleScalingPolicyConfiguration={AdjustmentType=CHANGE_IN_CAPACITY,ScalingAd
ElasticMapReduce,Period=300,Statistic=AVERAGE,Threshold=15,Unit=PERCENT,Dimensions=[{Key=JobFlo
```

Der folgende Befehl veranschaulicht die Verwendung der Befehlszeile zur Angabe einer Auto-Scaling-Richtliniendefinition im Rahmen einer Instance-Gruppe-Konfigurationsdatei mit dem Namen *instancegroupconfig.json*.

```
aws emr create-cluster --release-label emr-5.2.0 --service-role EMR_DefaultRole --ec2-
attributes InstanceProfile=EMR_EC2_DefaultRole --instance-groups file://your/path/to/
instancegroupconfig.json --auto-scaling-role EMR_AutoScaling_DefaultRole
```

Der Inhalt der Konfigurationsdatei sieht wie folgt aus:

```
[
```

```
{
  "InstanceCount": 1,
  "Name": "MyMasterIG",
  "InstanceGroupType": "MASTER",
  "InstanceType": "m5.xlarge"
},
{
  "InstanceCount": 2,
  "Name": "MyCoreIG",
  "InstanceGroupType": "CORE",
  "InstanceType": "m5.xlarge",
  "AutoScalingPolicy":
    {
     "Constraints":
      {
       "MinCapacity": 2,
       "MaxCapacity": 10
      },
     "Rules":
     [
      {
       "Name": "Default-scale-out",
       "Description": "Replicates the default scale-out rule in the console for YARN
 memory.",
       "Action":{
        "SimpleScalingPolicyConfiguration":{
          "AdjustmentType": "CHANGE_IN_CAPACITY",
          "ScalingAdjustment": 1,
          "CoolDown": 300
        }
       },
       "Trigger":{
        "CloudWatchAlarmDefinition":{
          "ComparisonOperator": "LESS_THAN",
          "EvaluationPeriods": 1,
          "MetricName": "YARNMemoryAvailablePercentage",
          "Namespace": "AWS/ElasticMapReduce",
          "Period": 300,
          "Threshold": 15,
          "Statistic": "AVERAGE",
          "Unit": "PERCENT",
          "Dimensions":[
             {
               "Key" : "JobFlowId",
```

```
                "Value" : "${emr.clusterId}"
              }
            ]
          }
        }
      }
    ]
  }
}
]
```

Hinzufügen einer Instance-Gruppe mit einer Auto-Scaling-Richtlinie zu einem Cluster

Sie können genauso wie bei `--instance-groups` mithilfe der `add-instance-groups`-Option des `create-cluster`-Befehls eine Skalierungsrichtlinien-Konfiguration festlegen. Im folgenden Beispiel wird ein Verweis auf eine JSON-Datei (*`instancegroupconfig.json`*) mit der Konfiguration der Instance-Gruppe verwendet.

```
aws emr add-instance-groups --cluster-id j-1EKZ3TYEVF1S2 --instance-groups file://your/
path/to/instancegroupconfig.json
```

Anwenden einer Auto-Scaling-Richtlinie auf eine vorhandene Instance-Gruppe oder Ändern einer angewandten Richtlinie

Verwenden Sie den `aws emr put-auto-scaling-policy`-Befehl, um eine Auto Scaling-Richtlinie auf eine vorhandene Instance-Gruppe anzuwenden. Die Instance-Gruppe muss Teil eines Clusters sein, der die Auto-Scaling-IAM-Rolle verwendet. Im folgenden Beispiel wird ein Verweis auf eine JSON-Datei (*`autoscaleconfig.json`*) verwendet, in der eine Auto Scaling-Richtlinienkonfiguration definiert ist.

```
aws emr put-auto-scaling-policy --cluster-id j-1EKZ3TYEVF1S2 --instance-group-
id ig-3PLUZBA6WLS07 --auto-scaling-policy file://your/path/to/autoscaleconfig.json
```

Der Inhalt der `autoscaleconfig.json`-Datei, die die gleiche Scale-Out-Regel wie im vorherigen Beispiel definiert, ist unten dargestellt.

```
{
        "Constraints": {
                "MaxCapacity": 10,
                "MinCapacity": 2
        },
```

```
        "Rules": [{
                "Action": {
                        "SimpleScalingPolicyConfiguration": {
                                "AdjustmentType": "CHANGE_IN_CAPACITY",
                                "CoolDown": 300,
                                "ScalingAdjustment": 1
                        }
                },
                "Description": "Replicates the default scale-out rule in the console
for YARN memory",
                "Name": "Default-scale-out",
                "Trigger": {
                        "CloudWatchAlarmDefinition": {
                                "ComparisonOperator": "LESS_THAN",
                                "Dimensions": [{
                                        "Key": "JobFlowID",
                                        "Value": "${emr.clusterID}"
                                }],
                                "EvaluationPeriods": 1,
                                "MetricName": "YARNMemoryAvailablePercentage",
                                "Namespace": "AWS/ElasticMapReduce",
                                "Period": 300,
                                "Statistic": "AVERAGE",
                                "Threshold": 15,
                                "Unit": "PERCENT"
                        }
                }
        }]
 }
```

Entfernen einer Auto-Scaling-Richtlinie aus einer Instance-Gruppe

```
aws emr remove-auto-scaling-policy --cluster-id j-1EKZ3TYEVF1S2 --instance-group-
id ig-3PLUZBA6WLS07
```

Abrufen einer Auto-Scaling-Richtlinienkonfiguration

Der `describe-cluster`-Befehl ruft die Richtlinienkonfiguration im InstanceGroup-Block ab. Mit dem folgenden Befehl wird beispielsweise die Konfiguration für den Cluster mit der Cluster-ID `j-1CW0HP4PI30VJ` abgerufen.

```
aws emr describe-cluster --cluster-id j-1CWOHP4PI30VJ
```

Der Befehl generiert die folgende Beispielausgabe:

```
{
    "Cluster": {
        "Configurations": [],
        "Id": "j-1CWOHP4PI30VJ",
        "NormalizedInstanceHours": 48,
        "Name": "Auto Scaling Cluster",
        "ReleaseLabel": "emr-5.2.0",
        "ServiceRole": "EMR_DefaultRole",
        "AutoTerminate": false,
        "TerminationProtected": true,
        "MasterPublicDnsName": "ec2-54-167-31-38.compute-1.amazonaws.com",
        "LogUri": "s3n://aws-logs-232939870606-us-east-1/elasticmapreduce/",
        "Ec2InstanceAttributes": {
            "Ec2KeyName": "performance",
            "AdditionalMasterSecurityGroups": [],
            "AdditionalSlaveSecurityGroups": [],
            "EmrManagedSlaveSecurityGroup": "sg-09fc9362",
            "Ec2AvailabilityZone": "us-east-1d",
            "EmrManagedMasterSecurityGroup": "sg-0bfc9360",
            "IamInstanceProfile": "EMR_EC2_DefaultRole"
        },
        "Applications": [
            {
                "Name": "Hadoop",
                "Version": "2.7.3"
            }
        ],
        "InstanceGroups": [
            {
                "AutoScalingPolicy": {
                    "Status": {
                        "State": "ATTACHED",
                        "StateChangeReason": {
                            "Message": ""
                        }
                    },
                    "Constraints": {
```

```
                    "MaxCapacity": 10,
                    "MinCapacity": 2
                },
                "Rules": [
                    {
                        "Name": "Default-scale-out",
                        "Trigger": {
                            "CloudWatchAlarmDefinition": {
                                "MetricName": "YARNMemoryAvailablePercentage",
                                "Unit": "PERCENT",
                                "Namespace": "AWS/ElasticMapReduce",
                                "Threshold": 15,
                                "Dimensions": [
                                    {
                                        "Key": "JobFlowId",
                                        "Value": "j-1CWOHP4PI30VJ"
                                    }
                                ],
                                "EvaluationPeriods": 1,
                                "Period": 300,
                                "ComparisonOperator": "LESS_THAN",
                                "Statistic": "AVERAGE"
                            }
                        },
                        "Description": "",
                        "Action": {
                            "SimpleScalingPolicyConfiguration": {
                                "CoolDown": 300,
                                "AdjustmentType": "CHANGE_IN_CAPACITY",
                                "ScalingAdjustment": 1
                            }
                        }
                    },
                    {
                        "Name": "Default-scale-in",
                        "Trigger": {
                            "CloudWatchAlarmDefinition": {
                                "MetricName": "YARNMemoryAvailablePercentage",
                                "Unit": "PERCENT",
                                "Namespace": "AWS/ElasticMapReduce",
                                "Threshold": 75,
                                "Dimensions": [
                                    {
                                        "Key": "JobFlowId",
```

```
                                    "Value": "j-1CWOHP4PI30VJ"
                                }
                            ],
                            "EvaluationPeriods": 1,
                            "Period": 300,
                            "ComparisonOperator": "GREATER_THAN",
                            "Statistic": "AVERAGE"
                        }
                    },
                    "Description": "",
                    "Action": {
                        "SimpleScalingPolicyConfiguration": {
                            "CoolDown": 300,
                            "AdjustmentType": "CHANGE_IN_CAPACITY",
                            "ScalingAdjustment": -1
                        }
                    }
                }
            ]
        },
        "Configurations": [],
        "InstanceType": "m5.xlarge",
        "Market": "ON_DEMAND",
        "Name": "Core - 2",
        "ShrinkPolicy": {},
        "Status": {
            "Timeline": {
                "CreationDateTime": 1479413437.342,
                "ReadyDateTime": 1479413864.615
            },
            "State": "RUNNING",
            "StateChangeReason": {
                "Message": ""
            }
        },
        "RunningInstanceCount": 2,
        "Id": "ig-3M16XBE8C3PH1",
        "InstanceGroupType": "CORE",
        "RequestedInstanceCount": 2,
        "EbsBlockDevices": []
    },
    {
        "Configurations": [],
        "Id": "ig-OP62I28NSE8M",
```

```
                "InstanceGroupType": "MASTER",
                "InstanceType": "m5.xlarge",
                "Market": "ON_DEMAND",
                "Name": "Master - 1",
                "ShrinkPolicy": {},
                "EbsBlockDevices": [],
                "RequestedInstanceCount": 1,
                "Status": {
                    "Timeline": {
                        "CreationDateTime": 1479413437.342,
                        "ReadyDateTime": 1479413752.088
                    },
                    "State": "RUNNING",
                    "StateChangeReason": {
                        "Message": ""
                    }
                },
                "RunningInstanceCount": 1
            }
        ],
        "AutoScalingRole": "EMR_AutoScaling_DefaultRole",
        "Tags": [],
        "BootstrapActions": [],
        "Status": {
            "Timeline": {
                "CreationDateTime": 1479413437.339,
                "ReadyDateTime": 1479413863.666
            },
            "State": "WAITING",
            "StateChangeReason": {
                "Message": "Cluster ready after last step completed."
            }
        }
    }
}
```

Manuelle Größenanpassung eines aktiven Clusters

Über die AWS Management Console, die AWS CLI oder die Amazon-EMR-API können Sie in einem aktiven Cluster Instances zu Core- und Aufgaben-Instance-Gruppen und Instance-Flotten hinzufügen oder daraus entfernen. Wenn ein Cluster Instance-Gruppen verwendet, müssen Sie die Anzahl der Instances explizit ändern. Wenn Ihr Cluster Instance-Flotten verwendet, können Sie

die Zieleinheiten für On-Demand-Instances und Spot-Instances ändern. Die Instance-Flotte fügt anschließend Instances hinzu bzw. entfernt diese, um dem neuen Ziel zu entsprechen. Weitere Informationen finden Sie unter Instance-Flotten-Optionen. Sobald die Instances verfügbar sind, können Anwendungen die neu bereitgestellten Amazon-EC2-Instances zum Hosten von Knoten nutzen. Wenn Instances entfernt werden, fährt Amazon EMR Aufgaben so herunter, dass es weder zu einer Unterbrechung der Aufträge noch zu einem Datenverlust kommt. Weitere Informationen finden Sie unter Beendigung bei Aufgaben-Abschluss.

Die Größe eines Clusters mit der Konsole anpassen

Sie können die Größe eines Clusters über die Amazon-EMR-Konsole ändern.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So ändern Sie die Anzahl der Instances für einen vorhandenen Cluster mithilfe der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann den Cluster aus, den Sie aktualisieren möchten. Der Cluster muss ausgeführt werden. Sie können die Größe eines bereitgestellten oder beendeten Clusters nicht ändern.
3. Sehen Sie sich auf der Cluster-Detailseite auf der Registerkarte Instances den Bereich Instancegruppen an.
4. Um die Größe einer vorhandenen Instancegruppe zu ändern, wählen Sie das Optionsfeld neben der Core- oder Aufgaben-Instancegruppe aus, deren Größe Sie ändern möchten, und wählen Sie dann Größe der Instancegruppe ändern. Geben Sie die neue Anzahl der Instances für die Instance-Gruppe an und wählen Sie anschließend Größe ändern aus.

> **Note**
>
> Wenn Sie sich dafür entscheiden, die Größe einer laufenden Instance-Gruppe zu reduzieren, wählt Amazon EMR intelligent die Instances aus, die aus der Gruppe entfernt werden sollen, um den Datenverlust zu minimieren. Für eine genauere Steuerung Ihrer Größenänderungsaktion können Sie die ID für die Instance-Gruppe auswählen, die Instances auswählen, die Sie entfernen möchten, und dann die Option Terminate verwenden. Weitere Informationen zum intelligenten Herunterskalierungs-Verhalten finden Sie unter Cluster-Herunterskalierung.

5. Wenn Sie die Größenänderung abbrechen möchten, können Sie das Optionsfeld für eine Instancegruppe mit dem Status Größenänderung beenden auswählen und dann in der Liste der Aktionen die Option Größenänderung beenden auswählen.
6. Um Ihrem Cluster als Reaktion auf den steigenden Workload eine oder mehrere Aufgaben-Instance-Gruppen hinzuzufügen, wählen Sie Aufgaben-Instancegruppe hinzufügen aus der Liste der Aktionen aus. Wählen Sie den Amazon EC2-Instance-Typ, geben Sie die Anzahl der Instances für die Aufgabengruppe ein und wählen Sie dann Aufgaben-Instance-Gruppe hinzufügen, um zum Bereich Instancegruppen für Ihren Cluster zurückzukehren.

Old console

So ändern Sie die Anzahl der Instances für einen vorhandenen aktiven Cluster mithilfe der alten Konsole

1. Wählen Sie auf der Seite Cluster List (Cluster-Liste) den zu ändernden Cluster aus.
2. Wählen Sie auf der Seite Cluster Details (Cluster-Details) die Option Hardware aus.
3. Wenn Ihr Cluster Instance-Gruppen verwendet, wählen Sie für die Instance-Gruppe, die Sie ändern möchten, die Option Resize (Größe ändern) in der Spalte Instance count (Instance-Anzahl) aus. Geben Sie eine neue Instance-Anzahl ein und aktivieren Sie anschließend das grüne Häkchen.

   -ODER-

   Wenn Ihr Cluster Instance-Flotten verwendet, wählen Sie Größe ändern in der Spalte Bereitgestellte Kapazität aus, geben Sie neue Werte für On-Demand-Einheiten und Spot-Einheiten ein, und klicken Sie anschließend auf Größe ändern.

Wenn Sie die Anzahl der Knoten ändern, wird der Status der Instance-Gruppe aktualisiert. Wenn die gewünschte Änderung abgeschlossen ist, ändert sich der Status zu Running (Wird ausgeführt).

Größe eines Clusters mit der AWS CLI anpassen

Sie können die Größe eines Clusters über die AWS CLI ändern. Sie können die Anzahl der Aufgabenknoten erhöhen oder verringern. Sie können außerdem die Anzahl der Core-Knoten in einem ausgeführten Cluster erhöhen oder verringern. Es ist zudem möglich, eine Instance in der Core-Instance-Gruppe über die AWS CLI oder die API herunterzufahren. Dies sollte mit Vorsicht erfolgen. Beim Beenden einer Instance in der Core-Instance-Gruppe besteht das Risiko eines Datenverlustes. Die Instance wird zudem nicht automatisch ersetzt.

Zusätzlich zur Größenanpassung der Core- und Aufgaben-Gruppen können Sie mithilfe der AWS CLI auch eine oder mehrere Aufgaben-Instance-Gruppen zu einem ausgeführten Cluster hinzufügen.

So ändern Sie die Größe eines Clusters über die Änderung der Instance-Anzahl mithilfe der AWS CLI

Sie können Instances zur Core- oder Aufgaben-Gruppe hinzufügen. Mit dem AWS CLI-Unterbefehl `modify-instance-groups` und dem Parameter `InstanceCount` können Sie außerdem Instances aus der Aufgaben-Gruppe entfernen. Erhöhen Sie `InstanceCount`, um Instances zu Core- oder Task-Gruppen hinzuzufügen. Reduzieren Sie `InstanceCount`, um die Anzahl der Instances in der Gruppe zu verringern. Die Reduzierung der Anzahl der Instances einer Task-Gruppe auf null entfernt zwar alle Instances, nicht jedoch die Instance-Gruppe.

- Um die Anzahl der Instances in der Task-Instance-Gruppe von 3 auf 4 zu erhöhen, geben Sie den folgenden Befehl ein und ersetzen *ig-31JXXXXXXBT0* mit der Instance-Gruppen-ID.

  ```
  aws emr modify-instance-groups --instance-groups
   InstanceGroupId=ig-31JXXXXXXBT0,InstanceCount=4
  ```

  Verwenden Sie den Unterbefehl `InstanceGroupId`, um die `describe-cluster` abzurufen. Die Ausgabe ist ein JSON-Objekt mit dem Namen `Cluster`, das die ID jeder Instance-Gruppe enthält. Um diesen Befehl verwenden zu können, benötigen Sie die Cluster-ID (diese können Sie über den `aws emr list-clusters`-Befehl oder die Konsole abrufen). Geben Sie den folgenden Befehl ein, um die Instance-Gruppen-ID abzurufen. Ersetzen Sie *j-2AXXXXXXGAPLF* durch die Cluster-ID.

  ```
  aws emr describe-cluster --cluster-id j-2AXXXXXXGAPLF
  ```

Mit dem Unterbefehl `--modify-instance-groups` können Sie eine Instance in der Core-Instance-Gruppe auch über die AWS CLI beenden.

> **Warning**
>
> Die Angabe von `EC2InstanceIdsToTerminate` muss mit Vorsicht erfolgen. Instances werden sofort beendet, unabhängig vom Status der Anwendungen, die auf ihnen ausgeführt werden, und die Instance wird nicht automatisch ersetzt. Dies gilt unabhängig von der Konfiguration vom Scale down behavior (Abwärtsskalierungsverhalten) für den Cluster. Wenn eine Instance auf diese Weise beendet wird, besteht das Risiko von Datenverlusten und unvorhersehbarem Clusterverhalten.

Um eine bestimmte Instance zu beenden, benötigen Sie die Instance-Gruppen-ID (wird vom `aws emr describe-cluster --cluster-id`-Unterbefehl zurückgegeben) und die Instance-ID (wird vom `aws emr list-instances --cluster-id`-Unterbefehl zurückgegeben). Geben Sie den folgenden Befehl ein und ersetzen Sie *`ig-6RXXXXXX07SA`* durch die Instance-Gruppen-ID sowie *`i-f9XXXXf2`* durch die Instance-ID.

```
aws emr modify-instance-groups --instance-groups
 InstanceGroupId=ig-6RXXXXXX07SA,EC2InstanceIdsToTerminate=i-f9XXXXf2
```

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

So ändern Sie die Größe eines Clusters über das Hinzufügen von Aufgaben-Instance-Gruppen mithilfe der AWS CLI

Mit der AWS CLI können Sie über den `--add-instance-groups`-Unterbefehl zwischen 1–48 Aufgaben-Instance-Gruppen zu einem Cluster hinzufügen. Aufgaben-Instances-Gruppen können nur zu einem Cluster mit einer Primär-Instance-Gruppe und einer Core-Instance-Gruppe hinzugefügt werden. Bei der Verwendung der AWS CLI können Sie bis zu fünf Aufgaben-Instance-Gruppen per `--add-instance-groups`-Unterbefehl hinzufügen.

1. Geben Sie den folgenden Befehl ein, um eine einzelne Task-Instance-Gruppe hinzuzufügen. Ersetzen Sie *`j-JXBXXXXXX37R`* durch die Cluster-ID, um die Instance-Gruppen-ID abzurufen.

```
aws emr add-instance-groups --cluster-id j-JXBXXXXXX37R --instance-groups
 InstanceCount=6,InstanceGroupType=task,InstanceType=m5.xlarge
```

2. Geben Sie den folgenden Befehl ein, um mehrere Task-Instance-Gruppen zu einem Cluster hinzuzufügen. Ersetzen Sie *j-JXBXXXXXX37R* durch die Cluster-ID. Sie können bis zu fünf Task-Instance-Gruppen pro Befehl hinzufügen.

```
aws emr add-instance-groups --cluster-id j-JXBXXXXXX37R --instance-
groups InstanceCount=6,InstanceGroupType=task,InstanceType=m5.xlarge
 InstanceCount=10,InstanceGroupType=task,InstanceType=m5.xlarge
```

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Unterbrechen einer Größenänderung

Wenn Sie Amazon-EMR-Version 4.1.0 oder höher verwenden, können Sie eine Größenänderung auch während einer laufenden Größenänderung durchführen. Sie können außerdem eine zuvor gesendete Anfrage zur Größenanpassung stoppen oder eine neue Anfrage senden, um eine frühere Anfrage zu überschreiben, ohne auf deren Abschluss zu warten. Sie können eine vorhandene Größenänderung über die Konsole oder über einen `ModifyInstanceGroups`-API-Aufruf mit der aktuellen Anzahl als Zielanzahl für den Cluster beenden.

Die folgende Abbildung zeigt eine Task-Instance-Gruppe, deren Größe gerade geändert wird und bei der die Größenänderung über Stop (Stopp) beendet werden kann.

So unterbrechen Sie eine Größenänderung mit der AWS CLI

Mit dem `modify-instance-groups`-Unterbefehl können Sie eine Größenänderung über die AWS CLI beenden. Nehmen wir an, Sie haben sechs Instances in der Instance-Gruppe und Sie möchten diese auf 10 erhöhen. Später entscheiden Sie, dass Sie diese Anforderung stornieren möchten:

- Die ursprüngliche Anforderung:

```
aws emr modify-instance-groups --instance-groups
 InstanceGroupId=ig-myInstanceGroupId,InstanceCount=10
```

Die zweite Anforderung zum Beenden der ersten Anforderung:

```
aws emr modify-instance-groups --instance-groups
 InstanceGroupId=ig-myInstanceGroupId,InstanceCount=6
```

> **Note**
>
> Da es sich um einen asynchronen Prozess handelt, ändert sich die Instance-Anzahl möglicherweise entsprechend der vorherigen API-Anforderung, bevor nachfolgende Anforderungen berücksichtigt werden. Bei einer Verkleinerung kann es sein, dass auf den Knoten noch Aufgaben ausgeführt werden. In diesem Fall wird die Instance-Gruppe nicht verkleinert, bis die Knoten ihre Arbeit abgeschlossen haben.

Suspendierter Zustand

Eine Instancegruppe geht in einen suspendierten Zustand über, wenn sie beim Versuch, die neuen Clusterknoten zu starten, auf zu viele Fehler stößt. Wenn z. B. neue Knoten während der Durchführung von Bootstrap-Aktionen wiederholt fehlschlagen, wechselt die Instance-Gruppe in den Status SUSPENDED, statt weiterhin zu versuchen, neue Knoten bereitzustellen. Nachdem Sie das entsprechende Problem behoben haben, setzen Sie die Anzahl der gewünschten Knoten in der Instance-Gruppe des Clusters zurück. Anschließend fährt die Instance-Gruppe mit der Reservierung von Knoten fort. Das Ändern einer Instance-Gruppe weist Amazon EMR an, die Knotenbereitstellung erneut zu versuchen. Nicht ausgeführte Knoten werden neu gestartet oder beendet.

Mit dem `list-instancesdescribe-cluster`-Unterbefehl in der AWS CLI werden wie beim -Unterbefehl alle Instances und deren Status zurückgegeben. Wenn Amazon EMR einen Fehler bei einer Instance-Gruppe erkennt, wird der Status der Gruppe auf `SUSPENDED` geändert.

Um einen Cluster im SUSPENDED-Zustand zurückzusetzen, verwenden Sie AWS CLI

Geben Sie den `describe-cluster`-Unterbefehl mit dem Parameter `--cluster-id` ein, um den Status der Instances in Ihrem Cluster anzuzeigen.

- Um Informationen über alle Instances und Instance-Gruppen in einem Cluster anzuzeigen, geben Sie den folgenden Befehl ein und ersetzen *`j-3KVXXXXXXY7UG`* durch die Cluster-ID.

```
aws emr describe-cluster --cluster-id j-3KVXXXXXXY7UG
```

Die Ausgabe zeigt Informationen über Ihre Instance-Gruppen und den Status der Instances an:


```
{
    "Cluster": {
        "Status": {
            "Timeline": {
                "ReadyDateTime": 1413187781.245,
                "CreationDateTime": 1413187405.356
            },
            "State": "WAITING",
            "StateChangeReason": {
                "Message": "Waiting after step completed"
            }
        },
        "Ec2InstanceAttributes": {
            "Ec2AvailabilityZone": "us-west-2b"
        },
        "Name": "Development Cluster",
        "Tags": [],
        "TerminationProtected": false,
        "RunningAmiVersion": "3.2.1",
        "NormalizedInstanceHours": 16,
        "InstanceGroups": [
            {
                "RequestedInstanceCount": 1,
                "Status": {
                    "Timeline": {
                        "ReadyDateTime": 1413187775.749,
                        "CreationDateTime": 1413187405.357
                    },
                    "State": "RUNNING",
                    "StateChangeReason": {
                        "Message": ""
                    }
                },
                "Name": "MASTER",
                "InstanceGroupType": "MASTER",
                "InstanceType": "m5.xlarge",
                "Id": "ig-3ETXXXXXXFYV8",
                "Market": "ON_DEMAND",
```

```
                "RunningInstanceCount": 1
            },
            {
                "RequestedInstanceCount": 1,
                "Status": {
                    "Timeline": {
                        "ReadyDateTime": 1413187781.301,
                        "CreationDateTime": 1413187405.357
                    },
                    "State": "RUNNING",
                    "StateChangeReason": {
                        "Message": ""
                    }
                },
                "Name": "CORE",
                "InstanceGroupType": "CORE",
                "InstanceType": "m5.xlarge",
                "Id": "ig-3SUXXXXXQ9ZM",
                "Market": "ON_DEMAND",
                "RunningInstanceCount": 1
            }
...
}
```

Um Informationen zu einer bestimmten Instance-Gruppe anzuzeigen, geben Sie den Unterbefehl `list-instances` mit den Parametern `--cluster-id` und `--instance-group-types` ein. Sie können Informationen für Primär-, Core- oder Aufgaben-Gruppen anzeigen.

```
aws emr list-instances --cluster-id j-3KVXXXXXXY7UG --instance-group-types "CORE"
```

Verwenden Sie den Unterbefehl `modify-instance-groups` mit dem Parameter `--instance-groups`, um einen Cluster mit dem SUSPENDED-Status zurückzusetzen. Die Instance-Gruppen-ID wird vom Unterbefehl `describe-cluster` zurückgegeben.

```
aws emr modify-instance-groups --instance-groups
 InstanceGroupId=ig-3SUXXXXXQ9ZM,InstanceCount=3
```

Überlegungen zur Reduzierung der Clustergröße

Wenn Sie sich dafür entscheiden, die Größe eines laufenden Clusters zu reduzieren, sollten Sie das folgende Verhalten und die folgenden Best Practices von Amazon EMR berücksichtigen:

- Um die Auswirkungen auf laufende Jobs zu reduzieren, wählt Amazon EMR intelligent die zu entfernenden Instances aus. Weitere Informationen zum Verhalten beim Herunterskalieren von Clustern finden Sie unter Beendigung bei Aufgaben-Abschluss im Amazon-EMR-Managementhandbuch.
- Wenn Sie die Größe eines Clusters herunterskalieren, kopiert Amazon EMR die Daten aus den Instances, die es entfernt hat, in die verbleibenden Instances. Stellen Sie sicher, dass in den Instances, die in der Gruppe verbleiben, ausreichend Speicherkapazität für diese Daten vorhanden ist.
- Amazon EMR versucht, HDFS auf Instances in der Gruppe außer Betrieb zu nehmen. Bevor Sie die Größe eines Clusters reduzieren, empfehlen wir, die HDFS-Schreib-I/O zu minimieren.
- Wenn Sie die Größe eines Clusters am genauesten steuern möchten, können Sie den Cluster in der Konsole anzeigen und zur Registerkarte Instances wechseln. Wählen Sie die ID für die Instancegruppe aus, deren Größe Sie ändern möchten. Verwenden Sie dann die Option Terminate für die spezifischen Instanceen, die Sie entfernen möchten.

Konfigurieren Sie Timeouts für die Bereitstellung von Kapazität

Wenn Sie Instanceflotten verwenden, können Sie Timeouts für die Bereitstellung konfigurieren. Ein Bereitstellungs-Timeout weist Amazon EMR an, die Bereitstellung von Instance-Kapazität zu beenden, wenn der Cluster während des Cluster-Starts oder der Cluster-Skalierung einen bestimmten Zeitschwellenwert überschreitet. In den folgenden Themen wird beschrieben, wie ein Bereitstellungs-Timeout für den Clusterstart und für Cluster-Hochskalierungsvorgänge konfiguriert wird.

Themen

- Konfigurieren Sie Bereitstellungs-Timeouts für den Cluster-Start in Amazon EMR
- Ein Bereitstellungs-Timeout für den Cluster-Start in Amazon EMR anpassen

Konfigurieren Sie Bereitstellungs-Timeouts für den Cluster-Start in Amazon EMR

Sie können einen Timeout-Zeitraum für die Bereitstellung von Spot Instances für jede Flotte in Ihrem Cluster definieren. Wenn Amazon EMR keine Spot-Kapazität bereitstellen kann, können Sie entweder den Cluster beenden oder stattdessen On-Demand-Kapazität bereitstellen. Wenn der Timeout-Zeitraum während der Cluster-Größenänderung endet, storniert Amazon EMR nicht bereitgestellte Spot-Anfragen. Nicht bereitgestellte Spot Instances werden nicht in On-Demand-Kapazität übertragen.

> **Note**
>
> In der alten Konsole können Sie keinen Timeout-Zeitraum für die Bereitstellung anpassen. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

Führen Sie die folgenden Schritte aus, um ein Bereitstellungs-Timeout für den Clusterstart mit der Amazon-EMR-Konsole anzupassen.

New console

Wie Sie das Bereitstellungs-Timeout konfigurieren, wenn Sie einen Cluster mit der neuen Konsole erstellen

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Navigieren Sie auf der Seite Cluster erstellen zur Cluster-Konfiguration und wählen Sie Instanceflotten.
4. Geben Sie unter Option Clusterskalierung und -Bereitstellung die Spotgröße für Ihre Core- und Taskflotten an.
5. Wählen Sie unter Spot-Timeout-Konfiguration entweder Cluster nach Spot-Timeout beenden oder Nach Spot-Timeout zu On-Demand wechseln. Geben Sie dann den Timeout-Zeitraum für die Bereitstellung von Spot Instances an. Der Standardwert lautet 1 Stunde.
6. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
7. Um Ihren Cluster mit dem konfigurierten Timeout zu starten, wählen Sie Cluster erstellen aus.

AWS CLI

Um ein Bereitstellungs-Timeout mit dem Befehl **`create-cluster`** anzugeben

```
aws emr create-cluster \
--release-label emr-5.35.0 \
--service-role EMR_DefaultRole \
--ec2-attributes '{"InstanceProfile":"EMR_EC2_DefaultRole","SubnetIds":["subnet-
XXXXX"]}' \
--instance-fleets
 '[{"InstanceFleetType":"MASTER","TargetOnDemandCapacity":1,"TargetSpotCapacity":0,"LaunchSp
{"OnDemandSpecification":{"AllocationStrategy":"lowest-
price"}},"InstanceTypeConfigs":[{"WeightedCapacity":1,"EbsConfiguration":
{"EbsBlockDeviceConfigs":[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemand
 - 1"},
{"InstanceFleetType":"CORE","TargetOnDemandCapacity":1,"TargetSpotCapacity":1,"LaunchSpecifi
{"SpotSpecification":
{"TimeoutDurationMinutes":120,"TimeoutAction":"SWITCH_TO_ON_DEMAND"},"OnDemandSpecification"
{"AllocationStrategy":"lowest-price"}},"InstanceTypeConfigs":
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemand
 - 2"}]'
```

Ein Bereitstellungs-Timeout für den Cluster-Start in Amazon EMR anpassen

Definieren Sie einen Timeout-Zeitraum für die Bereitstellung von Spot Instances für jede Flotte in Ihrem Cluster. Wenn Amazon EMR die Spot-Kapazität nicht bereitstellen kann, storniert es die Größenänderungsanforderung und beendet seine Versuche, zusätzliche Spot-Kapazität bereitzustellen. Wenn Sie einen Cluster erstellen, können Sie das Timeout konfigurieren. Für einen laufenden Cluster können Sie ein Timeout hinzufügen oder aktualisieren.

Wenn der Timeout-Zeitraum abläuft, sendet Amazon EMR Ereignisse automatisch an einen Amazon CloudWatch Events Events-Stream. Mit CloudWatch können Sie Regeln erstellen, die nach einem bestimmten Muster auf Ereignisse zutreffen, und Sie können die Ereignisse an Ziele weiterleiten, um entsprechende Maßnahmen zu ergreifen. Sie können beispielsweise eine Regel zum Senden einer E-Mail-Benachrichtigung konfigurieren. Weitere Informationen zum Erstellen von Regeln finden Sie unter Erstellen von Regeln für Amazon-EMR-Ereignisse mit CloudWatch. Weitere Informationen zu

verschiedenen Ereignisdetails finden Sie unter Ereignisse zur Änderung des Status der Instance-Flotte.

Beispiele für Bereitstellungs-Timeouts bei der Clustergrößenänderung

Geben Sie ein Bereitstellungs-Timeout für die Größenänderung mit dem AWS CLI an

Im folgenden Beispiel wird der `create-cluster`-Befehl verwendet, um ein Bereitstellungs-Timeout für die Größenänderung hinzuzufügen.

```
aws emr create-cluster \
--release-label emr-5.35.0 \
--service-role EMR_DefaultRole \
--ec2-attributes '{"InstanceProfile":"EMR_EC2_DefaultRole","SubnetIds":["subnet-
XXXXX"]}' \
--instance-fleets
 '[{"InstanceFleetType":"MASTER","TargetOnDemandCapacity":1,"TargetSpotCapacity":0,"InstanceTyp
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemandPri
 - 1"},
{"InstanceFleetType":"CORE","TargetOnDemandCapacity":1,"TargetSpotCapacity":1,"LaunchSpecificat
{"SpotSpecification":
{"TimeoutDurationMinutes":120,"TimeoutAction":"SWITCH_TO_ON_DEMAND"},"OnDemandSpecification":
{"AllocationStrategy":"lowest-price"}},"ResizeSpecifications":
{"SpotResizeSpecification":{"TimeoutDurationMinutes":20},"OnDemandResizeSpecification":
{"TimeoutDurationMinutes":25}},"InstanceTypeConfigs":
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemandPri
 - 2"}]'
```

Im folgenden Beispiel wird der `modify-instance-fleet`-Befehl verwendet, um ein Bereitstellungs-Timeout für die Größenänderung hinzuzufügen.

```
aws emr modify-instance-fleet \
--cluster-id j-XXXXXXXXXXXXX \
--instance-fleet '{"InstanceFleetId":"if-XXXXXXXXXXXX","ResizeSpecifications":
{"SpotResizeSpecification":{"TimeoutDurationMinutes":30},"OnDemandResizeSpecification":
{"TimeoutDurationMinutes":60}}}' \
--region us-east-1
```

Im folgenden Beispiel wird der `add-instance-fleet-command` verwendet, um ein Bereitstellungs-Timeout für die Größenänderung hinzuzufügen.

```
aws emr add-instance-fleet \
--cluster-id j-XXXXXXXXXXXX \
--instance-fleet
 '{"InstanceFleetType":"TASK","TargetOnDemandCapacity":1,"TargetSpotCapacity":0,"InstanceTypeCo
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemandPri
{"SpotResizeSpecification":{"TimeoutDurationMinutes":30},"OnDemandResizeSpecification":
{"TimeoutDurationMinutes":35}}}' \
--region us-east-1
```

Geben Sie ein Bereitstellungs-Timeout für die Größenänderung und den Start mit dem AWS CLI an

Im folgenden Beispiel wird der `create-cluster`-Befehl verwendet, um ein Bereitstellungs-Timeout für die Größenänderung hinzuzufügen.

```
aws emr create-cluster \
--release-label emr-5.35.0 \
--service-role EMR_DefaultRole \
--ec2-attributes '{"InstanceProfile":"EMR_EC2_DefaultRole","SubnetIds":["subnet-
XXXXX"]}' \
--instance-fleets
 '[{"InstanceFleetType":"MASTER","TargetOnDemandCapacity":1,"TargetSpotCapacity":0,"LaunchSpeci
{"OnDemandSpecification":{"AllocationStrategy":"lowest-price"}},"InstanceTypeConfigs":
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemandPri
 - 1"},
{"InstanceFleetType":"CORE","TargetOnDemandCapacity":1,"TargetSpotCapacity":1,"LaunchSpecificat
{"SpotSpecification":
{"TimeoutDurationMinutes":120,"TimeoutAction":"SWITCH_TO_ON_DEMAND"},"OnDemandSpecification":
{"AllocationStrategy":"lowest-price"}},"ResizeSpecifications":
{"SpotResizeSpecification":{"TimeoutDurationMinutes":20},"OnDemandResizeSpecification":
{"TimeoutDurationMinutes":25}},"InstanceTypeConfigs":
[{"WeightedCapacity":1,"EbsConfiguration":{"EbsBlockDeviceConfigs":
[{"VolumeSpecification":
{"SizeInGB":32,"VolumeType":"gp2"},"VolumesPerInstance":2}]},"BidPriceAsPercentageOfOnDemandPri
 - 2"}]'
```

Überlegungen zur Größenänderung von Bereitstellungs-Timeouts

Wenn Sie Timeouts für die Cluster-Bereitstellung für Ihre Instanceflotten konfigurieren, sollten Sie die folgenden Verhaltensweisen berücksichtigen.

- Sie können Bereitstellungs-Timeouts sowohl für Spot Instances als auch für On-Demand-Instances konfigurieren. Das Mindestzeitlimit für die Bereitstellung beträgt 5 Minuten. Das maximale Bereitstellungszeitlimit beträgt 7 Tage.
- Sie können Bereitstellungs-Zeitlimit nur für einen EMR-Cluster konfigurieren, der Instance-Flotten verwendet. Sie müssen jeden Core und jede Aufgaben-Flotte separat konfigurieren.
- Wenn Sie einen Cluster erstellen, können Sie Bereitstellungs-Zeitlimits konfigurieren. Sie können ein Zeitlimit für einen laufenden Cluster hinzufügen oder ein vorhandenes Zeitlimit aktualisieren.
- Wenn Sie mehrere Größenänderungsvorgänge einreichen, verfolgt Amazon EMR die Bereitstellungs-Timeouts für jeden Größenänderungsvorgang. Legen Sie beispielsweise das Bereitstellungs-Zeitlimit für einen Cluster auf *60* Minuten fest. Senden Sie dann zum Zeitpunkt *T1* einen Vorgang zur Größenänderung *R1*. Senden Sie zum Zeitpunkt *T2* einen zweiten Größenänderungsvorgang *R2*. Das Bereitstellungszeitlimit für R1 läuft bei *T1 + 60 Minuten* ab. Das Bereitstellungszeitlimitt für R2 läuft bei *T2 + 60 Minuten* ab.
- Wenn Sie vor Ablauf des Timeouts einen neuen Vorgang zur Skalierung der Größe einreichen, versucht Amazon EMR weiterhin, Kapazität für Ihren EMR-Cluster bereitzustellen.

Cluster-Herunterskalierung

> **Note**
>
> Optionen für das Herunterskalierungs-Verhalten werden seit der Amazon-EMR-Version 5.10.0 nicht mehr unterstützt. Aufgrund der Einführung der sekundengenauen Abrechnung in Amazon EC2 lautet das standardmäßige Herunterskalierungsverhalten für Amazon-EMR-Cluster nun „Beenden bei Abschluss der Aufgabe“.

Mit Amazon EMR Version 5.1.0 bis 5.9.1. gibt es zwei Optionen für das Herunterskalierungs-Verhalten: „Beenden zur Instance-Stundengrenze für die Amazon EC2-Fakturierung“ oder „Beenden bei Abschluss der Aufgabe“. Beginnend mit Amazon-EMR-Version 5.10.0 ist aufgrund der sekundenweisen Abrechnung die Einstellung für ein Beenden an einer Instance-Stundengrenze

veraltet, da die Amazon-EC2-Abrechnung pro Sekunde eingeführt wurde. Wir raten davon ab, die Beendigung zur Instance-Stundengrenze zu verwenden, wenn diese Option angeboten wird.

> **Warning**
>
> Wenn Sie eine `modify-instance-groups` mit der AWS CLI über `EC2InstanceIdsToTerminate` übergeben, werden diese Instances sofort und ohne Berücksichtigung dieser Einstellungen sowie unabhängig vom Status der darauf ausgeführten Anwendungen beendet. Wenn eine Instance auf diese Weise beendet wird, besteht das Risiko von Datenverlusten und unvorhersehbarem Clusterverhalten.

Wenn „Beim Abschluss der Aufgabe beenden“ angegeben ist, führt Amazon EMR eine Ablehnungsliste auf und entlädt Aufgaben von den Knoten, bevor die Amazon-EC2-Instances beendet werden. Bei beiden Varianten werden durch Amazon EMR keine Amazon-EC2-Instances in den Core-Instance-Gruppen beendet, sofern dies zu HDFS-Beschädigungen führen könnte.

Beendigung bei Aufgaben-Abschluss

Mit Amazon EMR können Sie eine Herunterskalierung für den Cluster durchführen, ohne dass es zu Auswirkungen auf den Workload kommt. Amazon EMR legt YARN, HDFS und andere Daemons auf Core- und Aufgabenknoten während einer Verkleinerung ordnungsgemäß und ohne Datenverlust oder Unterbrechung von Aufgaben still. Amazon EMR verkleinert Instance-Gruppen nur, wenn die zu den Gruppen zugewiesenen Aufgaben abgeschlossen sind und sie unausgelastet sind. Bei ordnungsgemäßer Stilllegung mit YARN NodeManager können Sie die Zeit, die ein Knoten auf die Außerbetriebnahme wartet, manuell einstellen.

Die Dauer wird mit einer Eigenschaft in der `YARN-site`-Konfigurationsklassifizierung eingerichtet. Wenn Sie Amazon-EMR-Version 5.12.0 und höher verwenden, geben Sie die Eigenschaft `YARN.resourcemanager.nodemanager-graceful-decommission-timeout-secs` an. Bei Verwendung von früheren Amazon-EMR-Versionen geben Sie die Eigenschaft `YARN.resourcemanager.decommissioning.timeout` an.

Wenn nach diesem Stilllegungszeitraum noch Container oder YARN-Anwendungen ausgeführt werden, wird die Stilllegung des Knotens erzwungen. YARN plant betroffene Container in anderen Knoten neu. Die Standardwert ist 3600 Sekunden (eine Stunde). Sie können den Timeout auf einen extrem hohen Wert festlegen, um die ordnungsgemäße Verkleinerung zu verzögern. Weitere Informationen finden Sie unter Ordnungsgemäßes Stilllegen von YARN Knoten in der Apache-Hadoop-Dokumentation.

Aufgabenknoten-Gruppen

Amazon EMR wählt in intelligenter Weise Instances aus, die keine Aufgaben im Zusammenhang mit einem Schritt oder einer Anwendung ausführen und entfernt diese Instance zuerst aus einem Cluster. Wenn alle Instances im Cluster genutzt werden, wartet Amazon EMR auf den Abschluss von Tasks in einer Instance, bevor diese aus dem Cluster entfernt wird. Die standardmäßige Leerlaufzeit beträgt eine Stunde. Dieser Wert kann mit der Einstellung `YARN.resourcemanager.decommissioning.timeout` geändert werden. Amazon EMR nutzt die neue Einstellung dynamisch. Sie können diesen Wert auf eine beliebig große Zahl festlegen, um sicherzustellen, dass Amazon EMR keine Aufgaben beendet und gleichzeitig die Clustergröße reduziert.

Core-Knoten-Gruppen

Auf Core-Knoten müssen YARN NodeManager- und HDFS-DataNode-Daemons stillgelegt werden, um die Instance-Gruppe zu verkleinern. Bei YARN stellt das ordnungsgemäße Verkleinern sicher, dass ein für die Außerbetriebnahme vorgesehener Knoten nur dann in den Status `DECOMMISSIONED` wechselt, wenn es keine ausstehenden oder unvollständigen Container oder Anwendungen gibt. Die Außerbetriebnahme wird direkt beendet, falls es zu Beginn der Außerbetriebnahme keine laufenden Container auf dem Knoten gibt.

Bei HDFS stellt die ordnungsgemäße Verkleinerung sicher, dass die Zielkapazität von HDFS für alle vorhandenen Blöcke ausreichend ist. Wenn die Zielkapazität nicht groß genug ist, wird nur ein Teil der Core-Instances außer Betrieb gestellt. So können die verbleibenden Knoten die aktuell in HDFS vorhandenen Daten verarbeiten. Stellen Sie für eine weitere Außerbetriebnahme zusätzliche HDFS-Kapazität sicher. Sie sollten auch versuchen, die Schreib-E/A zu minimieren, bevor Sie versuchen, Instancegruppen zu reduzieren. Übermäßiger Schreib-E/A-Vorgang kann den Abschluss des Größenänderungsvorgangs verzögern.

Ein weiterer Faktor ist der Standard-Replikationsfaktor (`dfs.replication`) in `/etc/hadoop/conf/hdfs-site`. Amazon EMR konfiguriert den Wert basierend auf der Anzahl der Instances im Cluster: `1` bei 1–3 Instances, `2` für Cluster mit 4–9 Instances und `3` für Cluster mit mehr als zehn Instances.

⚠ Warning

1. Das Festlegen von `dfs.replication` auf 1 auf Clustern mit weniger als vier Knoten kann zu einem HDFS-Datenverlust führen, wenn ein einzelner Knoten ausfällt. Wir

empfehlen, für Produktionsworkloads einen Cluster mit mindestens vier Core-Knoten zu verwenden.

2. Amazon EMR erlaubt Clustern nicht, Core-Knoten unter `dfs.replication` zu skalieren. Bei `dfs.replication = 2` z. B. beträgt die Mindestanzahl von Core-Knoten 2.
3. Wenn Sie verwaltete Skalierung oder Auto-Scaling verwenden oder die Größe Ihres Clusters manuell ändern möchten, empfehlen wir Ihnen, `dfs.replication` auf 2 oder höher einzustellen.

Durch die schrittweise Reduzierung können Sie die Anzahl der Core-Knoten nicht unter den HDFS-Replikationsfaktor reduzieren. Auf diese Weise kann HDFS Dateien aufgrund unzureichender Replikate schließen. Um diesen Grenzwert zu umgehen, müssen Sie den Replikationsfaktor verringern und den NameNode-Daemon neu starten.

Das Herunterskalierungs-Verhalten für Amazon-EMR-Cluster konfigurieren

> **Note**
>
> Die Option zum Herunterskalieren zur Instance-Stunde wird für Amazon EMR Version 5.10.0 und höher nicht mehr unterstützt. Die folgenden Optionen für das Scale-Down-Verhalten werden nur in der Amazon-EMR-Konsole für die Versionen 5.1.0 bis 5.9.1 angezeigt.

Sie können die AWS Management Console, die AWS CLI oder die Amazon-EMR-API zum Konfigurieren des Scale-Down-Verhaltens beim Erstellen eines Clusters nutzen.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So konfigurieren Sie das Scale-Down-Verhalten mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster und dann Cluster erstellen aus.
3. Suchen Sie im Abschnitt Optionen zur Cluster-Skalierung und -Bereitstellung nach Clusterbeendigung und wählen Sie aus, ob Sie Ihren Cluster manuell beenden möchten oder Amazon EMR Ihren Cluster nach einer bestimmten Leerlaufzeit beenden lassen möchten. Aktivieren Sie optional den Kündigungsschutz gegen Bugs oder Fehler.
4. Wählen Sie alle anderen Optionen aus, die für Ihren Cluster gelten.
5. Um Ihren Cluster jetzt zu starten, wählen Sie Cluster erstellen aus.

Old console

So konfigurieren Sie das Herunterskalierungs-Verhalten mit der neuen Konsole

1. Öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/elasticmapreduce.
2. Wählen Sie Create cluster (Cluster erstellen). Gehen Sie zu Erweiterte Optionen und wählen Sie Ihre Konfigurationseinstellungen in Schritt 1: Software und Schritte und Schritt 2: Hardware aus.
3. Wählen Sie in Schritt 3: Allgemeine Cluster-Einstellungen Ihr bevorzugtes Herunterskalierungs-Verhalten aus. Schließen Sie die verbleibenden Konfigurationen ab und erstellen Sie Ihren Cluster.

AWS CLI

Wie Sie das Herunterskalierungs-Verhalten mit der AWS CLI konfigurieren

- Verwenden Sie für die `--scale-down-behavior`-Option entweder `TERMINATE_AT_INSTANCE_HOUR` oder `TERMINATE_AT_TASK_COMPLETION`.

Einen Cluster beenden

In diesem Abschnitt werden die Methoden zum Beenden eines Clusters beschrieben. Informationen zum Aktivieren des Beendigungsschutzes und zum automatischen Beenden von Clustern finden Sie unter Steuern der Cluster-Beendigung. Sie können Cluster mit dem Status `STARTING`, `RUNNING`oder `WAITING` beenden. Ein Cluster mit dem Status `WAITING` muss beendet werden. Andernfalls wird er unbegrenzt ausgeführt, und verursacht Gebühren für Ihr Konto. Sie können einen Cluster beenden, der den Status `STARTING` nicht verlässt oder der einen bestimmten Schritt nicht durchführen kann.

Wenn Sie einen Cluster beenden, bei dem der Beendigungsschutz aktiviert ist, müssen Sie den Beendigungsschutz deaktivieren, bevor Sie den Cluster beenden können. Cluster können mithilfe der Konsole, per AWS CLI oder programmgesteuert über die `TerminateJobFlows`-API beendet werden.

Abhängig von der Konfiguration des Clusters kann es 5–20 Minuten dauern, bis der Cluster vollständig beendet ist und die zugeordneten Ressourcen, wie zum Beispiel EC2-Instances, freigegeben sind.

> **Note**
>
> Sie können einen beendeten Cluster nicht neu starten, aber Sie können einen beendeten Cluster klonen, um seine Konfiguration für einen neuen Cluster wiederzuverwenden. Weitere Informationen finden Sie unter Klonen eines Clusters mithilfe der Konsole.

> **Important**
>
> Amazon EMR verwendet die Amazon-EMR-Servicerolle und die `AWSServiceRoleForEMRCleanup` Rolle, um Clusterressourcen in Ihrem Konto zu bereinigen, die Sie nicht mehr verwenden, z. B. Amazon-EC2-Instances. Sie müssen Aktionen für die Rollenrichtlinien angeben, um die Ressourcen zu löschen oder zu beenden. Andernfalls kann Amazon EMR diese Bereinigungsaktionen nicht durchführen, und es können Kosten für ungenutzte Ressourcen anfallen, die im Cluster verbleiben.

Einen Cluster mit der Konsole zu beenden

Sie können einen oder mehrere Cluster mithilfe der Amazon-EMR-Konsole beenden. Die Schritte zum Beenden eines Clusters über die Konsole variieren je nachdem, ob der Beendigungsschutz aktiviert oder deaktiviert ist. Um einen geschützten Cluster zu beenden, müssen Sie zuerst den Beendigungsschutz deaktivieren.

New console

Um den Cluster mit der neuen Konsole zu beenden

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie Clusters und dann den Cluster aus, den Sie beenden möchten.
3. Wählen Sie im Dropdownmenü Aktionen die Option Cluster beenden aus, um die Aufforderung Cluster beenden zu öffnen.
4. Wählen Sie an der Eingabeaufforderung die Option Beenden. Je nach Clusterkonfiguration kann die Kündigung 5 bis 10 Minuten dauern. Weitere Informationen zum Amazon-EMR-Cluster finden Sie unter Einen Cluster beenden.

Old console

So beenden Sie einen Cluster ohne Beendigungsschutz mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie den zu beendenden Cluster aus. Sie können mehrere Cluster auswählen und gleichzeitig beenden.
3. Wähen Sie Beenden.
4. Wählen Sie bei Aufforderung Terminate (Beenden) aus.

   Amazon EMR beendet die Instances im Cluster und stoppt das Speichern von Protokolldaten.

So beenden Sie einen Cluster ohne Beendigungsschutz mit der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie auf der Seite Cluster List (Cluster-Liste) den zu beendenden Cluster aus. Sie können mehrere Cluster auswählen und gleichzeitig beenden.
3. Wähen Sie Beenden.
4. Wenn Sie dazu aufgefordert werden, wählen Sie Change (Ändern) aus, um den Beendigungsschutz zu deaktivieren. Wenn Sie mehrere Cluster ausgewählt haben, wählen Sie Turn off all (Alle deaktivieren) aus, um den Beendigungsschutz für alle Cluster auf einmal zu deaktivieren.
5. Wählen Sie im Dialogfeld Terminate clusters (Cluster beenden) für Termination Protection (Beendigungsschutz) die Option Off (Aus) aus und klicken Sie zur Bestätigung auf das Häkchen.
6. Klicken Sie auf Terminate (Beenden).

   Amazon EMR beendet die Instances im Cluster und stoppt das Speichern von Protokolldaten.

Beenden eines Clusters mithilfe der AWS CLI

So beenden Sie einen ungeschützten Cluster mit der AWS CLI

Verwenden Sie den Unterbefehl `terminate-clusters` mit dem Parameter --cluster-ids, um einen ungeschützten Cluster über die AWS CLI zu beenden.

- Geben Sie den folgenden Befehl ein, um einen einzelnen Cluster zu beenden. Ersetzen Sie dabei *j-3KVXXXXXXX7UG* mit Ihrer Cluster-ID.

  ```
  aws emr terminate-clusters --cluster-ids j-3KVXXXXXXX7UG
  ```

  Geben Sie den folgenden Befehl ein, um mehrere Cluster zu beenden. Ersetzen Sie dabei *j-3KVXXXXXXX7UG* und *j-WJ2XXXXXX8EU* mit Ihren Cluster-IDs.

  ```
  aws emr terminate-clusters --cluster-ids j-3KVXXXXXXX7UG j-WJ2XXXXXX8EU
  ```

Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

So beenden Sie einen geschützten Cluster mit der AWS CLI

Um einen geschützten Cluster mit der AWS CLI zu beenden, deaktivieren Sie zuerst mit dem Unterbefehl `modify-cluster-attributes` und dem Parameter `--no-termination-protected` den Beendigungsschutz. Verwenden Sie dann den Unterbefehl `terminate-clusters` mit dem Parameter `--cluster-ids`, um den Cluster zu beenden.

1. Geben Sie den folgenden Befehl ein, um den Beendigungsschutz zu deaktivieren. Ersetzen Sie dabei *j-3KVTXXXXXX7UG* durch Ihre Cluster-Kennung.

   ```
   aws emr modify-cluster-attributes --cluster-id j-3KVTXXXXXX7UG --no-termination-protected
   ```

2. Geben Sie den folgenden Befehl ein, um den Cluster zu beenden. Ersetzen Sie dabei *j-3KVXXXXXXX7UG* mit Ihrer Cluster-ID.

   ```
   aws emr terminate-clusters --cluster-ids j-3KVXXXXXXX7UG
   ```

   Geben Sie den folgenden Befehl ein, um mehrere Cluster zu beenden. Ersetzen Sie dabei *j-3KVXXXXXXX7UG* und *j-WJ2XXXXXX8EU* mit Ihren Cluster-IDs.

   ```
   aws emr terminate-clusters --cluster-ids j-3KVXXXXXXX7UG j-WJ2XXXXXX8EU
   ```

   Weitere Informationen zur Verwendung von Amazon-EMR-Befehlen in der AWS CLI finden Sie unter https://docs.aws.amazon.com/cli/latest/reference/emr.

Beenden eines Clusters mit der API

Der Vorgang `TerminateJobFlows` beendet die Schrittverarbeitung, lädt alle Protokolldateien aus Amazon EC2 in Amazon S3 hoch (falls konfiguriert) und beendet den Hadoop-Cluster. Ein Cluster wird außerdem automatisch beendet, wenn Sie in einer `KeepJobAliveWhenNoSteps`-Anforderung `False` auf `RunJobFlows` festlegen.

Sie können diese Aktion zum Beenden eines einzelnen Clusters oder einer Liste von Clustern (über die Cluster-IDs) verwenden.

Weitere Informationen zu den speziellen Eingabeparametern von `TerminateJobFlows` finden Sie unter TerminateJobFlows. Weitere Informationen zu den grundlegenden Parametern in der Anfrage finden Sie unter Allgemeine Anforderungsparameter.

Klonen eines Clusters mithilfe der Konsole

Sie können die Amazon-EMR-Konsole zum Klonen eines Clusters verwenden, wodurch eine Kopie der Konfiguration des ursprünglichen Cluster als Basis für einen neuen Cluster erstellt wird.

> **Note**
>
> Wir haben die Amazon-EMR-Konsole neu gestaltet, um sie benutzerfreundlicher zu gestalten. In der neuen Konsole können Sie Cluster klonen, das Auto Scaling verwenden, aber Sie können nur neue Cluster erstellen, wenn Sie sie manuell skalieren oder verwaltete Skalierung verwenden möchten. Unter Was ist neu an der Konsole? erfahren Sie mehr über die Unterschiede zwischen der alten und der neuen Konsolenerfahrung.

New console

So klonen Sie einen Cluster mit der neuen Konsole

1. Melden Sie sich bei AWS Management Console an und öffnen Sie die Amazon-EMR-Konsole unter https://console.aws.amazon.com/emr.
2. Wählen Sie im linken Navigationsbereich unter EMR in EC2 die Option Cluster aus.
3. Um einen Cluster aus der Cluster-LIS zu klonen

    a. Verwenden Sie die Such- und Filteroptionen, um den Cluster, den Sie klonen möchten, in der Listenansicht zu finden.

    b. Markieren Sie das Kontrollkästchen links neben der Zeile für den Cluster, den Sie klonen möchten.

    c. Die Option Klonen ist jetzt oben in der Listenansicht verfügbar. Wählen Sie Klonen aus, um den Klonvorgang zu starten. Wenn für den Cluster Schritte konfiguriert sind, wählen Sie Schritte einschließen und Weiter aus, wenn Sie die Schritte zusammen mit den anderen Clusterkonfigurationen klonen möchten.

d. Überprüfen Sie die Einstellungen für den neuen Cluster, die aus dem geklonten Cluster kopiert wurden. Passen Sie die Einstellungen bei Bedarf an. Wenn Sie mit der Konfiguration des neuen Clusters zufrieden sind, wählen Sie Cluster erstellen aus, um den neuen Cluster zu starten.

4. Wie Sie einen Cluster von einer Cluster-Detailseite aus klonen

   a. Um zur Detailseite des Clusters zu gelangen, den Sie klonen möchten, wählen Sie dessen Cluster-ID aus der Cluster-Listenansicht aus.

   b. Wählen Sie oben auf der Cluster-Detailseite im Menü Aktionen die Option Cluster klonen aus, um den Klonvorgang zu starten. Wenn für den Cluster Schritte konfiguriert sind, wählen Sie Schritte einschließen und Weiter aus, wenn Sie die Schritte zusammen mit den anderen Clusterkonfigurationen klonen möchten.

   c. Überprüfen Sie die Einstellungen für den neuen Cluster, die aus dem geklonten Cluster kopiert wurden. Passen Sie die Einstellungen bei Bedarf an. Wenn Sie mit der Konfiguration des neuen Clusters zufrieden sind, wählen Sie Cluster erstellen aus, um den neuen Cluster zu starten.

Old console

So klonen Sie einen Cluster mithilfe der alten Konsole

1. Navigieren Sie zur neuen Amazon-EMR-Konsole und wählen Sie in der Seitennavigation die Option Zur alten Konsole wechseln aus. Weitere Informationen darüber, was Sie erwartet, wenn Sie zur alten Konsole wechseln, finden Sie unter Verwenden der alten Konsole.
2. Wählen Sie Create cluster (Cluster erstellen).
3. Klicken Sie auf der Seite Cluster List (Cluserliste) auf den zu klonenden Cluster.
4. Klicken Sie oben auf der Seite Cluster Details (Clusterdetails) auf Clone (Klonen).

   Wählen Sie in dem Dialogfeld Yes (Ja), um die Schritte aus dem ursprünglichen Cluster in den geklonten Cluster zu integrieren. Wählen Sie No (Nein) aus, um die Konfiguration des ursprünglichen Clusters zu klonen, ohne die Schritte zu integrieren.

   > **Note**
   >
   > Für Cluster, die mit AMI 3.1.1 und höher (Hadoop 2.x) oder AMI 2.4.8 und höher (Hadoop 1.x) erstellt wurden, gilt, dass wenn Sie einen Cluster klonen und Schritte

integrieren, alle Systemschritte (z. B. Konfigurieren von Hive) zusammen mit den vom Benutzer übermittelten Schritten, bis zu insgesamt 1 000, geklont werden. Alle älteren Schritte, die nicht mehr im Schrittverlauf der Konsole erscheinen, können nicht geklont werden. Für frühere AMIs können nur 256 Schritte geklont werden (einschließlich Systemschritten). Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.

5. Es wird die Seite Create Cluster (Cluster erstellen) wird mit einer Kopie der ursprünglichen Cluster-Konfiguration angezeigt. Überprüfen Sie die Konfiguration, nehmen Sie notwendige Änderungen vor und klicken Sie dann auf Create Cluster (Cluster erstellen).

Automatisieren wiederkehrender Cluster mit AWS Data Pipeline

AWS Data Pipeline ist ein Service zur Automatisierung der Verlagerung und Transformation von Daten. Sie können ihn verwenden, um Eingabedaten in Amazon S3 zu verlagern und das Starten von Clustern zu planen, die diese Daten verarbeiten. Betrachten wir zum Beispiel den Fall, bei dem ein Webserver Datenverkehrsprotokolle aufzeichnet. Wenn Sie einen Cluster wöchentlich zum Analysieren der Verkehrsdaten ausführen möchten, können Sie diese Cluster mit AWS Data Pipeline planen. AWS Data Pipeline ist ein datengesteuerter Workflow, d. h., Aufgaben können von einer anderen Aufgabe abhängig sein (Beispiel: Der Start eines Clusters ist von einem Verschieben der Eingabedaten nach Amazon S3 abhängig). Der Workflow verfügt außerdem über eine robuste Wiederholungsfunktionalität.

Weitere Informationen zu AWS Data Pipeline finden Sie im AWS Data Pipeline-Entwicklerhandbuch, insbesondere in den Tutorials zu Amazon EMR:

- Tutorial: Einen Amazon-EMR-Auftragsverlauf starten
- Erste Schritte: Webprotokolle mit AWS Data Pipeline, Amazon EMR und Hive verarbeiten
- Tutorial: Amazon DynamoDB-Import und Export mit AWS Data Pipeline

Fehlersuche bei Clustern

Ein EMR-Cluster läuft in einem komplexen Ökosystem, das Open-Source-Software, benutzerdefinierten Anwendungscode und AWS-Services umfasst. Wenn bei einem dieser Teile ein Problem auftritt, schlägt der Cluster möglicherweise fehl oder es dauert länger als erwartet, bis er abgeschlossen ist. Die folgenden Themen können Ihnen bei der Identifizierung von Cluster-Problemen und deren Behebung helfen.

Themen

- Welche Tools sind zur Fehlerbehebung verfügbar?
- Anzeigen und Neustarten von Amazon-EMR- und Anwendungsprozessen (Daemons)
- Häufige Fehler in Amazon EMR
- Fehlerbehebung für einen ausgefallenen Cluster
- Fehlerbehebung für einen langsamen Cluster
- Problembehandlung bei einem Lake-Formation-Cluster

Wenn Sie eine neue Hadoop-Anwendung entwickeln, empfehlen wir Ihnen, das Debugging zu aktivieren und eine kleine, aber repräsentative Teilmenge Ihrer Daten zu verarbeiten, um die Anwendung zu testen. Möglicherweise möchten Sie die Anwendung auch Schritt für Schritt ausführen, um jeden Schritt separat zu testen. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings und Schritt 5: Den Cluster Schritt für Schritt testen.

Welche Tools sind zur Fehlerbehebung verfügbar?

Um Clusterfehler zu identifizieren und zu beheben, können Sie die auf dieser Seite beschriebenen Tools verwenden. Möglicherweise müssen Sie einige der Tools initialisieren, wenn Sie den Cluster starten. Andere Tools sind standardmäßig für jeden Cluster verfügbar.

Themen

- Anzeigen von EMR Cluster-Details
- EMR-Cluster-Fehlerdetails anzeigen
- Skripts ausführen und Amazon-EMR-Prozesse konfigurieren
- Anzeige von -Protokolldateien

- Überwachen Sie die Leistung des EMR-Clusters

Anzeigen von EMR Cluster-Details

Sie können die AWS Management Console, die AWS CLI oder die EMR-API verwenden, um detaillierte Informationen zu einem EMR-Cluster und zur Auftragsausführung abzurufen. Weitere Informationen zur Verwendung der AWS Management Console und der AWS CLI finden Sie unter Cluster-Status und -Details anzeigen.

Detailbereich der Amazon-EMR-Konsole

In der Liste Cluster in der Amazon-EMR-Konsole werden allgemeine Informationen über den Status der einzelnen Cluster in Ihrem Konto und Ihrer AWS-Region angezeigt. Die Liste zeigt alle aktiven und beendeten Cluster an, die Sie in den vergangenen zwei Monaten gestartet haben. Sie können in der Liste Clusters (Cluster) den Name (Namen) eines Clusters auswählen, um Details zu diesem anzuzeigen. Diese Informationen sind in verschiedene Kategorien unterteilt, um das Navigieren zu vereinfachen.

Die auf der Cluster-Detailseite verfügbaren Anwendungsbenutzeroberflächen können bei der Fehlerbehebung bei Clustern hilfreich sein. Sie zeigt den Status von YARN-Anwendungen. Bei einigen Anwendungen wie z. B. Spark-Anwendungen können Sie verschiedene Metriken und Facets wie Aufträge, Phasen und Ausführende anzeigen. Weitere Informationen finden Sie unter Anwendungsverlauf anzeigen. Dieses Feature ist nur mit Amazon-EMR-Versionen 5.8.0 und höher verfügbar.

Amazon-EMR;-Befehlszeilenschnittstelle

Sie können die Details eines Cluster in AWS CLI mit dem Argument `--describe` abrufen.

Amazon-EMR-API

Sie können die Details eines Cluster in der API mit der Aktion `DescribeJobFlows` abrufen.

EMR-Cluster-Fehlerdetails anzeigen

Wenn ein EMR-Cluster mit einem Fehler beendet wird, geben die APIs `DescribeCluster` und `ListClusters` einen Fehlercode und eine Fehlermeldung zurück. Bei ausgewählten Clusterfehlern kann Ihnen das `ErrorDetail`-Datenarray bei der Behebung des Fehlers helfen.

Eine Liste der Fehlercodes, die `ErrorDetail` Daten enthalten, finden Sie unter Fehlercodes mit ErrorDetail-Informationen.

> **Note**
>
> Wir verfeinern unsere Fehlermeldungen kontinuierlich, damit Sie die aktuellsten und relevantesten Informationen erhalten. Es wird nicht empfohlen, den Text von `ErrorMessage` zu analysieren, da sich dieser Text ändern kann.

Skripts ausführen und Amazon-EMR-Prozesse konfigurieren

Im Rahmen Ihrer Problembehandlung kann es hilfreich sein, benutzerdefinierte Skripts auf Ihrem Cluster auszuführen oder Clusterprozesse anzuzeigen und zu konfigurieren.

Anwendungsprozesse anzeigen und neu starten

Es kann hilfreich sein, sich die laufenden Prozesse auf Ihrem Cluster anzusehen, um potenzielle Probleme zu diagnostizieren. Sie können Clusterprozesse beenden und neu starten, indem Sie eine Verbindung zum Hauptknoten Ihres Clusters herstellen. Weitere Informationen finden Sie unter Anzeigen und Neustarten von Amazon-EMR- und Anwendungsprozessen (Daemons).

Führen Sie Befehle und Skripts ohne SSH-Verbindung aus

Um als Schritt einen Befehl oder ein Skript auf Ihrem Cluster auszuführen, können Sie die Tools `command-runner.jar` oder `script-runner.jar` verwenden, ohne eine SSH-Verbindung zum Hauptknoten herzustellen. Weitere Informationen finden Sie unter Befehle und Skripts auf einem Amazon-EMR-Cluster ausführen.

Anzeige von -Protokolldateien

Amazon EMR und Hadoop generieren beide Protokolldateien, während der Cluster ausgeführt wird. Sie können auf diese Protokolldateien mit mehreren Tools zugreifen, abhängig von der Konfiguration, die Sie beim Starten des Clusters angegeben haben. Weitere Informationen finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings.

Protokolldateien auf dem Hauptknoten

Jeder Cluster veröffentlicht Protokolldateien im Verzeichnis /mnt/var/log/ auf dem Master-Knoten. Diese Protokolldateien sind nur verfügbar, während der Cluster ausgeführt wird.

So archivieren Sie Protokolldateien in Amazon S3

Wenn Sie den Cluster starten und einen Amazon S3 -Pfad angeben, kopiert der Cluster die in /mnt/var/log/ gespeicherten Protokolldateien auf dem Hauptknoten nach Amazon S3 in 5-Minuten-Intervallen. So wird sichergestellt, dass Sie Zugriff auf die Protokolldateien auch nach Beendigung des Clusters haben. Da die Dateien in 5-Minuten-Intervallen archiviert werden, stehen die letzten Minuten eines unvermittelt beendeten Clusters ggf. nicht zur Verfügung.

Überwachen Sie die Leistung des EMR-Clusters

Amazon EMR bietet mehrere Tools zur Überwachung der Leistung Ihres Clusters.

Hadoop-Webschnittstellen

Jeder Cluster veröffentlicht eine Reihe von Webschnittstellen auf dem Master-Knoten, die Informationen über den Cluster enthalten. Sie können auf diese Webseiten über einen SSH-Tunnel zugreifen, um sie auf dem Master-Knoten zu verbinden. Weitere Informationen finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

CloudWatch-Metriken

Jeder Cluster meldet Metriken an CloudWatch. CloudWatch ist ein Webservice zum Nachverfolgen von Metriken und Festlegen von Alarmen für diese Metriken. Weitere Informationen finden Sie unter Überwachung von Amazon-EMR-Metriken mit CloudWatch.

Anzeigen und Neustarten von Amazon-EMR- und Anwendungsprozessen (Daemons)

Wenn Sie in einem Cluster Fehler beheben, möchten Sie möglicherweise laufende Prozesse auflisten. Möglicherweise möchten Sie Prozesse auch beenden oder neu starten. Sie können beispielsweise einen Prozess neu starten, nachdem Sie eine Konfiguration geändert haben, oder ein Problem mit einem bestimmten Prozess feststellen, nachdem Sie Protokolldateien und Fehlermeldungen analysiert haben.

Es gibt zwei Arten von Prozessen, die auf einem Cluster ausgeführt werden können: Amazon-EMR-Prozesse (z. B. Instance-Controller und Log Pusher) und Prozesse im Zusammenhang mit den auf dem Cluster installierten Anwendungen (z. B. hadoop-hdfs-namenode und hadoop-yarn-resourcemanager).

Um mit Prozessen direkt auf einem Cluster zu arbeiten, stellen Sie eine Verbindung mit dem Hauptknoten her. Weitere Informationen finden Sie unter Verbinden mit einem Cluster.

Anzeigen von ausgeführten Prozessen

Die Methode, mit der Sie laufende Prozesse in einem Cluster anzeigen, unterscheidet sich je nach der von Ihnen verwendeten Amazon-EMR-Version.

EMR 5.30.0 and 6.0.0 and later

Example : Listet alle laufenden Prozesse auf

Im folgenden Beispiel wird `systemctl` verwendet und `--type` angegeben, um alle Prozesse anzuzeigen.

```
systemctl --type=service
```

Example : Listet bestimmte Prozesse auf

Im folgenden Beispiel werden alle Prozesse aufgeführt, deren Namen `hadoop` enthalten.

```
systemctl --type=service | grep -i hadoop
```

Beispielausgabe:

```
 hadoop-hdfs-namenode.service           loaded active running Hadoop namenode
 hadoop-httpfs.service                  loaded active running Hadoop httpfs
 hadoop-kms.service                     loaded active running Hadoop kms
 hadoop-mapreduce-historyserver.service loaded active running Hadoop historyserver
 hadoop-state-pusher.service            loaded active running Daemon process that
 processes and serves EMR metrics data.
 hadoop-yarn-proxyserver.service        loaded active running Hadoop proxyserver
 hadoop-yarn-resourcemanager.service    loaded active running Hadoop resourcemanager
 hadoop-yarn-timelineserver.service     loaded active running Hadoop timelineserver
```

Example : Sehen Sie sich einen detaillierten Statusbericht für einen bestimmten Prozess an

Im folgenden Beispiel wird ein detaillierter Statusbericht für den `hadoop-hdfs-namenode`-Service angezeigt.

```
sudo systemctl status hadoop-hdfs-namenode
```

Beispielausgabe:

```
hadoop-hdfs-namenode.service - Hadoop namenode
   Loaded: loaded (/etc/systemd/system/hadoop-hdfs-namenode.service; enabled; vendor
 preset: disabled)
   Active: active (running) since Wed 2021-08-18 21:01:46 UTC; 26min ago
 Main PID: 9733 (java)
    Tasks: 0
   Memory: 1.1M
   CGroup: /system.slice/hadoop-hdfs-namenode.service
           # 9733 /etc/alternatives/jre/bin/java -Dproc_namenode -Xmx1843m -server -
XX:OnOutOfMemoryError=kill -9 %p ...

Aug 18 21:01:37 ip-172-31-20-123 systemd[1]: Starting Hadoop namenode...
Aug 18 21:01:37 ip-172-31-20-123 su[9715]: (to hdfs) root on none
Aug 18 21:01:37 ip-172-31-20-123 hadoop-hdfs-namenode[9683]: starting namenode,
 logging to /var/log/hadoop-hdfs/ha...out
Aug 18 21:01:46 ip-172-31-20-123 hadoop-hdfs-namenode[9683]: Started Hadoop
 namenode:[  OK  ]
Aug 18 21:01:46 ip-172-31-20-123 systemd[1]: Started Hadoop namenode.
Hint: Some lines were ellipsized, use -l to show in full.
```

EMR 4.x - 5.29.0

Example : Listet alle laufenden Prozesse auf

Das folgende Beispiel listet alle laufenden Prozesse auf.

```
initctl list
```

EMR 2.x - 3.x

Example : Listet alle laufenden Prozesse auf

Das folgende Beispiel listet alle laufenden Prozesse auf.

```
ls /etc/init.d/
```

Beenden und Neustarten von Prozessen

Nachdem Sie bestimmen, welche Prozesse ausgeführt werden, können Sie diese beenden und dann neu starten.

EMR 5.30.0 and 6.0.0 and later

Example : Stoppt einen Prozess

Das folgende Beispiel stoppt den `hadoop-hdfs-namenode`-Prozess.

```
sudo systemctl stop hadoop-hdfs-namenode
```

Sie können `status` abfragen, um zu überprüfen, ob der Prozess gestoppt wurde.

```
sudo systemctl status hadoop-hdfs-namenode
```

Beispielausgabe:

```
hadoop-hdfs-namenode.service - Hadoop namenode
  Loaded: loaded (/etc/systemd/system/hadoop-hdfs-namenode.service; enabled; vendor
 preset: disabled)
  Active: failed (Result: exit-code) since Wed 2021-08-18 21:37:50 UTC; 8s ago
Main PID: 9733 (code=exited, status=143)
```

Example : Startet einen Prozess

Das folgende Beispiel startet den `hadoop-hdfs-namenode`-Prozess.

```
sudo systemctl start hadoop-hdfs-namenode
```

Sie können den Status überprüfen, um sicherzustellen, dass der Prozess ausgeführt wird.

```
sudo systemctl status hadoop-hdfs-namenode
```

Beispielausgabe:

```
hadoop-hdfs-namenode.service - Hadoop namenode
   Loaded: loaded (/etc/systemd/system/hadoop-hdfs-namenode.service; enabled; vendor
 preset: disabled)
   Active: active (running) since Wed 2021-08-18 21:38:24 UTC; 2s ago
  Process: 13748 ExecStart=/etc/init.d/hadoop-hdfs-namenode start (code=exited,
 status=0/SUCCESS)
 Main PID: 13800 (java)
    Tasks: 0
```

```
   Memory: 1.1M
   CGroup: /system.slice/hadoop-hdfs-namenode.service
           # 13800 /etc/alternatives/jre/bin/java -Dproc_namenode -Xmx1843m -server
 -XX:OnOutOfMemoryError=kill -9 %p...
```

EMR 4.x - 5.29.0

Example : Stoppt einen laufenden Prozess

Im folgenden Beispiel wird der `hadoop-hdfs-namenode`-Service gestoppt.

```
sudo stop hadoop-hdfs-namenode
```

Example : Startet einen gestoppten Prozess neu

Im folgenden Beispiel wird der `hadoop-hdfs-namenode`-Service neu gestartet. Sie müssen den `start`-Befehl verwenden und nicht `restart`.

```
sudo start hadoop-hdfs-namenode
```

Example : Überprüfen des Prozessstatus

Im Folgenden wird der Status für `hadoop-hdfs-namenode` abgerufen. Sie können den `status` Befehl verwenden, um zu überprüfen, ob der Prozess gestoppt oder gestartet wurde.

```
sudo status hadoop-hdfs-namenode
```

EMR 2.x - 3.x

Example : Beenden eines Anwendungsprozesses

Im folgenden Beispiel wird der `hadoop-hdfs-namenode`-Service beendet, der mit der auf dem Cluster installierten Version von Amazon EMR verknüpft ist.

```
sudo /etc/init.d/hadoop-hdfs-namenode stop
```

Example : Startet einen Anwendungsprozess neu

Geben Sie den folgenden Befehl ein, um den Prozess `hadoop-hdfs-namenode` neu zu starten:

```
sudo /etc/init.d/hadoop-hdfs-namenode start
```

Example : Beendet einen Amazon-EMR-Prozesses

Das folgende Beispiel stoppt einen Prozess, wie z. B. instance-controller, der nicht mit der Version von Amazon EMR auf dem Cluster verknüpft ist.

```
sudo /sbin/stop instance-controller
```

Example : Neustart eines Amazon-EMR-Prozesses

Im folgenden Beispiel wird ein Prozess neu gestartet, z. B. instance-Controller, der nicht mit der Version von Amazon EMR auf dem Cluster verknüpft ist.

```
sudo /sbin/start instance-controller
```

> **Note**
>
> Die Befehle `/sbin/start, stop` und `restart` sind symbolische Links zu `/sbin/initctl`. Weitere Informationen zu `initctl`finden Sie auf der initctl man-Seite. Geben Sie `man initctl` in die Befehlszeile ein.

Häufige Fehler in Amazon EMR

Manchmal schlagen Cluster fehl oder verarbeiten Daten nur langsam. In den folgenden Abschnitten werden einige häufig auftretende Clusterprobleme mit Vorschlägen zur Behebung dieser Probleme aufgeführt.

Themen

- Fehlercodes mit ErrorDetail-Informationen
- Ressourcenfehler
- Fehler bei der Ein- und Ausgabe
- Berechtigungsfehler
- Hive-Cluster-Fehler
- VPC-Fehler

- Streaming-Cluster-Fehler
- Benutzerdefinierte JAR-Cluster-Fehler
- Fehler in AWS GovCloud (USA-West)
- Finden Sie einen fehlenden Cluster

Fehlercodes mit ErrorDetail-Informationen

Wenn ein EMR-Cluster mit einem Fehler beendet wird, geben die APIs `DescribeCluster` und `ListClusters` einen Fehlercode und eine Fehlermeldung zurück. Bei einigen Clusterfehlern kann Ihnen das `ErrorDetail`-Datenarray bei der Behebung des Fehlers helfen.

Fehler, die ein `ErrorDetail`-Array beinhalten, enthalten die folgenden Informationen:

`ErrorCode`

Ein eindeutiger Fehlercode, den Sie für den programmatischen Zugriff verwenden können.

`ErrorData`

Eine Liste von Bezeichnern in Schlüssel-Wert-Paaren, die Sie für die Programmierung oder die manuelle Suche verwenden können. Eine Beschreibung der `ErrorData` Werte, die ein Fehlercode enthält, finden Sie auf der Seite zur Problembehandlung für den Fehlercode.

`ErrorMessage`

Beschreibung des Fehlers mit einem Link zu weiteren Informationen in der Amazon-EMR-Dokumentation.

> **Note**
>
> Es wird nicht empfohlen, den Text von `ErrorMessage` zu analysieren, da sich dieser Text ändern kann.

Fehlercodes nach Kategorie

- Fehlercodes für Bootstrap-Fehler
- Interne Fehlercodes
- Fehlercodes für Fehler bei der Validierung

Fehlercodes für Bootstrap-Fehler

Die folgenden Abschnitte enthalten Informationen zur Fehlerbehebung bei Bootstrap-Fehlercodes.

Themen

- BOOTSTRAP_FAILURE_PRIMARY_WITH_NON_ZERO_CODE
- BOOTSTRAP_FAILURE_BA_DOWNLOAD_FAILED_PRIMARY
- BOOTSTRAP_FAILURE_FILE_NOT_FOUND_PRIMARY

BOOTSTRAP_FAILURE_PRIMARY_WITH_NON_ZERO_CODE

Übersicht

Wenn ein Cluster mit einem `BOOTSTRAP_FAILURE_PRIMARY_WITH_NON_ZERO_CODE`-Fehler beendet wird, ist eine Bootstrap-Aktion in der primären Instance fehlgeschlagen. Weitere Informationen zu Bootstrap-Aktionen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.

Behebung

Um diesen Fehler zu beheben, überprüfen Sie die im API-Fehler zurückgegebenen Details, ändern Sie Ihr Bootstrap-Aktionsskript und erstellen Sie einen neuen Cluster mit der aktualisierten Bootstrap-Aktion.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`primary-instance-id`

Die ID der primären Instance, bei der die Bootstrap-Aktion fehlgeschlagen ist.

`bootstrap-action`

Die Ordinalzahl für die fehlgeschlagene Bootstrap-Aktion. Ein Skript mit dem `bootstrap-action`-Wert von `1` ist die erste Bootstrap-Aktion, die auf der Instance ausgeführt wird.

`return-code`

Der Rückgabecode für die fehlgeschlagene Bootstrap-Aktion.

`amazon-s3-path`

Der Amazon-S3-Speicherort der Bootstrap-Aktion, die fehlgeschlagen ist.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Gehen Sie wie folgt vor, um die Ursache des Bootstrap-Aktionsfehlers zu ermitteln und zu beheben. Starten Sie dann einen neuen Cluster.

1. Überprüfen Sie die Bootstrap-Aktionsprotokolldateien in Amazon S3, um die Hauptursache für den Fehler zu ermitteln. Weitere Informationen zum Anzeigen von Amazon-EMR-Protokollen finden Sie unter Anzeige von -Protokolldateien.
2. Wenn Sie bei der Erstellung der Instance Cluster-Protokolle aktiviert haben, finden Sie weitere Informationen im `stdout`-Protokoll. Sie finden das `stdout`-Protokoll für die Bootstrap-Aktion an diesem Amazon-S3-Speicherort:

   ```
   s3://EXAMPLE-BUCKET/logs/Your_Cluster_Id/node/Primary_Instance_Id/bootstrap-actions/Failed_Bootstrap_Action_Number/stdout.gz
   ```

   Weitere Informationen zu Clusterprotokollen finden Sie im Abschnitt Konfigurieren der Cluster-Protokollierung und des Debuggings.
3. Um festzustellen, ob die Bootstrap-Aktion fehlgeschlagen ist, überprüfen Sie die Ausnahmen in den `stdout`-Protokollen und den `return-code`-Wert in `ErrorData`.
4. Verwenden Sie Ihre Ergebnisse aus dem vorherigen Schritt, um Ihre Bootstrap-Aktion so zu überarbeiten, dass Ausnahmen vermieden werden oder Ausnahmen ordnungsgemäß behandelt werden können, wenn sie auftreten.
5. Starten Sie einen neuen Cluster mit Ihrer aktualisierten Bootstrap-Aktion.

BOOTSTRAP_FAILURE_BA_DOWNLOAD_FAILED_PRIMARY

Übersicht

Ein Cluster wird mit dem `BOOTSTRAP_FAILURE_BA_DOWNLOAD_FAILED_PRIMARY`-Fehler beendet, wenn die primäre Instance kein Bootstrap-Aktionsskript von dem von Ihnen angegebenen Amazon-S3-Speicherort herunterladen kann. Zu den potentiellen Ursachen zählen auch die Folgenden:

- Die Bootstrap-Aktionsskriptdatei befindet sich nicht am angegebenen Amazon-S3-Speicherort.
- Die Servicerolle für Amazon-EC2-Instances auf dem Cluster (auch EC2-Instance-Profil für Amazon EMR genannt) hat keine Berechtigungen für den Zugriff auf den Amazon-S3-Bucket, in dem sich das Bootstrap-Aktionsskript befindet. Weitere Informationen zu Servicerollen finden Sie unter Servicerolle für EC2-Cluster-Instances (EC2-Instance-Profil).

Weitere Informationen zu Bootstrap-Aktionen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.

Behebung

Um diesen Fehler zu beheben, stellen Sie sicher, dass Ihre primäre Instance über angemessenen Zugriff auf das Bootstrap-Aktionsskript verfügt.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`primary-instance-id`

Die ID der primären Instance, bei der die Bootstrap-Aktion fehlgeschlagen ist.

`bootstrap-action`

Die Ordinalzahl für die fehlgeschlagene Bootstrap-Aktion. Ein Skript mit dem `bootstrap-action`-Wert von `1` ist die erste Bootstrap-Aktion, die auf der Instance ausgeführt wird.

`amazon-s3-path`

Der Amazon-S3-Speicherort der Bootstrap-Aktion, die fehlgeschlagen ist.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Gehen Sie wie folgt vor, um die Ursache des Bootstrap-Aktionsfehlers zu ermitteln und zu beheben. Starten Sie dann einen neuen Cluster.

Fehlerbehebungsschritte

1. Verwenden Sie den `amazon-s3-path`-Wert aus dem `ErrorData`-Array, um das entsprechende Bootstrap-Aktionsskript in Amazon S3 zu finden.
2. Wenn Sie bei der Erstellung der Instance Cluster-Protokolle aktiviert haben, finden Sie weitere Informationen im `stdout`-Protokoll. Sie finden das `stdout`-Protokoll für die Bootstrap-Aktion an diesem Amazon-S3-Speicherort:

   ```
   s3://EXAMPLE-BUCKET/logs/Your_Cluster_Id/node/Primary_Instance_Id/bootstrap-actions/Failed_Bootstrap_Action_Number/stdout.gz
   ```

   Weitere Informationen zu Clusterprotokollen finden Sie im Abschnitt Konfigurieren der Cluster-Protokollierung und des Debuggings.
3. Um festzustellen, ob die Bootstrap-Aktion fehlgeschlagen ist, überprüfen Sie die Ausnahmen in den `stdout`-Protokollen und den `return-code`-Wert in `ErrorData`.
4. Verwenden Sie Ihre Ergebnisse aus dem vorherigen Schritt, um Ihre Bootstrap-Aktion so zu überarbeiten, dass Ausnahmen vermieden werden oder Ausnahmen ordnungsgemäß behandelt werden können, wenn sie auftreten.
5. Starten Sie einen neuen Cluster mit Ihrer aktualisierten Bootstrap-Aktion.

BOOTSTRAP_FAILURE_FILE_NOT_FOUND_PRIMARY

Übersicht

Der `BOOTSTRAP_FAILURE_FILE_NOT_FOUND_PRIMARY`-Fehler weist darauf hin, dass die primäre Instance das Bootstrap-Aktionsskript nicht finden kann, das die Instance gerade aus dem angegebenen Amazon-S3-Bucket heruntergeladen hat.

Behebung

Um diesen Fehler zu beheben, stellen Sie sicher, dass Ihre primäre Instance über angemessenen Zugriff auf das Bootstrap-Aktionsskript verfügt.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`primary-instance-id`

Die ID der primären Instance, bei der die Bootstrap-Aktion fehlgeschlagen ist.

`bootstrap-action`

Die Ordinalzahl für die fehlgeschlagene Bootstrap-Aktion. Ein Skript mit dem `bootstrap-action`-Wert von 1 ist die erste Bootstrap-Aktion, die auf der Instance ausgeführt wird.

`amazon-s3-path`

Der Amazon-S3-Speicherort der Bootstrap-Aktion, die fehlgeschlagen ist.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Gehen Sie wie folgt vor, um die Ursache des Bootstrap-Aktionsfehlers zu ermitteln und zu beheben. Starten Sie dann einen neuen Cluster.

1. Verwenden Sie den `amazon-s3-path`-Wert aus dem `ErrorData`-Array, um das entsprechende Bootstrap-Aktionsskript in Amazon S3 zu finden.
2. Überprüfen Sie die Bootstrap-Aktionsprotokolldateien in Amazon S3, um die Hauptursache für den Fehler zu ermitteln. Weitere Informationen zum Anzeigen von Amazon-EMR-Protokollen finden Sie unter Anzeige von -Protokolldateien.

   > **Note**
   >
   > Wenn Sie die Protokolle für Ihren Cluster nicht aktiviert haben, müssen Sie einen neuen Cluster mit denselben Konfigurationen und Bootstrap-Aktionen erstellen. Informationen dazu, wie Sie sicherstellen können, dass die Clusterprotokolle aktiviert sind, finden Sie unter Konfigurieren der Cluster-Protokollierung und des Debuggings.

3. Überprüfen Sie das `stdout`-Protokoll auf Ihre Bootstrap-Aktionen und stellen Sie sicher, dass es keine benutzerdefinierten Prozesse gibt, die Dateien im `/emr/instance-controller/lib/bootstrap-actions`-Ordner auf Ihren primären Instances löschen. Sie finden das `stdout`-Protokoll für die Bootstrap-Aktion an diesem Amazon-S3-Speicherort:

```
s3://EXAMPLE-BUCKET/logs/Your_Cluster_Id/node/Primary_Instance_Id/bootstrap-
actions/Failed_Bootstrap_Action_Number/stdout.gz
```

4. Starten Sie einen neuen Cluster mit Ihrer aktualisierten Bootstrap-Aktion.

Interne Fehlercodes

Die folgenden Abschnitte enthalten Informationen zur Fehlerbehebung bei internen Fehlercodes.

Themen

- INTERNAL_ERROR_EC2_INSUFFICIENT_CAPACITY_AZ
- INTERNAL_ERROR_SPOT_PRICE_INCREASE_PRIMARY
- INTERNAL_ERROR_SPOT_NO_CAPACITY_PRIMARY

INTERNAL_ERROR_EC2_INSUFFICIENT_CAPACITY_AZ

Übersicht

Ein Cluster wird mit einem `INTERNAL_ERROR_EC2_INSUFFICIENT_CAPACITY_AZ`-Fehler beendet, wenn die ausgewählte Availability Zone nicht über genügend Kapazität verfügt, um Ihre Anfrage vom Amazon-EC2-Instance-Typ zu erfüllen. Die Availability Zone ist von dem von Ihnen für einen Cluster ausgewählten Subnetz abhängig. Weitere Informationen über die Amazon-EMR-Unterstützung erhalten Sie unter Netzwerk konfigurieren.

Behebung

Um diesen Fehler zu beheben, ändern Sie Ihre Instance-Typ-Konfigurationen und erstellen Sie einen neuen Cluster mit Ihrer aktualisierten Anfrage.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`instance-type`

Der Instance-Typ, dessen Kapazität aufgebraucht ist.

availability-zone

Die Availability Zone, in die Ihr Subnetz aufgelöst wird.

public-doc

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Gehen Sie wie folgt vor, um die Ursache des Cluster Konfigurationsfehlers zu ermitteln und zu beheben:

- Für andere Clusterkonfiguration lesen Sie die bewährten Methoden. Weitere Informationen finden Sie unter Bewährte Methoden für die Konfiguration des Clusters im Amazon-EMR-Managementhandbuch.
- Beheben Sie die Startprobleme und überprüfen Sie Ihre Konfiguration. Weitere Informationen finden Sie unter Beheben von Problemen beim Starten von Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.
- Starten Sie einen neuen Cluster mit Ihrer aktualisierten Cluster-Konfiguration.

INTERNAL_ERROR_SPOT_PRICE_INCREASE_PRIMARY

Übersicht

Ein Cluster wird mit einem `INTERNAL_ERROR_SPOT_PRICE_INCREASE_PRIMARY`-Fehler beendet, wenn Amazon EMR Ihre Spot Instance-Anfrage für den Primärknoten nicht erfüllen kann, weil Instances nicht zu oder unter Ihrem maximalen Spot-Preis verfügbar sind. Weitere Informationen dazu finden Sie unter Spot-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Behebung

Um diesen Fehler zu beheben, geben Sie Instance-Typen für Ihren Cluster an, die innerhalb Ihres Preisziels liegen, oder erhöhen Sie Ihr Preislimit für denselben Instance-Typ.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`primary-instance-id`

Die ID für die primäre Instance des Clusters, die fehlgeschlagen ist.

`instance-type`

Der Instance-Typ, dessen Kapazität aufgebraucht ist.

`availability-zone`

Die Availability Zone, in der sich Ihr Subnetz befindet.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um Probleme mit Ihrer Cluster-Konfigurationsstrategie zu beheben, und starten Sie dann einen neuen Cluster:

1. Lesen Sie die bewährten Methoden für Spot Instances in Amazon EC2 und überprüfen Sie Ihre Cluster-Konfigurationsstrategie. Weitere Informationen finden Sie unter Bewährte Methoden für Spot Instances für EC2 Spot und im Benutzerhandbuch von Amazon EC2 für Linux-Instances und Bewährte Methoden für die Konfiguration des Clusters.
2. Um diesen Fehler zu beheben, ändern Sie Ihre Instance-Typ-Konfigurationen oder Availability Zone und erstellen Sie einen neuen Cluster mit Ihrer aktualisierten Anfrage.
3. Wenn das Problem weiterhin besteht, verwenden Sie On-Demand-Kapazität für Ihre primäre Instance.

INTERNAL_ERROR_SPOT_NO_CAPACITY_PRIMARY

Übersicht

Ein Cluster wird mit einem `INTERNAL_ERROR_SPOT_NO_CAPACITY_PRIMARY`-Fehler beendet, wenn nicht genügend Kapazität vorhanden ist, um eine Spot Instance-Anfrage für Ihren Primärknoten zu erfüllen. Weitere Informationen dazu finden Sie unter Spot-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Behebung

Um diesen Fehler zu beheben, geben Sie Instance-Typen für Ihren Cluster an, die innerhalb Ihres Preisziels liegen, oder erhöhen Sie Ihr Preislimit für denselben Instance-Typ.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`primary-instance-id`

Die ID für die primäre Instance des Clusters, die fehlgeschlagen ist.

`instance-type`

Der Instance-Typ, dessen Kapazität aufgebraucht ist.

`availability-zone`

Die Availability Zone, in die Ihr Subnetz aufgelöst wird.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um Probleme mit Ihrer Cluster-Konfigurationsstrategie zu beheben, und starten Sie dann einen neuen Cluster:

1. Lesen Sie die bewährten Methoden für Spot Instances in Amazon EC2 und überprüfen Sie Ihre Cluster-Konfigurationsstrategie. Weitere Informationen finden Sie unter Bewährte Methoden für Spot Instances für EC2 Spot und im Benutzerhandbuch von Amazon EC2 für Linux-Instances und Bewährte Methoden für die Konfiguration des Clusters.
2. Ändern Sie Ihre Instance-Typ-Konfigurationen und erstellen Sie einen neuen Cluster mit Ihrer aktualisierten Anfrage.
3. Wenn das Problem weiterhin besteht, verwenden Sie On-Demand-Kapazität für Ihre primäre Instance.

Fehlercodes für Fehler bei der Validierung

Die folgenden Abschnitte enthalten Informationen zur Fehlerbehebung bei Validierung-Fehlercodes.

Themen

- VALIDATION_ERROR_SUBNET_NOT_FROM_ONE_VPC
- VALIDATION_ERROR_SECURITY_GROUP_NOT_FROM_ONE_VPC
- VALIDATION_ERROR_INVALID_SSH_KEY_NAME
- VALIDATION_ERROR_INSTANCE_TYPE_NOT_SUPPORTED

VALIDATION_ERROR_SUBNET_NOT_FROM_ONE_VPC

Übersicht

Wenn Ihr Cluster und die Subnetze, auf die Sie für Ihren Cluster verweisen, zu verschiedenen Virtual Private Clouds (VPCs) gehören, wird der Cluster mit einem Fehler `VALIDATION_ERROR_SUBNET_NOT_FROM_ONE_VPC` beendet. Sie können Cluster mit Amazon EMR mit der Konfiguration der Instance-Flotten in allen Subnetzen in einer VPC starten. Weitere Informationen über Instance-Flotten finden Sie unter Instance-Flotten konfigurieren im Amazon-EMR-Managementhandbuch.

Behebung

Verwenden Sie Subnetze, die zur gleichen VPC gehören wie der Cluster, um diesen Fehler zu beheben.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`vpc`

Für jedes Subnetz:VPC-Paar die ID für die VPC, der das Subnetz angehört.

`subnet`

Für jedes Subnetz:VPC-Paar die ID für das Subnetz.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um den Fehler zu identifizieren und zu beheben:

1. Überprüfen Sie die Subnetz-IDs, die im `ErrorData`-Array aufgeführt sind, und stellen Sie sicher, dass sie zu der VPC gehören, auf der Sie den EMR-Cluster starten möchten.
2. Ändern Sie Ihre Subnetzkonfigurationen. Sie können eine der folgenden Methoden verwenden, um alle verfügbaren öffentlichen und privaten Subnetze in einer VPC zu finden.
   - Navigieren Sie zur Amazon-VPC-Konsole. Wählen Sie Subnetze aus und listen Sie alle Subnetze auf, die sich in Ihrem AWS-Region-Cluster befinden. Um nur öffentliche oder private Subnetze zu finden, wenden Sie den Filter Öffentliche IPv4-Adresse automatisch zuweisen an. Um Subnetze in der von Ihrem Cluster verwendeten VPC zu finden und auszuwählen, verwenden Sie die Option Nach VPC filtern. Weitere Informationen zum Erstellen von Subnetzen finden Sie unter Erstellen eines Subnetzes im Benutzerhandbuch von Amazon Virtual Private Cloud.
   - Verwenden Sie AWS CLI, um alle verfügbaren öffentlichen und privaten Subnetze in der VPC zu finden, die Ihr Cluster verwendet. Weitere Informationen finden Sie in der describe-subnets-API. Informationen zum Erstellen neuer Subnetze in einer VPC finden Sie in der create-subnet-API.
3. Starten Sie einen neuen Cluster mit Subnetzen aus derselben VPC wie der Cluster.

VALIDATION_ERROR_SECURITY_GROUP_NOT_FROM_ONE_VPC

Übersicht

Wenn Ihr Cluster und die Sicherheitsgruppen, die Sie Ihrem Cluster zuweisen, zu verschiedenen Virtual Private Clouds (VPCs) gehören, wird der Cluster mit einem `VALIDATION_ERROR_SECURITY_GROUP_NOT_FROM_ONE_VPC`-Fehler beendet. Weitere Informationen zu Sicherheitsgruppen finden Sie unter Angeben von Amazon EMR-verwalteten und zusätzlichen Sicherheitsgruppen und Steuerung des Netzwerkverkehrs mit Sicherheitsgruppen.

Behebung

Um diesen Fehler zu beheben, verwenden Sie Sicherheitsgruppen, die zu derselben VPC gehören wie der Cluster.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`vpc`

Für jedes Security-Group:VPC-Paar die ID für die VPC, zu der die Sicherheitsgruppe gehört.

`security-group`

Für jedes Security-Group:VPC-Paar die ID für die Sicherheitsgruppe.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um den Fehler zu identifizieren und zu beheben:

1. Überprüfen Sie die Sicherheitsgruppen-IDs, die im `ErrorData`-Array aufgeführt sind, und stellen Sie sicher, dass sie zu der VPC gehören, auf der Sie den EMR-Cluster starten möchten.
2. Navigieren Sie zur Amazon-VPC-Konsole. Wählen Sie Sicherheitsgruppen aus, um alle Sicherheitsgruppen in der ausgewählten Region aufzulisten. Suchen Sie die Sicherheitsgruppen aus derselben VPC wie Ihr Cluster und ändern Sie dann Ihre Sicherheitsgruppenkonfiguration.
3. Starten Sie einen neuen Cluster mit Sicherheitsgruppen aus derselben VPC wie der Cluster.

VALIDATION_ERROR_INVALID_SSH_KEY_NAME

Übersicht

Ein Cluster wird mit einem `VALIDATION_ERROR_INVALID_SSH_KEY_NAME`-Fehler beendet, wenn Sie ein Amazon-EC2-Schlüsselpaar verwenden, das für SSH-Verbindungen zur primären Instance nicht gültig ist. Der Name des Schlüsselpaars ist möglicherweise falsch, oder das key pair ist in der

angeforderten AWS-Region nicht vorhanden. Weitere Informationen über Schlüsselpaare finden Sie unter Amazon-EC2-Schlüsselpaare und Linux-Instances im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

Behebung

Um diesen Fehler zu beheben, erstellen Sie einen neuen Cluster mit einem gültigen SSH-Schlüsselpaarnamen.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`ssh-key`

Der Name des SSH-Schlüsselpaars, den Sie bei der Erstellung des Clusters angegeben haben.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um den Fehler zu identifizieren und zu beheben:

1. Überprüfen Sie Ihre *`Schlüsselpaar`*.pem-Datei und vergewissern Sie sich, dass sie mit dem Namen des SSH-Schlüssels übereinstimmt, den Sie in der Amazon-EMR-Konsole sehen.
2. Navigieren Sie zur Amazon-EC2-Konsole. Stellen Sie sicher, dass der SSH-Schlüsselname, den Sie verwendet haben, in der AWS-Region die Ihr Cluster verwendet, verfügbar ist. Sie finden Ihre AWS-Region neben Ihrer Konto-ID oben im AWS Management Console.
3. Starten Sie einen neuen Cluster mit einem gültigen SSH-Schlüsselnamen.

VALIDATION_ERROR_INSTANCE_TYPE_NOT_SUPPORTED

Übersicht

Ein Cluster wird mit einem `VALIDATION_ERROR_INSTANCE_TYPE_NOT_SUPPORTED`-Fehler beendet, wenn die AWS-Region und Availability Zones für Ihren Cluster den angegebenen

Instance-Typ für eine oder mehrere Instance-Gruppen nicht unterstützen. Amazon EMR unterstützt möglicherweise einen Instance-Typ in einer Availability Zone innerhalb einer Region, aber nicht in einer anderen. Die Availability Zone innerhalb der Region ist von dem von Ihnen für einen Cluster ausgewählten Subnetz abhängig. Eine Liste der Instance-Typen und -Regionen, die Amazon EMR unterstützt, finden Sie unter Unterstützte Instance-Typen.

Behebung

Um diesen Fehler zu beheben, geben Sie Instance-Typen für Ihren Cluster an, die Amazon EMR in der Region und Availability Zone unterstützt, in der Sie den Cluster anfordern.

Informationen zur Behebung des ausgefallenen EMR-Clusters finden Sie in den `ErrorDetail`-Informationen, die von den APIs `DescribeCluster` und `ListClusters` zurückgegeben werden. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen. Das in `ErrorDetail` enthaltene `ErrorData`-Array gibt die folgenden Informationen für diesen Fehlercode zurück:

`instance-types`

Die Liste der nicht unterstützten Instance-Typen.

`availability-zones`

Die Availability Zone Liste, in die Ihr Subnetz aufgelöst wird.

`public-doc`

Die öffentliche URL der Dokumentation für den Fehlercode.

Schritte zum Absolvieren

Führen Sie die folgenden Schritte aus, um den Fehler zu identifizieren und zu beheben:

1. Verwenden Sie AWS CLI, um die verfügbaren Instance-Typen in einer Availability Zone abzurufen. Zu diesem Zweck können Sie den `ec2 describe-instance-type-offerings`-Befehl verwenden, um verfügbare Instance-Typen nach Standort (AWS-Region oder Availability Zone) zu filtern. Beispielsweise können Sie den folgenden Befehl verwenden, um die Instance-Typen anzuzeigen, die in der angegebenen AZ angeboten werden. *`us-east-2a`*

```
aws ec2 describe-instance-type-offerings --location-type "availability-
zone" --filters Name=location,Values=us-east-2a --region us-east-2 --query
 "InstanceTypeOfferings[*].[InstanceType]" --output text | sort
```

Weitere Informationen darüber, wie Sie verfügbare Instance-Typen ermitteln können, finden Sie unter Suchen eines Amazon-EC2-Instance-Typs.

2. Nachdem Sie die Instance-Typen ermittelt haben, die in derselben Region und Availability Zone wie der Cluster verfügbar sind, wählen Sie eine der folgenden Lösungen, um fortzufahren:

   a. Erstellen Sie einen neuen Cluster und wählen Sie ein Subnetz für den Cluster aus, das sich in einer Availability Zone befindet, in der der von Ihnen ausgewählte Instance-Typ verfügbar ist und von Amazon EMR unterstützt wird.

   b. Erstellen Sie einen neuen Cluster in derselben Region und demselben Amazon-EC2-Subnetz wie der ausgefallene Cluster, jedoch mit einem Instance-Typ, der an diesem Standort von Amazon EMR unterstützt wird.

Eine Liste der Instance-Typen und -Regionen, die Amazon EMR unterstützt, finden Sie unter Unterstützte Instance-Typen. Informationen zum Vergleichen der Funktionen der Instance-Typen finden Sie unter Amazon-EC2-Instance-Typen.

Ressourcenfehler

Die folgenden Fehler werden häufig durch eingeschränkte Ressourcen im Cluster verursacht.

Themen

- Cluster wird mit NO_SLAVE_LEFT und Core-Knoten mit FAILED_BY_MASTER beendet
- Replizieren von Block nicht möglich, nur Replizieren auf null Knoten möglich.
- EC2-KONTINGENT ÜBERSCHRITTEN
- Zu viele Abruffehler
- Datei konnte nur auf 0 Knoten anstatt auf 1 repliziert werden
- Knoten, die auf der Liste stehen
- Drosselungsfehler
- Instance-Typ nicht unterstützt
- EC2 hat keine Kapazität mehr

Cluster wird mit NO_SLAVE_LEFT und Core-Knoten mit FAILED_BY_MASTER beendet

Dies passiert in der Regel, da der Beendigungsschutz deaktiviert ist, und alle Core-Knoten überschreiten die Datenträger-Speicherkapazität, die durch einen Schwellenwert für die maximale Auslastung in der `yarn-site`-Konfigurationsklassifizierung angegeben ist, die der `yarn-site.xml`-Datei entspricht. Dieser Wert liegt standardmäßig bei 90 %. Wenn die Datenträgernutzung für einen Core-Knoten die Auslastungsschwelle überschreitet, meldet der Zustandsprüfungsdienst YARN NodeManager den Knoten als `UNHEALTHY`. Während sich der Knoten in diesem Zustand befindet, wird er von Amazon EMR gesperrt und ihm werden keine YARN-Container zugeordnet. Wenn der Knoten 45 Minuten lang fehlerhaft bleibt, markiert Amazon EMR die zugehörige Amazon-EC2-Instance für die Beendigung als `FAILED_BY_MASTER`. Wenn alle mit Core-Knoten verknüpften Amazon-EC2-Instances für die Beendigung markiert sind, wird der Cluster mit dem Status `NO_SLAVE_LEFT` beendet, da keine Ressourcen zum Ausführen von Aufträgen vorhanden sind.

Das Überschreiten der Datenträgernutzung auf einem Core-Knoten könnte eine Kettenreaktion auslösen. Wenn ein einzelner Knoten den Schwellenwert für die Datenträgernutzung aufgrund von HDFS überschreitet, liegen andere Knoten wahrscheinlich auch in der Nähe des Schwellenwerts. Der erste Knoten überschreitet den Schwellenwert für die Datenträgernutzung, daher wird er von Amazon EMR zu einer Sperrliste hinzugefügt. Dies erhöht den Aufwand der Datenträgernutzung für die verbleibenden Knoten, da sie jetzt untereinander HDFS-Daten replizieren, die auf dem gesperrten Knoten verloren gingen. Jeder Knoten wird anschließend auf die gleiche Weise in den Zustand `UNHEALTHY` versetzt und der Cluster wird schließlich beendet.

Bewährte Methoden und Empfehlungen

Konfigurieren von Cluster-Hardware mit ausreichend Speicher

Wenn Sie einen Cluster erstellen, stellen Sie sicher, dass genügend Core-Knoten vorhanden sind und alle über ausreichend Instance-Speicher und EBS-Speicher-Volumes für HDFS verfügen. Weitere Informationen finden Sie unter Berechnen der erforderlichen HDFS-Kapazität eines Clusters. Sie können auch Core-Instances manuell oder mithilfe der automatischen Skalierung zu vorhandenen Instance-Gruppen hinzuzufügen. Die neuen Instances haben dieselbe Speicherkonfiguration wie andere Instances in der Instance-Gruppe. Weitere Informationen finden Sie unter Clusterskalierung verwenden.

Aktivieren des Beendigungsschutzes

Beendigungsschutz aktivieren. Wenn ein Core-Knoten gesperrt wird, können Sie auf diese Weise mithilfe von SSH eine Verbindung mit der zugehörigen Amazon-EC2-Instance herstellen, um den Fehler zu beheben und Daten wiederherzustellen. Wenn Sie den Beendigungsschutz aktivieren, sollten Sie daran denken, dass Amazon EMR die Amazon-EC2-Instance nicht durch eine neue Instance ersetzt. Weitere Informationen finden Sie unter Verwenden des Beendigungsschutzes.

Erstellen von Alarmen für die CloudWatch-Metrik MRUnhealthyNodes

Diese Metrik meldet die Anzahl der Knoten mit dem Status `UNHEALTHY`. Sie entspricht der YARN-Metrik `mapred.resourcemanager.NoOfUnhealthyNodes`. Sie können eine Benachrichtigung für diesen Alarm einrichten, um über fehlerhafte Knoten informiert zu werden, bevor der 45-Minuten-Timeout erreicht ist. Weitere Informationen finden Sie unter Überwachung von Amazon-EMR-Metriken mit CloudWatch.

Anpassen von Einstellungen mit yarn-site

Die folgenden Einstellungen können an Ihre Anwendungsanforderungen angepasst werden. Beispiel: Sie möchten den Schwellenwert für die Datenträgernutzung erhöhen, bei dem ein Knoten `UNHEALTHY` melden, indem Sie den Wert von `yarn.nodemanager.disk-health-checker.max-disk-utilization-per-disk-percentage` erhöhen.

Sie können diese Werte festlegen, wenn Sie einen Cluster mithilfe der `yarn-site`-Konfigurationsklassifizierung erstellen. Weitere Informationen finden Sie unter Konfigurieren von Anwendungen in den Amazon-EMR-Versionshinweisen. Sie können mit SSH auch eine Verbindung zu den mit Core-Knoten verknüpften Amazon-EC2-Instances herstellen und die Werte dann mithilfe eines Texteditors in `/etc/hadoop/conf.empty/yarn-site.xml` hinzufügen. Nachdem Sie die Änderung vorgenommen haben, müssen Sie hadoop-yarn-nodemanager wie unten dargestellt neu starten.

> **Important**
>
> Wenn Sie den Service NodeManager neu starten, werden die aktiven YARN-Container beendet, es sei denn, `yarn.nodemanager.recovery.enabled` wird bei der Erstellung des Clusters mithilfe der `yarn-site`-Konfigurationsklassifizierung auf `true` festgelegt. Darüber hinaus müssen Sie über die Eigenschaft `yarn.nodemanager.recovery.dir` das Verzeichnis angeben, in dem der Containerstatus gespeichert werden soll.

```
sudo /sbin/stop hadoop-yarn-nodemanager
sudo /sbin/start hadoop-yarn-nodemanager
```

Weitere Informationen zu den aktuellen `yarn-site`-Eigenschaften und Standardwerten finden Sie unter YARN-Standardeinstellungen in der Apache Hadoop-Dokumentation.

Property (Eigenschaft)	Standardwert	Beschreibung
yarn.nodemanager.disk-health-checker.interval-ms	120000	Die Häufigkeit (in Sekunden), mit der die Datenträger-Zustandsprüfung ausgeführt wird.
yarn.nodemanager.disk-health-checker.min-healthy-disks	0.25	Der Mindestbruchteil der Anzahl von Datenträgern, die fehlerfrei sein müssen, damit NodeManager neue Container startet. Dies entspricht sowohl yarn.nodemanager.local-dirs (standardmäßig `/mnt/yarn` in Amazon EMR) und yarn.nodemanager.log-dirs (standardmäßig `/var/log/hadoop-yarn/containers`, was symbolisch mit `mnt/var/log/hadoop-yarn/containers` in Amazon EMR verknüpft ist).
`yarn.nodemanager.disk-health-checker.max-disk-utilization-per-disk-percentage`	90.0	Der maximale Prozentsatz der zulässigen Speicherplatzauslastung, ab der ein Datenträger als fehlerhaft markiert wird. Die Werte können zwischen 0,0 und 100,0 liegen. Wenn der Wert größer oder gleich 100 ist, prüft NodeManager auf einen vollen Datenträg

Property (Eigenschaft)	Standardwert	Beschreibung
		er. Dies gilt für `yarn-node manager.local-dirs` und `yarn.nodemanager.log-dirs` .
`yarn.nodemanager.disk-health-checker.min-free-space-per-disk-mb`	0	Der mindestens erforderliche verfügbare Speicherplatz, damit ein Datenträger verwendet werden kann. Dies gilt für `yarn-node manager.local-dirs` und `yarn.nodemanager.log-dirs` .

Replizieren von Block nicht möglich, nur Replizieren auf null Knoten möglich.

Der Fehler „Replizieren von Block nicht möglich, nur Replizieren auf null Knoten möglich“ tritt in der Regel auf, wenn ein Cluster nicht über genügend HDFS-Speicher verfügt. Dieser Fehler tritt auf, wenn Sie mehr Daten in Ihrem Cluster generieren als in HDFS gespeichert werden können. Sie sehen diesen Fehler nur, während der Cluster ausgeführt wird, da der HDFS-Speicherplatz nach dem Beenden des Auftrags freigegeben wird.

Die Menge des für einen Cluster verfügbaren HDFS-Speicherplatzes hängt von der Anzahl und Art der Amazon EC2 Instances ab, die als Core-Knoten verwendet werden. Für HDFS-Speicher werden keine Aufgabenknoten verwendet. Der gesamte Speicherplatz auf jeder Amazon-EC2-Instance, einschließlich angefügter EBS-Speichervolumen, ist für HDFS verfügbar. Weitere Informationen über die Größe des lokalen Speichers für jeden einzelnen EC2 Instance-Typ finden Sie unter Instance Types and Families im Amazon EC2 Benutzerhandbuch für Linux Instances.

Der zweite Faktor, der sich auf die Menge des verfügbaren HDFS Speicherplatzes auswirkt, ist der Replikationsfaktor. Dieser beschreibt die Anzahl von Kopien jedes Datenblocks, die in HDFS zu Redundanzzwecken gespeichert werden können. Der Replikationsfaktor steigt mit der Anzahl der Knoten im Cluster: Es gibt 3 Kopien jedes Datenblocks für einen Cluster mit 10 oder mehr Knoten, 2 Kopien jedes Blocks für einen Cluster mit 4 bis 9 Knoten und 1 Kopie (keine Redundanz) für Cluster mit 3 oder weniger Knoten. Der gesamte verfügbare HDFS-Speicherplatz wird durch den Replikationsfaktor dividiert. In einigen Fällen, z. B. bei Erhöhung der Anzahl von Knoten von 9 auf

10, kann der Anstieg des Replikationsfaktors dazu führen, dass der verfügbare HDFS-Speicherplatz verringert wird.

Beispielsweise kann ein Cluster mit 10 Core-Knoten vom Typ m1.large 2.833 GB Speicherplatz für HDFS zur Verfügung stellen ((10 Knoten X 850 GB pro Knoten)/Replikationsfaktor 3).

Wenn Ihr Cluster den HDFS zur Verfügung stehenden Speicherplatz überschreitet, können Sie Ihrem Cluster weitere Core-Knoten hinzufügen oder die Datenkomprimierung verwenden, um mehr HDFS-Speicherplatz zu erstellen. Wenn Ihr Cluster beendet und neu gestartet werden kann, können Sie ggf. Core-Knoten eines größeren Amazon EC2 Instance-Typs verwenden. Sie können auch den Replikationsfaktor anpassen. Beachten Sie, dass durch Verringern des Replikationsfaktors die Redundanz der HDFS-Daten sowie die Cluster-Funktion zur Wiederherstellung von verlorenen oder beschädigten HDFS-Blöcken beeinträchtigt wird.

EC2-KONTINGENT ÜBERSCHRITTEN

Wenn Sie die Meldung `EC2 QUOTA EXCEEDED` erhalten, gibt es möglicherweise mehrere Ursachen. Je nach Konfigurationsunterschieden kann es zwischen 5 und 20 Minuten dauern, bis vorherige Cluster beendet und die entsprechenden Ressourcen wieder freigegeben werden. Wenn Sie beim Versuch, einen Custer zu starten, die Fehlermeldung `EC2 QUOTA EXCEEDED` erhalten, kann es daran liegen, dass Ressourcen eines kürzlich beendeten Clusters noch nicht zur Verfügung stehen. Diese Meldung kann auch durch die Größenanpassung einer Instance-Gruppe oder Instance-Flotte an eine Zielgröße, die das aktuelle Instance-Kontingent für das Konto überschreitet, verursacht werden. Dies kann manuell oder automatisch durch Auto Scaling geschehen.

Sie können das Problem u. U. mit den folgenden Optionen beheben:

- Folgen Sie den Anweisungen unter AWS-Service-Quotas in Allgemeine Amazon Web Services-Referenz, um eine Erhöhung des Servicelimits zu beantragen. Für einige APIs ist die Einrichtung eines CloudWatch-Ereignisses möglicherweise eine bessere Option als die Erhöhung der Grenzwerte. Weitere Details finden Sie unter Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden.
- Wenn einer oder mehrere der aktiven Cluster nicht ausgelastet sind, skalieren Sie Instance-Gruppen oder reduzieren Sie Zielkapazitäten von Instance-Flotten für aktive Cluster.
- Erstellen Sie Cluster mit weniger EC2-Instances oder reduzierter Zielkapazität.

Zu viele Abruffehler

Die Fehlermeldung „Too many fetch-failures (Zu viele Abruffehler)“ oder „Error reading task output (Fehler beim Lesen der Aufgabenausgabe)“ in Schritt- oder Aufgabenversuchsprotokollen gibt an, dass die auszuführende Aufgabe von der Ausgabe einer anderen Aufgabe abhängt. Dies geschieht häufig, wenn eine Reduce-Aufgabe zur Ausführung in die Warteschlange gestellt wird und die Ausgabe einer oder mehrerer Map-Aufgaben erfordert, die jedoch noch nicht verfügbar ist.

Es gibt mehrere Gründe, warum die Ausgabe noch nicht verfügbar ist:

- Die erforderliche Aufgabe befindet sich noch in Bearbeitung. Dies ist oft eine Map-Aufgabe.
- Die Daten sind möglicherweise aufgrund einer schlechten Netzwerkverbindung nicht verfügbar, wenn sie sich auf einer anderen Instance befinden.
- Wenn HDFS verwendet wird, um die Ausgabe abzurufen, kann ein Problem mit HDFS vorliegen.

Der häufigste Grund ist, dass sich die vorherige Aufgabe noch in Bearbeitung befindet. Dies ist besonders wahrscheinlich, wenn die Fehler beim ersten Ausführen der Reduce-Aufgaben auftreten. Sie können prüfen, ob dies der Fall ist, indem Sie sich das Syslog-Protokoll für den Cluster-Schritt ansehen, der den Fehler zurückgibt. Wenn das Syslog den Fortschritt beider Map- und Reduce-Aufgaben belegt, weist dies darauf hin, dass die Reduce-Phase gestartet wurde und einige Map-Aufgaben noch nicht abgeschlossen sind.

Sehen Sie sich in den Protokollen den Prozentsatz für den Map-Fortschritt an, der auf 100 % ansteigt und dann wieder auf einen niedrigeren Wert zurückfällt. Wenn der Map-Prozentsatz 100 % beträgt, bedeutet das nicht, dass alle Map-Aufgaben abgeschlossen sind. Es bedeutet lediglich, dass Hadoop alle Map-Aufgaben ausführt. Wenn dieser Wert unter 100 % fällt, bedeutet dies, dass eine Map-Aufgabe fehlgeschlagen ist und Hadoop je nach Konfiguration versucht, die Aufgabe neu zu planen. Wenn der Map-Prozentanteil in den Protokollen bei 100 % Prozentsatz bleibt, sehen Sie sich die CloudWatch-Metriken, insbesondere `RunningMapTasks`, an, um zu prüfen, ob sich die Map-Aufgabe noch in Bearbeitung befindet. Sie finden diese Informationen auch mithilfe der Hadoop-Weboberfläche auf dem Master-Knoten.

Wenn dieses Problem auftritt, können Sie verschiedene Schritte versuchen:

- Weisen Sie die Reduce-Phase an, länger zu warten, bis sie startet. Ändern Sie dazu die Konfigurationseinstellung mapred.reduce.slowstart.completed.maps in Hadoop und legen Sie sie auf einen längeren Zeitraum fest. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software.

- Passen Sie die Reducer-Anzahl der gesamten Reducer-Kapazität des Clusters an. Ändern Sie dazu die Konfigurationseinstellung mapred.reduce.tasks für den Auftrag in Hadoop.
- Verwenden Sie einen Kombinationsklassencode zum Minimieren der Anzahl der Ausgaben, die abgerufen werden müssen.
- Stellen Sie sicher, dass keine Probleme mit dem Amazon-EC2-Service bestehen, die die Netzwerkleistung des Clusters beeinträchtigen. Verwenden Sie dazu das Dashboard zum Servicestatus.
- Überprüfen Sie die CPU- und Arbeitsspeicherressourcen für die Instances in Ihrem Cluster, um sicherzustellen, dass Ihre Datenverarbeitung die Ressourcen Ihrer Knoten nicht überlastet. Weitere Informationen finden Sie unter Cluster-Hardware und Netzwerken konfigurieren.
- Prüfen Sie die Version des Amazon Machine Image (AMI), das in Ihrem Amazon-EMR-Cluster verwendet wird. Wenn die Version 2.3.0 bis einschließlich 2.4.4 ist, aktualisieren Sie auf eine neuere Version. AMI-Versionen im angegebenen Bereich verwenden eine Jetty-Version, die ggf. keine Ausgabe aus der Map-Phase liefert. Der Abruf-Fehler tritt auf, wenn die Reducer keine Ausgabe aus der Map-Phase abrufen können.

  Jetty ist ein Open-Source-HTTP-Server, der für die Maschine-zu-Maschine-Kommunikation innerhalb eines Hadoop-Clusters verwendet wird.

Datei konnte nur auf 0 Knoten anstatt auf 1 repliziert werden

Wenn eine Datei in HDFS geschrieben wird, wird sie in mehreren Core-Knoten repliziert. Wenn dieser Fehler angezeigt wird, bedeutet dies, dass der NameNode-Daemon keine verfügbaren DataNode-Instances besitzt, um Daten in HDFS zu schreiben. Mit anderen Worten, es findet keine Block-Replikation statt. Dieser Fehler kann durch eine Reihe von Problemen verursacht werden:

- Das HDFS-Dateisystem hat keinen verfügbaren Speicherplatz. Dies ist die wahrscheinlichste Ursache.
- DataNode-Instances waren möglicherweise nicht verfügbar, als der Auftrag ausgeführt wurde.
- DataNode-Instances können für die Kommunikation mit dem Master-Knoten gesperrt gewesen sein.
- Instances in der Core-Instance-Gruppe sind möglicherweise nicht verfügbar.
- Berechtigungen können fehlen. Der JobTracker-Daemon verfügt möglicherweise nicht über die Berechtigungen zum Erstellen von JobTracker-Informationen.

- Die Einstellung für den reservierten Speicherplatz für eine DataNode-Instance reicht möglicherweise nicht aus. Stellen Sie fest, ob dies der Fall ist, indem Sie die Konfigurationseinstellung dfs.datanode.du.reserved prüfen.

Um zu prüfen, ob dieses Problem durch unzureichenden Speicherplatz in HDFS verursacht wird, sehen Sie sich die `HDFSUtilization`-Metrik in CloudWatch an. Wenn dieser Wert zu hoch ist, können Sie zusätzliche Core-Knoten zum Cluster hinzufügen. Wenn Sie über einen Cluster verfügen, dessen HDFS-Speicherplatz möglicherweise nicht ausreicht, können Sie einen Alarm in CloudWatch festlegen, damit Sie benachrichtigt werden, wenn der Wert `HDFSUtilization` einen bestimmten Punkt überschreitet. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters und Überwachung von Amazon-EMR-Metriken mit CloudWatch.

Wenn das Problem nicht auf unzureichenden Speicherplatz in HDFS zurückzuführen ist, prüfen Sie die DataNode- und NameNode-Protokolle sowie die Netzwerkverbindungen auf andere Probleme, die verhindern könnten, dass HDFS Daten repliziert. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Knoten, die auf der Liste stehen

Die NodeManager-Daemon ist verantwortlich für das Starten und Verwalten von Containern auf Core- und Aufgabenknoten. Die Container werden dem NodeManager-Daemon vom ResourceManager-Daemon zugeordnet, der auf dem Master-Knoten ausgeführt wird. Der ResourceManager überwacht den NodeManager-Knoten über einen Heartbeat.

Es gibt einige Situationen, in denen der ResourceManager-Daemon einen NodeManager-Knoten sperrt und ihn aus dem Pool von Knoten, die zur Verarbeitung von Aufgaben zur Verfügung stehen, entfernt:

- Wenn der NodeManager in den letzten 10 Minuten (600 000 Millisekunden) keinen Heartbeat an den ResourceManager-Daemon gesendet hat. Dieser Zeitraum kann über die Konfigurationseinstellung `yarn.nm.liveness-monitor.expiry-interval-ms` festgelegt werden. Weitere Informationen zur Änderung von Yarn-Konfigurationseinstellungen finden Sie unter Anwendungen konfigurieren im Amazon-EMR-Versionshandbuch.
- Der NodeManager prüft den Zustand der Datenträger, die durch `yarn.nodemanager.local-dirs` und `yarn.nodemanager.log-dirs` bestimmt wurden. Die Prüfungen umfassen Berechtigungen und freien Speicherplatz (< 90 %). Wenn ein Datenträger ausfällt, stoppt der NodeManager die Verwendung dieses Datenträgers, meldet aber den Zustand des Knotens weiterhin als fehlerfrei. Wenn mehrere Datenträger die Prüfung nicht bestehen, wird der Knoten als

fehlerhaft an den ResourceManager gemeldet und es werden dem Knoten keine neuen Container zugewiesen

Der Anwendungsmaster kann einen NodeManager-Knoten auch sperren, wenn dieser mehr als drei fehlgeschlagene Aufgaben hat. Sie können hierfür mithilfe des Konfigurationsparameters `mapreduce.job.maxtaskfailures.per.tracker` einen höheren Wert einstellen. Andere Konfigurationseinstellungen, die Sie ändern können, steuern, wie oft versucht wird, eine Aufgabe auszuführen, bevor ein Fehler gemeldet wird: `mapreduce.map.max.attempts` für Map-Aufgaben und `mapreduce.reduce.maxattempts` für Reduce-Aufgaben. Weitere Informationen zur Änderung von Konfigurationseinstellungen finden Sie unter Anwendungen konfigurieren im Amazon-EMR-Versionshandbuch.

Drosselungsfehler

Die Fehler „Von *Amazon EC2* beim Starten des Clusters gedrosselt“ und „Instances konnten aufgrund der Drosselung von *Amazon EC2* nicht bereitgestellt werden“ treten auf, wenn Amazon EMR eine Anfrage nicht abschließen kann, weil ein anderer Service die Aktivität gedrosselt hat. Amazon EC2 ist die häufigste Ursache für Drosselungsfehler, aber auch andere Services können die Ursache für Drosselungsfehler sein. AWS-Service-Limits gelten für jede Region, um die Leistung zu verbessern. Ein Drosselungsfehler weist darauf hin, dass Sie das Service-Limit für Ihr Konto in dieser Region überschritten haben.

Mögliche Ursachen

Die häufigste Quelle von Amazon-EC2-Drosselungsfehlern besteht darin, dass durch das Starten einer großen Anzahl von Cluster-Instances das Service-Limit für EC2-Instances überschritten wird. Cluster-Instances können aus den folgenden Gründen gestartet werden:

- Es werden neue Cluster erstellt.
- Die Clustergröße wird manuell angepasst. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters.
- Instance-Gruppen in einem Cluster fügen Instances als Ergebnis einer Auto Scaling-Regel hinzu ("Scale-Out" oder horizontales Skalieren). Weitere Informationen finden Sie unter Grundlegendes zu Auto-Scaling-Regeln.
- Instance-Flotten in einem Cluster fügen Instances hinzu, um eine erhöhte Zielkapazität zu erreichen. Weitere Informationen finden Sie unter Instance-Flotten konfigurieren.

Es ist auch möglich, dass durch die Häufigkeit oder den Typ der API-Anforderung an Amazon EC2 Drosselungsfehler verursacht werden. Weitere Informationen darüber, wie Amazon EC2 API-Anforderungen drosselt, finden Sie unter Anforderungsrate der Abfrage-API in der Amazon-EC2-API-Referenz.

Lösungen

Erwägen Sie die folgenden Lösungen:

- Folgen Sie den Anweisungen unter AWS-Service-Quotas in Allgemeine Amazon Web Services-Referenz, um eine Erhöhung des Servicelimits zu beantragen. Für einige APIs ist die Einrichtung eines CloudWatch-Ereignisses möglicherweise eine bessere Option als die Erhöhung der Grenzwerte. Weitere Details finden Sie unter Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden.
- Wenn Sie Cluster haben, die nach demselben Zeitplan gestartet werden, z. B. zu Beginn der Stunde, sollten Sie gestaffelte Startzeiten in Betracht ziehen.
- Wenn die Nachfragespitzen für Ihre Cluster zu groß angelegt sind und Sie Ihre Instance-Kapazitäten in regelmäßigen Abständen angeben, sollten Sie Ihre Instance mit Auto Scaling nach Bedarf hinzufügen und entfernen. Auf diese Weise werden Instances effizienter genutzt und können je nach Bedarfsprofil zu jedem beliebigen Zeitpunkt für ein Konto weniger Instances angefordert werden. Weitere Informationen finden Sie unter Verwenden der automatischen Skalierung mit einer benutzerdefinierten Richtlinie für Instance-Gruppen .

Instance-Typ nicht unterstützt

Wenn das Erstellen eines Clusters mit der Fehlermeldung „The requested instance type *`InstanceType`* is not supported in the requested Availability Zone (Der angeforderte Instance-Typ InstanceType wird in der angeforderten Availability Zone nicht unterstützt)" fehlschlägt, bedeutet dies, dass Sie den Cluster erstellt und einen Instance-Typ für eine oder mehrere Instance-Gruppen angegeben haben, der von Amazon EMR in der Region und Availability Zone, in der der Cluster erstellt wurde, nicht unterstützt wird. unterstützt einen Instance-Typ nicht unbedingt in jeder Region einer Availability Zone. Amazon EMR unterstützt möglicherweise einen Instance-Typ in einer Availability Zone innerhalb einer Region und nicht in einer anderen. Die Availability Zone innerhalb der Region ist von dem von Ihnen für einen Cluster ausgewählten Subnetz abhängig.

Lösung

So bestimmen Sie verfügbare Instance-Typen in einer Availability Zone mithilfe der AWS CLI

- Verwenden Sie den Befehl `ec2 run-instances` mit der Option `--dry-run`. Ersetzen Sie in dem folgenden Beispiel *`m5.xlarge`* durch den Instance-Typ, den Sie verwenden möchten, *`ami-035be7bafff33b6b6`* durch die diesem Instance-Typ zugeordnete AMI und *`subnetz-12ab3c45`* durch ein Subnetz in der Availability Zone, das Sie abfragen möchten.

  ```
  aws ec2 run-instances --instance-type m5.xlarge --dry-run --image-
  id ami-035be7bafff33b6b6 --subnet-id subnet-12ab3c45
  ```

  Anweisungen zum Suchen einer AMI-ID finden Sie unter Suchen eines Linux-AMI. Um eine Subnetz-ID zu finden, können Sie den Befehl describe-subnets verwenden.

Weitere Informationen darüber, wie Sie verfügbare Instance-Typen ermitteln können, finden Sie unter Suchen eines Amazon-EC2-Instance-Typs.

Nachdem Sie die verfügbaren Instance-Typen bestimmt haben, können Sie beliebige der folgenden Aktionen ausführen:

- Erstellen Sie den Cluster in der gleichen Region und im gleichen EC2-Subnetz und wählen Sie einen anderen Instance-Typ mit ähnlichen Funktionen wie Ihre erste Wahl aus. Eine Liste mit unterstützten Instance-Typen finden Sie unter Unterstützte Instance-Typen. Informationen zum Vergleichen der Funktionen der EC2-Instance-Typen finden Sie unter Amazon-EC2-Instance-Typen.
- Wählen Sie ein Subnetz für den Cluster in einer Availability Zone aus, in der der Instance-Typ verfügbar ist und von Amazon EMR unterstützt wird.

EC2 hat keine Kapazität mehr

Der Fehler „EC2 hat keine Kapazität für *`InstanceType`*“ tritt auf, wenn Sie versuchen, einen Cluster zu erstellen oder Instances zu einem Cluster in einer Availability Zone hinzuzufügen, die nicht mehr über den angegebenen EC2-Instance-Typ verfügt. Die Availability Zone ist von dem von Ihnen für einen Cluster ausgewählten Subnetz abhängig.

Um einen Cluster zu erstellen, führen Sie einen der folgenden Schritte aus:

- Geben Sie einen anderen Instance-Typ mit ähnlichen Funktionen an
- Erstellen des Clusters in einer anderen Region
- Wählen Sie ein Subnetz in einer Availability Zone aus, in dem der gewünschte Instance-Typ möglicherweise verfügbar ist.

Führen Sie einen der folgenden Schritte aus, um Instances zu einem laufenden Cluster hinzuzufügen:

- Ändern Sie Instance-Gruppenkonfigurationen oder Instance-Flottenkonfigurationen so bearbeiten, dass verfügbare Instance-Typen mit ähnlichen Funktionen hinzugefügt werden. Eine Liste mit unterstützten Instance-Typen finden Sie unter Unterstützte Instance-Typen. Informationen zum Vergleichen der Funktionen der EC2-Instance-Typen finden Sie unter Amazon-EC2-Instance-Typen.
- Beenden Sie den Cluster und erstellen Sie ihn in einer Region und Verfügbarkeitszone neu, in der der Instancetyp verfügbar ist.

Fehler bei der Ein- und Ausgabe

Die folgenden Fehler treten in Cluster-Ein- und Ausgabeoperationen häufig auf.

Themen

- Hat Ihr Pfad zu Amazon Simple Storage Service (Amazon S3) mindestens drei Schrägstriche?
- Versuchen Sie Eingabeverzeichnisse rekursiv zu durchlaufen?
- Ist Ihr Ausgabeverzeichnis bereits vorhanden?
- Versuche Sie, eine Ressource mit einer HTTP-URL anzugeben?
- Verweisen Sie mit einem ungültigen Namensformat auf einen Amazon-S3-Bucket?
- Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3?

Hat Ihr Pfad zu Amazon Simple Storage Service (Amazon S3) mindestens drei Schrägstriche?

Wenn Sie einen Amazon-S3-Bucket angeben, müssen Sie einen Abschlussschrägstrich am Ende der URL anfügen. Statt auf einen Bucket mit „s3n://*DOC-EXAMPLE-BUCKET1*“ zu verweisen, sollten Sie „s3n://*DOC-EXAMPLE-BUCKET1*/“ verwenden. Andernfalls tritt in Ihrem Hadoop-Cluster in den meisten Fällen ein Fehler auf.

Versuchen Sie Eingabeverzeichnisse rekursiv zu durchlaufen?

Hadoop durchsucht Eingabeverzeichnisse nicht rekursiv nach Dateien. Wenn Sie über eine Verzeichnisstruktur wie beispielsweise /corpus/01/01.txt, /corpus/01/02.txt, /corpus/02/01.txt usw. verfügen und /corpus/ als Eingabeparameter für Ihren Cluster angeben, findet Hadoop keine Eingabedateien, da das Verzeichnis /corpus/ leer ist und Hadoop den Inhalt der Unterverzeichnisse nicht überprüft. Entsprechend überprüft Hadoop die Unterverzeichnisse von Amazon-S3-Buckets nicht rekursiv.

Die Eingabedateien müssen sich direkt in dem Eingabeverzeichnis oder dem Amazon-S3-Bucket, das bzw. den Sie angeben, befinden und nicht in Unterverzeichnissen.

Ist Ihr Ausgabeverzeichnis bereits vorhanden?

Wenn Sie einen Ausgabepfad angeben, der bereits vorhanden ist, schlägt der Hadoop-Cluster in den meisten Fällen fehl. Das bedeutet, dass Sie, wenn Sie einen Cluster ausführen und dann diesen Vorgang mit denselben Parametern wiederholen, der erste Lauf und kein weiterer funktioniert. Nach dem ersten Lauf ist der Ausgabepfad vorhanden, was dazu führt, dass alle nachfolgenden Läufe fehlschlagen.

Versuche Sie, eine Ressource mit einer HTTP-URL anzugeben?

Hadoop akzeptiert keine Ressourcenspeicherorte, die mit dem Präfix http:// angegeben werden. Sie können auf eine Ressource nicht mit einer HTTP-URL verweisen. Beispiel: Das Übergeben von http://mysite/myjar.jar als JAR-Parameter bewirkt, dass der Cluster fehlschlägt.

Verweisen Sie mit einem ungültigen Namensformat auf einen Amazon-S3-Bucket?

Wenn Sie versuchen, einen Bucket-Namen wie „*DOC-EXAMPLE-BUCKET1*.1“ in Amazon EMR zu verwenden, schlägt Ihr Cluster fehl, da Bucket-Namen in Amazon EMR gültige RFC 2396-Hostnamen sein müssen. Der Name darf nicht mit einer Zahl enden. Um die Anforderungen von Hadoop zu erfüllen, dürfen Namen von mit Amazon EMR verwendeten Amazon-S3-Buckets darüber hinaus nur Kleinbuchstaben, Zahlen, Punkte (.) und Bindestriche (-) enthalten. Weitere Informationen zum Formatieren von Amazon-S3-Bucket-Namen finden Sie unter Bucket-Einschränkungen und -Limits im Benutzerhandbuch für Amazon Simple Storage Service.

Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3?

Amazon S3 ist die beliebteste Ein- und Ausgabequelle für Amazon EMR. Ein häufiger Fehler besteht darin, Amazon S3 so zu behandeln wie ein typisches Dateisystem. Es gibt Unterschiede zwischen

Amazon S3 und einem Dateisystem, die Sie berücksichtigen müssen, wenn Sie Ihren Cluster ausführen.

- Wenn ein interner Fehler in Amazon S3 auftritt, muss Ihre Anwendung diesen problemlos behandeln und die Operation wiederholen.
- Wenn Aufrufe in Amazon S3 zu lange dauern, muss Ihre Anwendung die Häufigkeit der Amazon-S3-Aufrufe ggf. reduzieren.
- Das Auflisten aller Objekte in einem Amazon-S3-Bucket ist ein teurer Aufruf. Ihre Anwendung sollte die Anzahl solcher Aufrufe minimieren.

Es gibt mehrere Möglichkeiten, wie Sie die Interaktion Ihres Cluster mit Amazon S3 verbessern können.

- Starten Sie Ihren Cluster mit der neuesten Version von Amazon EMR.
- Verwenden Sie S3DistCp zum Verschieben von Objekten in und aus Amazon S3. S3DistCp implementiert Fehlerbehandlung, Wiederholungen und Backoffs, um die Anforderungen von Amazon S3 zu erfüllen. Weitere Informationen finden Sie unter Verteiltes Kopieren mithilfe von S3DistCp.
- Entwickeln Sie Ihre Anwendung mit letztendlicher Datenkonsistenz im Blick. Verwenden Sie HDFS für das Zwischenspeichern von Daten, während der Cluster ausgeführt wird, und Amazon S3 nur für die Eingabe der Ausgangsdaten und für die Ausgabe der Endergebnisse.
- Wenn Ihre Cluster einen Commit für mindestens 200 Transaktionen pro Sekunde in Amazon S3 contact supportdurchführen, wenden Sie sich an den Support, um Ihren Bucket auf größere Transaktionen pro Sekunde vorzubereiten. Ziehen Sie dazu die unter Tipps und Tricks zur Leistung von Amazon S3 beschriebenen Strategien in Erwägung.
- Legen Sie die Hadoop-Konfigurationseinstellung "io.file.buffer.size" auf "65536" fest. Diese bewirkt, dass Hadoop weniger Zeit damit verbringt, Amazon-S3-Objekte zu durchsuchen.
- Überlegen Sie sich, ob Sie dasie Speculative-Execution-Feature in Hadoop deaktivieren, wenn Ihr Cluster Probleme mit der gleichzeitigen Ausführung von Amazon S3 hat. Diese Vorgehensweise ist auch bei der Problembehandlung eines langsamen Clusters nützlich. Sie tun dies, indem Sie die `mapreduce.map.speculative`- und die `mapreduce.reduce.speculative`-Eigenschaften auf `false` festlegen. Wenn Sie einen Cluster starten, können Sie diese Werte mithilfe der `mapred-env`-Konfigurationsklassifizierung festlegen. Weitere Informationen finden Sie unter Konfigurieren von Anwendungen in den Amazon EMR-Versionshinweisen.

- Wenn Sie einen Hive-Cluster ausführen, finden Sie weitere Informationen unter Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3 in Hive?.

Weitere Informationen finden Sie unter Bewährte Methoden für Amazon-S3-Fehler im Benutzerhandbuch von Amazon Simple Storage Service.

Berechtigungsfehler

Die folgenden Fehler treten häufig im Zusammenhang mit Berechtigungen oder Anmeldeinformationen auf.

Themen

- Haben Sie für SSH die korrekten Anmeldeinformationen angegeben?
- Haben Sie bei der Verwendung von IAM die korrekten Amazon-EC2-Richtlinien festgelegt?

Haben Sie für SSH die korrekten Anmeldeinformationen angegeben?

Wenn Sie keine SSH-Verbindung zum Master-Knoten herstellen können, gibt es höchstwahrscheinlich ein Problem mit Ihren Anmeldeinformationen.

Prüfen Sie zunächst, ob die PEM-Datei mit dem SSH-Schlüssel über die entsprechenden Berechtigungen verfügt. Verwenden Sie chmod, um die Berechtigungen für Ihre .PEM-Datei zu ändern. Im folgenden Beispiel würden Sie mykey.pem durch den Namen Ihre eigenen PEM-Datei ersetzen.

```
chmod og-rwx mykey.pem
```

Die zweite Fehlerquelle besteht darin, dass Sie nicht das Schlüsselpaar verwenden, das Sie beim Erstellen des Clusters angegeben haben. Dies passiert schnell, falls Sie mehrere Schlüsselpaare erstellt haben. Prüfen Sie die Cluster-Details in der Amazon-EMR-Konsole (oder verwenden Sie die Option `--describe` in der CLI). Stellen Sie fest, ob der Name des Schlüsselpaares mit dem bei der Erstellung des Clusters angegebenen übereinstimmt.

Nachdem Sie überprüft haben, ob Sie das richtige Schlüsselpaar und die korrekten Berechtigungen für die PEM-Datei verwendet haben, können Sie den folgenden Befehl nutzen, um eine SSH-Verbindung mit dem Hauptknoten herzustellen. Ersetzen Sie mykey.pem durch den Namen

Ihrer PEM-Datei und `hadoop@ec2-01-001-001-1.compute-1.amazonaws.com` durch den öffentlichen DNS-Namen des Hauptknotens (über die Option `--describe` in der CLI und über die Amazon-EMR-Konsole abrufbar).

> **Important**
>
> Sie müssen den Anmeldenamen `hadoop` verwenden, wenn Sie eine Verbindung mit dem Amazon-EMR-Cluster-Knoten herstellen. Andernfalls kann eine Fehlermeldung wie `Server refused our key` angezeigt werden.

```
ssh -i mykey.pem hadoop@ec2-01-001-001-1.compute-1.amazonaws.com
```

Weitere Informationen finden Sie unter Mit dem Primärknoten über SSH verbinden.

Haben Sie bei der Verwendung von IAM die korrekten Amazon-EC2-Richtlinien festgelegt?

Da Amazon EMR-EC2-Instances als Knoten verwendet, muss ein Benutzer von Amazon EMR auch bestimmte Amazon-EC2-Richtlinien festgelegt haben, damit Amazon EMR diese Instances im Namen des Benutzers verwalten kann. Wenn Sie nicht über die erforderlichen Berechtigungen verfügen, gibt Amazon EMR den folgenden Fehler zurück: „Das Benutzerkonto ist nicht berechtigt, EC2 aufzurufen.“

Weitere Informationen über die zur Ausführung von Amazon EC2 erforderlichen Amazon-EMR-Richtlinien in Ihrem IAM-Konto finden Sie unter Funktionsweise von Amazon EMR mit IAM.

Hive-Cluster-Fehler

Den Grund für einen Hive-Fehler finden Sie in der Regel in der Datei `syslog`, auf die Sie im Bereich Steps (Schritte) zugreifen können. Wenn Sie das Problem nicht ermitteln können, sehen Sie sich die Fehlermeldung für die versuchte Hadoop-Aufgabe an. Erstellen Sie einen Link dahin im Abschnitt Task Attempts (Aufgaben-Versuche).

Die folgenden Fehler treten häufig bei Hive-Clustern auf.

Themen

- Verwenden Sie die neueste Version von Hive?

- Ist im Hive-Skript ein Syntaxfehler aufgetreten?
- Ist ein interaktiv ausgeführter Auftrag fehlgeschlagen?
- Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3 in Hive?

Verwenden Sie die neueste Version von Hive?

Die neueste Version von Hive verfügt über alle aktuellen Patches und Fehlerbehebungen und kann Ihr Problem lösen.

Ist im Hive-Skript ein Syntaxfehler aufgetreten?

Wenn ein Schritt fehlschlägt, sehen Sie sich die Datei `stdout` der Protokolle für den Schritt an, die das Hive-Skript ausgeführt hat. Wenn der Fehler nicht vorhanden ist, sehen Sie sich die Datei `syslog` der Aufgabenprotokolle für die versuchte Aufgabe an, die fehlgeschlagen ist. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Ist ein interaktiv ausgeführter Auftrag fehlgeschlagen?

Wenn Sie Hive interaktiv auf dem Master-Knoten ausführen und der Cluster fehlschlägt, sehen Sie sich die Einträge `syslog` im Aufgabenprotokoll für die fehlgeschlagene Aufgabe an. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3 in Hive?

Falls Sie Probleme mit dem Zugriff auf Daten in Amazon S3 haben, überprüfen Sie zuerst die möglichen Ursachen, die in Haben Sie Probleme beim Laden von Daten in oder aus Amazon S3? aufgeführt sind. Wenn keines dieser Probleme die Ursache ist, ziehen Sie die folgenden, für Hive spezifischen Optionen in Betracht.

- Stellen Sie sicher, dass Sie die neueste Version von Hive verwenden, die über alle aktuellen Patches und Fehlerbehebungen verfügt, die Ihr Problem lösen können. Weitere Informationen finden Sie unter Apache Hive.
- Wenn Sie `INSERT OVERWRITE` verwenden, müssen Sie die Inhalte des Amazon-S3-Buckets oder -Ordners auflisten. Dies ist eine teure Operation. Wenn möglich, optimieren Sie den Pfad manuell die vorhandenen Objekte von Hive auflisten und löschen zu lassen.
- Wenn Sie ältere Versionen als Amazon EMR 5.0 verwenden, können Sie den folgenden Befehl in HiveQL ausführen, um die Ergebnisse einer Amazon-S3-Auflistungsoperation vorab lokal auf dem Cluster zwischenzuspeichern:

```
set hive.optimize.s3.query=true;
```

- Verwenden Sie statische Partitionen, wenn möglich.
- In einigen Versionen von Hive und Amazon EMR ist es möglich, dass mit ALTER TABLES ein Fehler auftritt, da die Tabelle an einem anderen Ort gespeichert ist, als von Hive erwartet wird. Die Lösung ist, Folgendes in `/home/hadoop/conf/core-site.xml` hinzuzufügen oder zu aktualisieren:

```
<property>
    <name>fs.s3n.endpoint</name>
    <value>s3.amazonaws.com</value>
</property>
```

VPC-Fehler

Die folgenden Fehler treten häufig bei der VPC-Konfiguration in Amazon EMR auf.

Themen

- Ungültige Subnetzkonfiguration
- Fehlende DHCP-Optionsliste
- Berechtigungsfehler
- Fehler, die zu START_FAILED führen
- Cluster Terminated with errors und NameNode können nicht gestartet werden

Ungültige Subnetzkonfiguration

Auf der Seite Cluster Details (Cluster-Details) im Feld Status sehen Sie eine Fehlermeldung wie folgende:

`The subnet configuration was invalid: Cannot find route to InternetGateway in main RouteTable` *`rtb-id`* `for vpc` *`vpc-id`*.

Um dieses Problem zu lösen, müssen Sie ein Internet-Gateway erstellen und Ihre VPC anfügen. Weitere Informationen finden Sie unter Hinzufügen eines Internet-Gateways zu Ihrer VPC.

Alternativ stellen Sie sicher, dass Sie Ihre VPC mit Enable DNS resolution (DNS-Auflösung aktivieren) und Enable DNS hostname support (DNS-Hostnamen-Unterstützung aktivieren) aktiviert konfiguriert haben. Weitere Informationen finden Sie unter Verwenden von DNS in Ihrer VPC.

Fehlende DHCP-Optionsliste

Sie sehen einen Schrittfehler im Cluster-Systemprotokoll (syslog) mit einer Fehlermeldung ähnlich der folgenden:

```
ERROR org.apache.hadoop.security.UserGroupInformation
(main): PriviledgedActionException as:hadoop (auth:SIMPLE)
cause:java.io.IOException:
org.apache.hadoop.yarn.exceptions.ApplicationNotFoundException: Application
with id 'application_id' doesn't exist in RM.
```

oder

```
ERROR org.apache.hadoop.streaming.StreamJob (main): Error Launching job :
org.apache.hadoop.yarn.exceptions.ApplicationNotFoundException: Application
with id 'application_id' doesn't exist in RM.
```

Um dieses Problem zu lösen, müssen Sie eine VPC mit einer DHCP-Optionsliste konfigurieren, deren Parameter auf die folgenden Werte festgelegt sind:

> **Note**
>
> Wenn Sie die Region AWS GovCloud (US-West) verwenden, legen Sie für domain-name **`us-gov-west-1.compute.internal`** anstelle des im folgenden Beispiel verwendeten Werts fest.

- domain-name = **`ec2.internal`**

  Verwenden Sie **`ec2.internal`**, wenn Ihre Region USA Ost (Nord-Virginia) ist. Für andere Regionen verwenden Sie *`region-name`***`.compute.internal`**. Verwenden Sie zum Beispiel in us-west-2 domain-name=**`us-west-2.compute.internal`**.
- domain-name-servers = **`AmazonProvidedDNS`**

Weitere Informationen finden Sie unter DHCP-Options-Sets.

Berechtigungsfehler

Ein Fehler im `stderr`-Protokoll für einen Schritt gibt an, dass eine Amazon-S3-Ressource nicht über die entsprechenden Berechtigungen verfügt. Dies ist ein Fehler 403, der wie folgt aussieht:

```
Exception in thread "main" com.amazonaws.services.s3.model.AmazonS3Exception: Access
 Denied (Service: Amazon S3; Status Code: 403; Error Code: AccessDenied; Request
 ID: REQUEST_ID
```

Wenn die ActionOnFailure auf `TERMINATE_JOB_FLOW` festgelegt ist, wird der Cluster mit dem Status `SHUTDOWN_COMPLETED_WITH_ERRORS` beendet.

Möglichkeiten, um dieses Problem zu beheben, sind beispielsweise:

- Wenn Sie eine Amazon-S3-Bucket-Richtlinie in einer VPC verwenden, stellen Sie sicher, dass der Zugriff auf alle Buckets ermöglicht wird. Erstellen Sie dazu einen VPC-Endpunkt und wählen Sie beim Erstellen des Endpunkts Alle zulassen unter der Option „Richtlinie“ aus.
- Stellen Sie sicher, dass alle Richtlinien im Zusammenhang mit S3-Ressourcen die VPC umfassen, in der Sie den Cluster starten.
- Führen Sie den folgenden Befehl über Ihren Cluster aus, um zu überprüfen, ob Sie auf den Bucket zugreifen können.

  ```
  hadoop fs -copyToLocal s3://path-to-bucket /tmp/
  ```

- Sie können spezifischere Debugging-Informationen abrufen, indem Sie den Parameter `log4j.logger.org.apache.http.wire` in der Datei `DEBUG`-Datei im Cluster auf `/home/hadoop/conf/log4j.properties` festlegen. Sie können die `stderr`-Protokolldatei prüfen, nachdem Sie versucht haben, über den Cluster auf den Bucket zuzugreifen. Die Protokolldatei enthält detaillierte Informationen:

  ```
  Access denied for getting the prefix for bucket - us-west-2.elasticmapreduce with
   path samples/wordcount/input/
  15/03/25 23:46:20 DEBUG http.wire: >> "GET /?prefix=samples%2Fwordcount%2Finput
  %2F&delimiter=%2F&max-keys=1 HTTP/1.1[\r][\n]"
  15/03/25 23:46:20 DEBUG http.wire: >> "Host: us-
  west-2.elasticmapreduce.s3.amazonaws.com[\r][\n]"
  ```

Fehler, die zu **START_FAILED** führen

Vor AMI 3.7.0 ordnete Amazon EMR VPCs, in denen ein Hostname für Amazon-EMR-Instances angegeben wird, die internen Hostnamen des Subnetzes den benutzerdefinierten Domainadressen wie folgt zu: `ip-`*X.X.X.X.customdomain.com*`.tld`. Wenn beispielsweise der Hostname `ip-10.0.0.10` lautet und die Domainnamenoption der VPC auf customdomain.com festgelegt ist, wird von Amazon EMR der Hostname `ip-10.0.1.0.customdomain.com` zugeordnet. Ein Eintrag wird in `/etc/hosts` hinzugefügt, um den Hostnamen in 10.0.0.10 aufzulösen. Dieses Verhalten wird ab AMI 3.7.0 geändert. Jetzt erkennt Amazon EMR die DHCP-Konfiguration der VPC vollständig an. Bislang konnten Kunden eine Zuweisung des Hostnamens auch mit einer Bootstrap-Aktion angeben.

Wenn Sie dieses Verhalten beibehalten möchten, müssen Sie die Einrichtung der DNS- und Weiterleitungsauflösung angeben, die Sie für die benutzerdefinierte Domain benötigen.

Cluster **Terminated with errors** und NameNode können nicht gestartet werden

Beim Starten eines EMR-Clusters in einer VPC, die einen benutzerdefinierten DNS-Domainnamen verwendet, tritt bei Ihrem Cluster möglicherweise ein Fehler mit der folgende Fehlermeldung in der Konsole auf:

```
Terminated with errors  On the master instance(instance-id), bootstrap action 1
 returned a  non-zero return code
```

Der Fehler resultiert daraus, dass der NameNode nicht starten konnte. Dies führt zu dem folgenden Fehler in den NameNode-Protokollen, deren Amazon-S3-URI folgendes Format hat: `s3://`*mybucket*`/`*logs*`/`*cluster-id*`/daemons/`*master instance-id*`/hadoop-hadoop-namenode-`*master node hostname*`.log.gz`:

```
2015-07-23 20:17:06,266 WARN
      org.apache.hadoop.hdfs.server.namenode.FSNamesystem (main): Encountered
 exception
      loading fsimage  java.io.IOException: NameNode is not formatted.
      at

 org.apache.hadoop.hdfs.server.namenode.FSImage.recoverTransitionRead(FSImage.java:212)
          at

 org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFSImage(FSNamesystem.java:1020)
          at

 org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFromDisk(FSNamesystem.java:739)
```

```
          at
     org.apache.hadoop.hdfs.server.namenode.NameNode.loadNamesystem(NameNode.java:537)
          at
     org.apache.hadoop.hdfs.server.namenode.NameNode.initialize(NameNode.java:596)

     at  org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.java:765)
          at
     org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.java:749)
     at

org.apache.hadoop.hdfs.server.namenode.NameNode.createNameNode(NameNode.java:1441)
          at
     org.apache.hadoop.hdfs.server.namenode.NameNode.main(NameNode.java:1507)
```

Der Grund hierfür ist ein potenzielles Problem, bei dem eine EC2 Instance mehrere Gruppen von vollständig qualifizierten Domainnamen beim Starten von EMR-Clustern in einer VPC besitzen kann, die sowohl einen von AWS bereitgestellten DNS-Server als auch einen benutzerdefinierten vom Benutzer bereitgestellten DNS-Server verwendet. Wenn der vom Benutzer bereitgestellte DNS-Server keine Zeigerdatensätze (PTR) für die A-Datensätze bereitstellt, die zum Angeben von Knoten in einem EMR-Cluster dienen, können die so konfigurierten Cluster nicht starten. Die Lösung besteht darin, einen PTR-Datensatz für jeden A-Datensatz hinzuzufügen, der erstellt wird, wenn eine EC2 Instance in einem der Subnetze der VPC gestartet wird.

Streaming-Cluster-Fehler

Sie können in der Regel die Ursache für einen Streaming-Fehler in einer `syslog`-Datei finden. Erstellen Sie einen Link dahin im Abschnitt Steps (Schritte).

Die folgenden Fehler treten häufig bei Streaming-Clustern auf.

Themen

- Werden Daten an den Mapper im falschen Format gesendet?
- Gibt es eine Zeitüberschreitung bei der Skriptausführung?
- Werden ungültige Streaming-Argumente übergeben?
- Wurde Ihr Skript mit einem Fehler beendet?

Werden Daten an den Mapper im falschen Format gesendet?

Suchen Sie in der `syslog`-Datei nach einer Fehlermeldung über einen fehlgeschlagenen Aufgabenversuch in den Protokolldateien der Aufgabenversuche, um dies zu überprüfen. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Gibt es eine Zeitüberschreitung bei der Skriptausführung?

Die standardmäßige Zeitbeschränkung für ein Mapper- oder Reducer-Skript beträgt 600 Sekunden. Wenn Ihr Skript mehr Zeit benötigt, schlägt der Aufgabenversuch fehl. Suchen Sie in der `syslog`-Datei nach einem fehlgeschlagenen Aufgabenversuch in den Protokolldateien der Aufgabenversuche, um dies zu überprüfen. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Sie können die Zeitbeschränkung ändern, indem Sie einen neuen Wert für die Konfigurationseinstellung `mapred.task.timeout` festlegen. Diese Einstellung gibt die Anzahl von Millisekunden an, nach der Amazon EMR eine Aufgabe beendet, die keine Eingabe gelesen, Ausgabe geschrieben oder ihre Status-Zeichenfolge nicht aktualisiert hat. Sie können diesen Wert aktualisieren, indem Sie ein zusätzliches Streaming-Argument `-jobconf mapred.task.timeout=800000` übergeben.

Werden ungültige Streaming-Argumente übergeben?

Hadoop-Streaming unterstützt nur die folgenden Argumente. Wenn Sie andere als die unten aufgeführten Argumente übergeben, schlägt der Cluster fehl.

```
-blockAutoGenerateCacheFiles
-cacheArchive
-cacheFile
-cmdenv
-combiner
-debug
-input
-inputformat
-inputreader
-jobconf
-mapper
-numReduceTasks
-output
-outputformat
```

```
-partitioner
-reducer
-verbose
```

Darüber hinaus erkennt Hadoop-Streaming nur in Java-Syntax übergebene Argumente, also mit einem vorangestellten einzelnen Bindestrich. Wenn Argumente mit vorangestelltem doppelten Bindestrich übergeben werden, schlägt der Cluster fehl.

Wurde Ihr Skript mit einem Fehler beendet?

Wenn Ihr Mapper- oder Reducer-Skript mit einem Fehler beendet wird, können Sie den Fehler in der `stderr`-Datei des fehlgeschlagenen Aufgabenversuchs in den Protokolldateien der Aufgabenversuche ermitteln. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Benutzerdefinierte JAR-Cluster-Fehler

Die folgenden Fehler treten häufig bei benutzerdefinierten JAR-Clustern auf.

Themen

- Löst Ihr JAR-Cluster vor dem Erstellen eines Auftrags eine Ausnahme aus?
- Tritt auf Ihrem JAR-Cluster ein Fehler in einer Map-Aufgabe auf?

Löst Ihr JAR-Cluster vor dem Erstellen eines Auftrags eine Ausnahme aus?

Wenn das Hauptprogramm des benutzerdefinierten JAR-Clusters einen Ausnahmefehler beim Erstellen des Hadoop-Auftrags ausgibt, sehen Sie sich am besten die Datei `syslog` der Schrittprotokolle an. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Tritt auf Ihrem JAR-Cluster ein Fehler in einer Map-Aufgabe auf?

Wenn Ihr benutzerdefinierte JAR-Cluster und Mapper einen Ausnahmefehler beim Verarbeiten von Eingabedaten ausgibt, sehen Sie sich am besten die Datei `syslog` der Aufgabenversuchsprotokolle an. Weitere Informationen finden Sie unter Anzeige von -Protokolldateien.

Fehler in AWS GovCloud (USA-West)

Die Region AWS GovCloud (US-West) unterscheidet sich von anderen Regionen in den Bereichen Sicherheit, Konfiguration und Standardeinstellungen. Verwenden Sie daher die folgende Checkliste

zur Behebung von Amazon-EMR-Fehlern, die speziell in der Region AWS GovCloud (US-West) auftreten, bevor Sie allgemeinen Hinweisen zur Behebung von Problemen folgen.

- Überprüfen Sie, ob Ihre IAM-Rollen ordnungsgemäß konfiguriert sind. Weitere Informationen finden Sie unter Konfigurieren Sie IAM-Servicerollen für Amazon EMR-Berechtigungen für AWS Services und Ressourcen.
- Stellen Sie sicher, dass Ihre VPC-Konfiguration den DNS-Auflösungs-/Hostnamensupport, das Internet-Gateway und die DHCP-Optionslisten-Parameter ordnungsgemäß konfiguriert hat. Weitere Informationen finden Sie unter VPC-Fehler.

Wenn diese Schritte das Problem nicht lösen, fahren Sie mit den Schritten zur Problembehebung allgemeiner Amazon-EMR-Fehler fort. Weitere Informationen finden Sie unter Häufige Fehler in Amazon EMR.

Finden Sie einen fehlenden Cluster

Wenn Ihr Cluster in der Konsolenliste oder `ListClusters`-API fehlt, überprüfen Sie Folgendes:

- Vergewissern Sie sich, dass das Alter des Clusters ab dem Zeitpunkt der Fertigstellung weniger als zwei Monate beträgt. Amazon EMR bewahrt Metadateninformationen für abgeschlossene Cluster zwei Monate lang kostenlos auf. Sie können abgeschlossene Cluster nicht aus der Konsole löschen. Stattdessen löscht Amazon EMR abgeschlossene Cluster automatisch nach zwei Monaten.
- Bestätigen Sie, dass Sie über Rollenberechtigungen zum Anzeigen des Clusters verfügen.
- Vergewissern Sie sich, dass Sie dasselbe AWS-Region anzeigen, in dem sich der Cluster befindet.

Fehlerbehebung für einen ausgefallenen Cluster

In diesem Abschnitt werden Sie durch den Vorgang zur Fehlerbehebung eines Cluster geführt, der ausgefallen ist. Das bedeutet, dass der Cluster mit einem Fehlercode beendet wurde.

> **Note**
>
> Wenn ein EMR-Cluster mit einem Fehler beendet wird, geben die APIs `DescribeCluster` und `ListClusters` einen Fehlercode und eine Fehlermeldung zurück. Bei einigen

Clusterfehlern kann Ihnen das `ErrorDetail`-Datenarray bei der Behebung des Fehlers helfen. Weitere Informationen finden Sie unter Fehlercodes mit ErrorDetail-Informationen.

Wenn Ihr Cluster ausgeführt wird, aber lange braucht, bis Ergebnisse zurückgegeben werden, finden Sie unter Fehlerbehebung für einen langsamen Cluster.

Themen

- Schritt 1: Daten über das Problem sammeln
- Schritt 2: Die Umgebung prüfen
- Schritt 3: Die letzte Statusänderung überprüfen
- Schritt 4: Die Protokolldateien überprüfen
- Schritt 5: Den Cluster Schritt für Schritt testen

Schritt 1: Daten über das Problem sammeln

Der erste Schritt bei der Fehlerbehebung bei einem Cluster besteht darin, Informationen darüber zu sammeln, was schief gelaufen ist, sowie über den aktuellen Status und die Konfiguration des Clusters. Diese Informationen werden in den folgenden Schritten verwendet, um mögliche Ursachen des Problems zu bestätigen oder auszuschließen.

Definieren des Problems

Eine klare Definition des Problems ist der erste Ausgangspunkt. Einige Fragen, die Sie sich stellen sollten:

- Was habe ich erwartet? Was ist stattdessen passiert?
- Wann ist dieses Problem zum ersten Mal aufgetreten? Wie oft ist es seitdem passiert?
- Hat sich etwas an der Konfiguration oder Ausführung meines Clusters geändert?

Cluster-Details

Die folgenden Clusterdetails sind hilfreich, um Probleme aufzuspüren. Weitere Informationen zum Sammeln dieser Informationen finden Sie unter Cluster-Status und -Details anzeigen.

- Die Cluster-ID. (Wird auch als Job-Flow-Identifier bezeichnet.)

- AWS-Region und Availability Zone, in der der Cluster gestartet werden soll.
- Status des Clusters, einschließlich Details zur letzten Statusänderung.
- Typ und Anzahl der EC2-Instances, die für die Master-, Core- und Aufgabenknoten angegeben wurden.

Schritt 2: Die Umgebung prüfen

Amazon EMR wird als Teil eines Ökosystems von Web-Services und Open-Source-Software betrieben. Faktoren, die sich auf diese Abhängigkeiten auswirken, können die Leistung von Amazon EMR beeinträchtigen.

Themen

- Prüfen auf Service-Ausfälle
- Prüfen auf Nutzungsgrenzen
- Überprüfen der Version
- Prüfen der Amazon-VPC-Subnetzkonfiguration

Prüfen auf Service-Ausfälle

Amazon EMR verwendet intern mehrere Amazon Web Services. Es betreibt virtuelle Server auf Amazon EC2, speichert Daten und Skripts auf Amazon S3 und meldet Metriken an CloudWatch. Ereignisse, die diese Services stören, sind selten – wenn sie jedoch auftreten, können sie zu Problemen in Amazon EMR führen.

Überprüfen Sie die Übersicht zum Servicestatus, bevor Sie fortfahren. Prüfen Sie in der Region, in der Sie Ihren Cluster gestartet haben, ob es bei einem dieser Services zu Störungen gekommen ist.

Prüfen auf Nutzungsgrenzen

Wenn Sie einen großen Cluster starten, viele Cluster gleichzeitig gestartet haben oder wenn Sie ein Benutzer sind, der einen Cluster AWS-Konto mit anderen Benutzern teilt, ist der Cluster möglicherweise ausgefallen, weil Sie ein AWS Servicelimit überschritten haben.

Amazon EC2 begrenzt die Anzahl der virtuellen Server-Instances, die in einer einzelnen AWS-Region ausgeführt werden, auf 20 On-Demand-Instances oder Reserved Instances. Wenn Sie einen Cluster mit mehr als 20 Knoten starten oder einen Cluster starten, der dazu führt, dass die Gesamtzahl der auf Ihrem AWS-Konto-Computer aktiven EC2-Instances 20 überschreitet, kann der Cluster nicht alle

benötigten EC2-Instances starten und kann ausfallen. In diesem Fall gibt Amazon EMR einen `EC2 QUOTA EXCEEDED`-Fehler zurück. Sie können bei AWS die Erhöhung der Anzahl der in Ihrem Konto verfügbaren EC2-Instances beantragen, indem Sie einen Antrag auf die Erhöhung des Amazon-EC2-Instance-Limits übermitteln.

Eine weitere Sache, die dazu führen kann, dass Sie Ihre Nutzungslimits überschreiten, ist die Verzögerung zwischen der Beendigung eines Clusters und der Freigabe aller seiner Ressourcen. Je nach Konfiguration kann es bis zu 5–20 Minuten dauern, bis ein Cluster vollständig beendet ist und zugewiesene Ressourcen freigibt. Wenn Sie beim Versuch, einen Custer zu starten, die Fehlermeldung `EC2 QUOTA EXCEEDED` erhalten, kann es daran liegen, dass Ressourcen eines kürzlich beendeten Clusters noch nicht zur Verfügung stehen. In diesem Fall können Sie entweder eine Erhöhung Ihres Amazon-EC2-Kontingents beantragen oder zwanzig Minuten warten und den Cluster neu starten.

Amazon S3 begrenzt die Anzahl der auf einem Konto erstellten Buckets auf 100. Wenn Ihr Cluster einen neuen Bucket erstellt, der dieses Limit überschreitet, schlägt die Bucket-Erstellung fehl und kann dazu führen, dass der Cluster fehlschlägt.

Überprüfen der Version

Vergleichen Sie die Versionsbezeichnung, die Sie zum Start des Clusters verwendet haben, mit der aktuellen Amazon-EMR-Version. Jede Version von Amazon EMR beinhaltet Verbesserungen, wie z. B. neue Anwendungen, Features, Patches und Fehlerbehebungen. Das Problem, das Ihren Cluster betrifft, wurde in der aktuellen Version möglicherweise bereits behoben. Führen Sie Ihren Cluster wenn möglich mit der aktuellen Version erneut aus.

Prüfen der Amazon-VPC-Subnetzkonfiguration

Wenn Ihr Cluster in einem Amazon VPC-Subnetz gestartet wurde, muss das Subnetz wie unter Netzwerk konfigurieren beschrieben konfiguriert werden. Überprüfen Sie außerdem, ob das Subnetz, in dem Sie den Cluster starten, über genügend freie elastische IP-Adressen verfügt, um jedem Knoten im Cluster eine zuzuweisen.

Schritt 3: Die letzte Statusänderung überprüfen

Die letzte Statusänderung gibt Aufschluss darüber, welches Ereignis bei der letzten Statusänderung des Clusters aufgetreten ist. Häufig lassen sich Informationen gewinnen, die Hinweise darauf geben, welcher Fehler auftrat, als sich der Cluster-Status in `FAILED` änderte. Wenn Sie beispielsweise einen Streaming-Cluster starten und einen Ausgabespeicherort angeben, der in Amazon S3 bereits

vorhanden ist, tritt beim Cluster ein Fehler auf und die letzte Statusänderung weist darauf hin, dass das Streaming-Ausgabeverzeichnis bereits vorhanden ist.

Sie können den Wert der letzten Statusänderung über die Konsole ermitteln, indem Sie den Detailbereich für den Cluster über die Befehlszeilenschnittstelle (CLI) mit dem Argument `list-steps` oder `describe-cluster` bzw. über die API mit den Aktionen `DescribeCluster` und `ListSteps` anzeigen. Weitere Informationen finden Sie unter Cluster-Status und -Details anzeigen.

Schritt 4: Die Protokolldateien überprüfen

Der nächste Schritt besteht darin, die Protokolldateien zu untersuchen, um einen Fehlercode oder einen anderen Hinweis auf das Problem zu finden, das in Ihrem Cluster aufgetreten ist. Informationen zu den verfügbaren Protokolldateien, wo sie zu finden sind und wie Sie sie anzeigen können, finden Sie unter Anzeige von -Protokolldateien.

Es kann einige Nachforschungen erfordern, um herauszufinden, was passiert ist. Hadoop führt die Arbeit der Aufträge in Aufgabenversuchen auf verschiedenen Knoten im Cluster aus. Amazon EMR kann spekulative Aufgabenversuche initiieren und die anderen Aufgabenversuche beenden, die nicht zuerst abgeschlossen werden. Dadurch werden umfangreiche Aktivitäten generiert, die in den Controller-, Stderr- und Syslog-Protokolldateien protokolliert werden. Darüber hinaus werden mehrere Aufgaben gleichzeitig ausgeführt, aber eine Protokolldatei kann die Ergebnisse nur linear anzeigen.

Überprüfen Sie zunächst die Bootstrap-Aktionsprotokolle auf Fehler oder unerwartete Konfigurationsänderungen beim Start des Clusters. Suchen Sie anschließend in den Schrittprotokollen nach Hadoop-Aufträgen, die als Teil eines fehlerhaften Schritts gestartet wurden. Untersuchen Sie die Hadoop-Auftragsprotokolle, um die fehlgeschlagenen Aufgabenversuche zu identifizieren. Das Protokoll der Aufgabenversuche wird Details darüber enthalten, was zum Fehlschlagen eines Aufgabenversuchs geführt hat.

In den folgenden Abschnitten wird erläutert, wie die verschiedenen Protokolldateien verwendet werden, um Fehler in Ihrem Cluster zu identifizieren.

Überprüfen der Bootstrap-Aktionsprotokolle

Bootstrap-Aktionen führen Skripts auf dem Cluster aus, während dieser gestartet wird. Sie werden häufig verwendet, um zusätzliche Software auf dem Cluster zu installieren oder um Konfigurationseinstellungen gegenüber den Standardwerten zu ändern. Die Überprüfung dieser Protokolle kann Aufschluss über Fehler geben, die bei der Einrichtung des Clusters aufgetreten sind, sowie über Änderungen der Konfigurationseinstellungen, die sich auf die Leistung auswirken könnten.

Die Schrittprotokolle überprüfen

Es gibt vier Arten von Schrittprotokollen.

- Controller – Enthält von Amazon EMR (Amazon EMR) generierte Dateien, die auf Fehler zurückzuführen sind, die bei der Ausführung Ihres Schritts aufgetreten sind. Wenn Ihr Schritt beim Laden fehlschlägt, finden Sie den Stack-Trace in diesem Protokoll. Fehler beim Laden oder Zugreifen auf Ihre Anwendung werden hier häufig beschrieben, ebenso wie Fehler in der fehlenden Mapper-Datei.
- stderr – Enthält Fehlermeldungen, die bei der Verarbeitung des Schritts aufgetreten sind. Fehler beim Laden von Anwendungen werden hier häufig beschrieben. Dieses Protokoll enthält manchmal einen Stack-Trace.
- stdout – Enthält den Status, der von Ihren ausführbaren Mapper- und Reducer-Dateien generiert wurde. Fehler beim Laden von Anwendungen werden hier häufig beschrieben. Dieses Protokoll enthält manchmal Anwendungsfehlermeldungen.
- syslog – Enthält Protokolle von Software, die nicht von Amazon stammt, wie Apache und Hadoop. Streaming-Fehler werden hier häufig beschrieben.

Überprüfe stderr auf offensichtliche Fehler. Wenn stderr eine kurze Liste von Fehlern anzeigt, wurde der Schritt schnell beendet und es wurde ein Fehler ausgelöst. Dies wird meistens durch einen Fehler in den Mapper- und Reducer-Anwendungen verursacht, die im Cluster ausgeführt werden.

Untersuchen Sie die letzten Zeilen von Controller und Syslog auf Hinweise auf Fehler oder Ausfälle. Folgen Sie allen Hinweisen zu fehlgeschlagenen Aufgaben, insbesondere wenn dort „Auftrag fehlgeschlagen“ steht.

Überprüfen der Aufgabenversuchsprotokolle

Wenn die vorherige Analyse der Schrittprotokolle eine oder mehrere fehlgeschlagene Aufgaben ergeben hat, suchen Sie in den Protokollen der entsprechenden Aufgabenversuche nach detaillierteren Fehlerinformationen.

Schritt 5: Den Cluster Schritt für Schritt testen

Eine nützliche Strategie zum Nachverfolgen der Ursache für einen Fehler besteht darin, den Cluster neu zu starten und die Schritte einzeln auszuführen. So können Sie die Ergebnisse für jeden Schritt überprüfen, bevor Sie die Verarbeitung des nächsten Schritts starten, und erhalten die Möglichkeit,

einen fehlgeschlagenen Schritt zu korrigieren und erneut auszuführen. Dies hat den Vorteil, dass Sie Ihre Eingabedaten nur einmal laden müssen.

So testen Sie den Cluster Schritt für Schritt

1. Starten Sie einen neuen Cluster mit aktiviertem Keepalive und Beendigungsschutz. Keepalive sorgt dafür, dass der Cluster weiterhin ausgeführt wird, nachdem er alle ausstehenden Schritte verarbeitet hat. Der Beendigungsschutz verhindert, dass ein Cluster im Falle eines Fehlers heruntergefahren wird. Weitere Informationen finden Sie unter Konfigurieren eines Clusters zum Fortfahren oder Beenden nach der Schrittausführung und Verwenden des Beendigungsschutzes.
2. Senden Sie einen Schritt an den Cluster. Weitere Informationen finden Sie unter Übermitteln von Arbeit an einen Cluster.
3. Wenn die Verarbeitung des Schritts abgeschlossen ist, prüfen Sie die Schrittprotokolldateien auf Fehler. Weitere Informationen finden Sie unter Schritt 4: Die Protokolldateien überprüfen. Die schnellste Möglichkeit zum Auffinden dieser Protokolldateien besteht darin, eine Verbindung mit dem Master-Knoten herzustellen und die Protokolldateien hier anzuzeigen. Die Schrittprotokolldateien werden erst angezeigt, wenn der Schritt einige Zeit ausgeführt wird, beendet wird oder ein Fehler auftritt.
4. Wenn der Schritt erfolgreich ohne Fehler abgeschlossen wurde, führen Sie den nächsten Schritt aus. Wenn Fehler vorliegen, ermitteln Sie den Fehler in den Protokolldateien. Wenn in Ihrem Code ein Fehler aufgetreten ist, korrigieren Sie ihn und führen Sie den Schritt erneut aus. Fahren Sie fort, bis alle Schritte ohne Fehler ausgeführt werden.
5. Wenn Sie das Debuggen des Clusters abgeschlossen haben, müssen Sie den Cluster ggf. manuell beenden. Dies ist erforderlich, da der Cluster mit aktiviertem Beendigungsschutz gestartet wurde. Weitere Informationen finden Sie unter Verwenden des Beendigungsschutzes.

Fehlerbehebung für einen langsamen Cluster

In diesem Abschnitt wird die Fehlerbehebung eines Clusters beschrieben, der noch ausgeführt wird, aber viel Zeit benötigt, um Ergebnisse zurückzugeben. Weitere Informationen zu Verfahren, die Sie anwenden können, wenn der Cluster mit einem Fehlercode beendet wurde, finden Sie unter Fehlerbehebung für einen ausgefallenen Cluster

Mit Amazon EMR können Sie die Anzahl und Art der Instances im Cluster festlegen. Diese Spezifikationen sind die beste Möglichkeit, die Geschwindigkeit, mit der Ihre Daten verarbeitet werden, zu beeinflussen. Sie können eine erneute Ausführung des Clusters in Betracht ziehen.

Hierbei legen Sie EC2-Instances mit mehr Ressourcen oder eine größere Anzahl der Instances im Cluster fest. Weitere Informationen finden Sie unter Cluster-Hardware und Netzwerken konfigurieren.

In den folgenden Themen wird erklärt, wie Sie alternative Ursachen für einen langsamen Cluster identifizieren.

Themen

- Schritt 1: Daten über das Problem sammeln
- Schritt 2: Die Umgebung prüfen
- Schritt 3: Die Protokolldateien prüfen
- Schritt 4: Den Zustand des Clusters und der Instance überprüfen
- Schritt 5: Nach gesperrten Gruppen suchen
- Schritt 6: Konfigurationseinstellungen überprüfen
- Schritt 7: Eingabedaten überprüfen

Schritt 1: Daten über das Problem sammeln

Der erste Schritt bei der Fehlerbehebung bei einem Cluster besteht darin, Informationen darüber zu sammeln, was schief gelaufen ist, sowie über den aktuellen Status und die Konfiguration des Clusters. Diese Informationen werden in den folgenden Schritten verwendet, um mögliche Ursachen des Problems zu bestätigen oder auszuschließen.

Definieren des Problems

Eine klare Definition des Problems ist der erste Ausgangspunkt. Einige Fragen, die Sie sich stellen sollten:

- Was habe ich erwartet? Was ist stattdessen passiert?
- Wann ist dieses Problem zum ersten Mal aufgetreten? Wie oft ist es seitdem passiert?
- Hat sich etwas an der Konfiguration oder Ausführung meines Clusters geändert?

Cluster-Details

Die folgenden Clusterdetails sind hilfreich, um Probleme aufzuspüren. Weitere Informationen zum Sammeln dieser Informationen finden Sie unter Cluster-Status und -Details anzeigen.

- Die Cluster-ID. (Wird auch als Job-Flow-Identifier bezeichnet.)
- AWS-Region und Availability Zone, in der der Cluster gestartet werden soll.
- Status des Clusters, einschließlich Details zur letzten Statusänderung.
- Typ und Anzahl der EC2-Instances, die für die Master-, Core- und Aufgabenknoten angegeben wurden.

Schritt 2: Die Umgebung prüfen

Themen

- Prüfen auf Service-Ausfälle
- Prüfen auf Nutzungsgrenzen
- Prüfen der Amazon-VPC-Subnetzkonfiguration
- Neustarten des Clusters

Prüfen auf Service-Ausfälle

Amazon EMR verwendet intern mehrere Amazon Web Services. Es betreibt virtuelle Server auf Amazon EC2, speichert Daten und Skripts auf Amazon S3 und meldet Metriken an CloudWatch. Ereignisse, die diese Services stören, sind selten – wenn sie jedoch auftreten, können sie zu Problemen in Amazon EMR führen.

Überprüfen Sie die Übersicht zum Servicestatus, bevor Sie fortfahren. Prüfen Sie in der Region, in der Sie Ihren Cluster gestartet haben, ob es bei einem dieser Services zu Störungen gekommen ist.

Prüfen auf Nutzungsgrenzen

Wenn Sie einen großen Cluster starten, viele Cluster gleichzeitig gestartet haben oder wenn Sie ein Benutzer sind, der einen Cluster AWS-Konto mit anderen Benutzern teilt, ist der Cluster möglicherweise ausgefallen, weil Sie ein AWS Servicelimit überschritten haben.

Amazon EC2 begrenzt die Anzahl der virtuellen Server-Instances, die in einer einzelnen AWS-Region ausgeführt werden, auf 20 On-Demand-Instances oder Reserved Instances. Wenn Sie einen Cluster mit mehr als 20 Knoten starten oder einen Cluster starten, der dazu führt, dass die Gesamtzahl der auf Ihrem AWS-Konto-Computer aktiven EC2-Instances 20 überschreitet, kann der Cluster nicht alle benötigten EC2-Instances starten und kann ausfallen. In diesem Fall gibt Amazon EMR einen `EC2 QUOTA EXCEEDED`-Fehler zurück. Sie können bei AWS die Erhöhung der Anzahl der in Ihrem Konto

verfügbaren EC2-Instances beantragen, indem Sie einen Antrag auf die Erhöhung des Amazon-EC2-Instance-Limits übermitteln.

Eine weitere Sache, die dazu führen kann, dass Sie Ihre Nutzungslimits überschreiten, ist die Verzögerung zwischen der Beendigung eines Clusters und der Freigabe aller seiner Ressourcen. Je nach Konfiguration kann es bis zu 5–20 Minuten dauern, bis ein Cluster vollständig beendet ist und zugewiesene Ressourcen freigibt. Wenn Sie beim Versuch, einen Custer zu starten, die Fehlermeldung `EC2 QUOTA EXCEEDED` erhalten, kann es daran liegen, dass Ressourcen eines kürzlich beendeten Clusters noch nicht zur Verfügung stehen. In diesem Fall können Sie entweder eine Erhöhung Ihres Amazon-EC2-Kontingents beantragen oder zwanzig Minuten warten und den Cluster neu starten.

Amazon S3 begrenzt die Anzahl der auf einem Konto erstellten Buckets auf 100. Wenn Ihr Cluster einen neuen Bucket erstellt, der dieses Limit überschreitet, schlägt die Bucket-Erstellung fehl und kann dazu führen, dass der Cluster fehlschlägt.

Prüfen der Amazon-VPC-Subnetzkonfiguration

Wenn Ihr Cluster in einem Amazon VPC-Subnetz gestartet wurde, muss das Subnetz wie unter Netzwerk konfigurieren beschrieben konfiguriert werden. Überprüfen Sie außerdem, ob das Subnetz, in dem Sie den Cluster starten, über genügend freie elastische IP-Adressen verfügt, um jedem Knoten im Cluster eine zuzuweisen.

Neustarten des Clusters

Die Verlangsamung der Verarbeitung kann von einer vorübergehenden Bedingung herrühren. Überlegen Sie sich, ob Sie den Cluster beenden und neu starten möchten, um zu prüfen, ob sich die Leistung verbessert.

Schritt 3: Die Protokolldateien prüfen

Der nächste Schritt besteht darin, die Protokolldateien zu untersuchen, um einen Fehlercode oder einen anderen Hinweis auf das Problem zu finden, das in Ihrem Cluster aufgetreten ist. Informationen zu den verfügbaren Protokolldateien, wo sie zu finden sind und wie Sie sie anzeigen können, finden Sie unter Anzeige von -Protokolldateien.

Es kann einige Nachforschungen erfordern, um herauszufinden, was passiert ist. Hadoop führt die Arbeit der Aufträge in Aufgabenversuchen auf verschiedenen Knoten im Cluster aus. Amazon EMR kann spekulative Aufgabenversuche initiieren und die anderen Aufgabenversuche beenden, die nicht zuerst abgeschlossen werden. Dadurch werden umfangreiche Aktivitäten generiert, die in den

Controller-, Stderr- und Syslog-Protokolldateien protokolliert werden. Darüber hinaus werden mehrere Aufgaben gleichzeitig ausgeführt, aber eine Protokolldatei kann die Ergebnisse nur linear anzeigen.

Überprüfen Sie zunächst die Bootstrap-Aktionsprotokolle auf Fehler oder unerwartete Konfigurationsänderungen beim Start des Clusters. Suchen Sie anschließend in den Schrittprotokollen nach Hadoop-Aufträgen, die als Teil eines fehlerhaften Schritts gestartet wurden. Untersuchen Sie die Hadoop-Auftragsprotokolle, um die fehlgeschlagenen Aufgabenversuche zu identifizieren. Das Protokoll der Aufgabenversuche wird Details darüber enthalten, was zum Fehlschlagen eines Aufgabenversuchs geführt hat.

In den folgenden Abschnitten wird erläutert, wie die verschiedenen Protokolldateien verwendet werden, um Fehler in Ihrem Cluster zu identifizieren.

Überprüfen der Bootstrap-Aktionsprotokolle

Bootstrap-Aktionen führen Skripts auf dem Cluster aus, während dieser gestartet wird. Sie werden häufig verwendet, um zusätzliche Software auf dem Cluster zu installieren oder um Konfigurationseinstellungen gegenüber den Standardwerten zu ändern. Die Überprüfung dieser Protokolle kann Aufschluss über Fehler geben, die bei der Einrichtung des Clusters aufgetreten sind, sowie über Änderungen der Konfigurationseinstellungen, die sich auf die Leistung auswirken könnten.

Die Schrittprotokolle überprüfen

Es gibt vier Arten von Schrittprotokollen.

- Controller – Enthält von Amazon EMR (Amazon EMR) generierte Dateien, die auf Fehler zurückzuführen sind, die bei der Ausführung Ihres Schritts aufgetreten sind. Wenn Ihr Schritt beim Laden fehlschlägt, finden Sie den Stack-Trace in diesem Protokoll. Fehler beim Laden oder Zugreifen auf Ihre Anwendung werden hier häufig beschrieben, ebenso wie Fehler in der fehlenden Mapper-Datei.
- stderr – Enthält Fehlermeldungen, die bei der Verarbeitung des Schritts aufgetreten sind. Fehler beim Laden von Anwendungen werden hier häufig beschrieben. Dieses Protokoll enthält manchmal einen Stack-Trace.
- stdout – Enthält den Status, der von Ihren ausführbaren Mapper- und Reducer-Dateien generiert wurde. Fehler beim Laden von Anwendungen werden hier häufig beschrieben. Dieses Protokoll enthält manchmal Anwendungsfehlermeldungen.
- syslog – Enthält Protokolle von Software, die nicht von Amazon stammt, wie Apache und Hadoop. Streaming-Fehler werden hier häufig beschrieben.

Überprüfe stderr auf offensichtliche Fehler. Wenn stderr eine kurze Liste von Fehlern anzeigt, wurde der Schritt schnell beendet und es wurde ein Fehler ausgelöst. Dies wird meistens durch einen Fehler in den Mapper- und Reducer-Anwendungen verursacht, die im Cluster ausgeführt werden.

Untersuchen Sie die letzten Zeilen von Controller und Syslog auf Hinweise auf Fehler oder Ausfälle. Folgen Sie allen Hinweisen zu fehlgeschlagenen Aufgaben, insbesondere wenn dort „Auftrag fehlgeschlagen“ steht.

Überprüfen der Aufgabenversuchsprotokolle

Wenn die vorherige Analyse der Schrittprotokolle eine oder mehrere fehlgeschlagene Aufgaben ergeben hat, suchen Sie in den Protokollen der entsprechenden Aufgabenversuche nach detaillierteren Fehlerinformationen.

Überprüfen der Hadoop-Daemon-Protokolle

In seltenen Fällen kann Hadoop selbst ausfallen. Um zu sehen, ob das der Fall ist, müssen Sie sich die Hadoop-Protokolle ansehen. Sie befinden sich auf `/var/log/hadoop/` auf jedem Knoten.

Sie können die JobTracker-Protokolle verwenden, um einen fehlgeschlagenen Aufgabenversuch dem Knoten zuzuordnen, auf dem er ausgeführt wurde. Sobald Sie den Knoten kennen, der mit dem Aufgabenversuch verknüpft ist, können Sie den Zustand der EC2-Instance überprüfen, die diesen Knoten hostet, um festzustellen, ob Probleme wie etwa ein Mangel an CPU oder Arbeitsspeicher aufgetreten sind.

Schritt 4: Den Zustand des Clusters und der Instance überprüfen

Ein Amazon-EMR-Cluster besteht aus Knoten, die auf Amazon EC2 Instances ausgeführt werden. Wenn diese Instances viele Ressourcen binden (z. B. CPU oder Speicherplatz), Probleme mit der Netzwerkkonnektivität haben oder beendet werden, leidet die Geschwindigkeit der Cluster-Verarbeitung.

Es gibt bis zu drei Arten von Knoten in einem Cluster:

- Hauptknoten – verwaltet den Cluster. Wenn ein Leistungsproblem auftritt, ist der gesamte Cluster betroffen.
- Core-Knoten – verarbeiten Map- und Reduce-Aufgaben und verwalten das Hadoop Distributed File System (HDFS). Wenn einer dieser Knoten ein Leistungsproblem hat, kann dies sowohl HDFS-Operationen als auch Map- und Reduce-Verarbeitungen verlangsamen. Sie können einem Cluster

zusätzliche Core-Knoten hinzufügen, um die Leistung zu verbessern, aber keine Core-Knoten entfernen. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters.

- Aufgabenknoten – verarbeiten Map- und Reduce-Aufgaben. Dies sind reine Rechenressourcen und speichern keine Daten. Sie können einem Cluster Aufgabenknoten hinzufügen, um die Leistung zu beschleunigen, oder nicht benötigte Aufgabenknoten entfernen. Weitere Informationen finden Sie unter Manuelle Größenanpassung eines aktiven Clusters.

Wenn Sie den Zustand eines Clusters prüfen, sollten Sie sich sowohl die Leistung des Clusters insgesamt als auch die Leistung der einzelnen Instances anschauen. Es gibt mehrere Tools, die Sie verwenden können:

Überprüfen Sie den Clusterstatus mit CloudWatch

Jeder Amazon-EMR-Cluster meldet Metriken an CloudWatch. Diese Metriken stellen zusammenfassende Leistungsinformationen über den Cluster bereit, wie z. B. Gesamtlast, HDFS-Auslastung, ausgeführte Aufgaben, verbleibende Aufgaben und beschädigte Blöcke. Ein Blick auf die CloudWatch-Metriken bietet Ihnen einen Überblick über den Betriebszustand Ihres Clusters und ermöglicht Ihnen einen detaillierten Einblick in die Ursachen für die Verlangsamung der Verarbeitung. Sie können CloudWatch aber nicht nur zum Analysieren bestehender Leistungsprobleme verwenden, sondern auch Alarme einrichten, damit CloudWatch eine Warnung bei zukünftigen Leistungsproblemen ausgibt. Weitere Informationen finden Sie unter Überwachung von Amazon-EMR-Metriken mit CloudWatch.

Überprüfen von Auftragsstatus und HDFS-Zustand

Verwenden Sie die Option Application user interface (Anwendungsbenutzeroberflächen) auf der Detailseite des Clusters, um Details zur YARN-Anwendung anzuzeigen. Bei bestimmten Anwendungen können Sie weitere Details und Zugriffsprotokolle direkt anzeigen. Dies ist besonders nützlich für Spark-Anwendungen. Weitere Informationen finden Sie unter Anwendungsverlauf anzeigen.

Hadoop bietet eine Reihe von Webschnittstellen, mit denen Sie Informationen anzeigen lassen können. Weitere Informationen darüber, wie Sie auf diese Webschnittstellen zugreifen können, finden Sie unter Anzeigen von auf Amazon-EMR-Clustern gehosteten Webschnittstellen.

- JobTracker – bietet Informationen über den Verlauf des Auftrags, der vom Cluster verarbeitet wird. Mit dieser Schnittstelle können Sie ermitteln, wann ein Auftrag blockiert ist.

- HDFS NameNode – bietet Informationen über den Prozentsatz der HDFS-Auslastung und des verfügbaren Speicherplatzes auf jedem Knoten. Sie können mit dieser Schnittstelle bestimmen, wann HDFS Ressourcen bindet und zusätzliche Kapazität benötigt.
- TaskTracker – bietet Informationen über die Aufgaben des Auftrags, der vom Cluster verarbeitet wird. Mit dieser Schnittstelle können Sie ermitteln, wann eine Aufgabe blockiert ist.

Instance-Zustandsprüfung mit Amazon EC2

Die Amazon-EC2-Konsole bietet eine weitere Möglichkeit, um Informationen über den Status der Instances in Ihrem Cluster zu ermitteln. Da jeder Knoten im Cluster auf einer EC2-Instance ausgeführt wird, können Sie mithilfe der von Amazon EC2 bereitgestellten Tools ihren Status überprüfen. Weitere Informationen finden Sie unter Anzeigen von Cluster-Instances in Amazon EC2.

Schritt 5: Nach gesperrten Gruppen suchen

Eine Instance-Truppe wird angehalten, wenn beim Versuch, einen Knoten zu starten, zu viele Fehler auftreten. Wenn z. B. neue Knoten während der Durchführung von Bootstrap-Aktionen wiederholt fehlschlagen, wechselt die Instance-Gruppe nach einiger Zeit in den Status `SUSPENDED`, anstatt fortlaufend zu versuchen, neue Knoten bereitzustellen.

In folgenden Fällen kann ein Knoten fehlschlagen:

- Hadoop oder der Cluster ist irgendwie beschädigt und akzeptiert keinen neuen Knoten im Cluster.
- Eine Bootstrap-Aktion schlägt auf dem neuen Knoten fehl.
- Der Knoten arbeitet nicht ordnungsgemäß und kann nicht mit Hadoop einchecken

Wenn sich eine Instance-Gruppe im Status `SUSPENDED` befindet und der Cluster den Status `WAITING` hat, können Sie einen Cluster-Schritt hinzufügen, um die gewünschte Anzahl von Core- und Aufgabenknoten zurückzusetzen. Durch Hinzufügen des Schritts wird die Verarbeitung des Clusters fortgesetzt und die Instance-Gruppe wieder in den Status `RUNNING` versetzt.

Weitere Informationen zum Zurücksetzen eines Clusters im angehaltenen Zustand finden Sie unter Suspendierter Zustand.

Schritt 6: Konfigurationseinstellungen überprüfen

Konfigurationseinstellungen legen die Ausführung eines Clusters im Detail fest, z. B. wie häufig eine Aufgabe wiederholt wird und wie viel Arbeitsspeicher zum Sortieren verfügbar ist. Wenn

Sie einen Cluster mithilfe von Amazon EMR starten, gibt es zusätzlich zu den standardmäßigen Hadoop-Konfigurationseinstellungen auch Amazon-EMR-spezifische Einstellungen. Die Konfigurationseinstellungen werden im Master-Knoten des Clusters gespeichert. Sie können die Konfigurationseinstellungen überprüfen, um sicherzustellen, dass Ihr Cluster über die benötigten Ressourcen für einen effizienten Betrieb verfügt.

Amazon EMR legt standardmäßige Hadoop-Konfigurationseinstellungen fest, die zum Starten eines Clusters verwendet werden. Die Werte basieren auf dem AMI und dem Instance-Typ, den Sie für den Cluster angeben. Ändern können Sie die Standardwerte der Konfigurationseinstellungen mithilfe einer Bootstrap-Aktion oder indem Sie neue Wert in den Parametern für die Auftragsausführung festlegen. Weitere Informationen finden Sie unter Erstellen von Bootstrap-Aktionen zur Installation zusätzlicher Software. Um zu bestimmen, ob eine Bootstrap-Aktion die Konfigurationseinstellungen geändert hat, prüfen Sie die Bootstrap-Aktionsprotokolle.

Amazon EMR protokolliert die Hadoop-Einstellungen für die Ausführung aller Aufträge. Die Protokolldaten werden in einer Datei mit dem Namen `job_`*`job-id`*`_conf.xml` im Verzeichnis des Master-Knotens `/mnt/var/log/hadoop/history/` gespeichert. Hierbei wird *`job-id`* durch die Auftrags-ID ersetzt. Wenn Protokollierungsarchivierung aktiviert ist, werden diese Daten nach Amazon S3 kopiert, und zwar in den Ordner `logs/`*`date`*`/`*`jobflow-id`*`/jobs`. Hierbei ist *`date`* das Datum der Auftragsausführung und *`jobflow-id`* die Cluster-ID.

Die folgenden Konfigurationseinstellungen des Hadoop-Auftrags eignen sich besonders für die Untersuchung von Leistungsproblemen. Weitere Informationen zu den Hadoop-Konfigurationseinstellungen und deren Auswirkungen auf das Verhalten von Hadoop finden Sie unter http://hadoop.apache.org/docs/.

Warning

1. Das Festlegen von `dfs.replication` auf 1 auf Clustern mit weniger als vier Knoten kann zu einem HDFS-Datenverlust führen, wenn ein einzelner Knoten ausfällt. Wir empfehlen, für Produktionsworkloads einen Cluster mit mindestens vier Core-Knoten zu verwenden.
2. Amazon EMR erlaubt Clustern nicht, Core-Knoten unter `dfs.replication` zu skalieren. Bei `dfs.replication = 2` z. B. beträgt die Mindestanzahl von Core-Knoten 2.
3. Wenn Sie verwaltete Skalierung oder Auto-Scaling verwenden oder die Größe Ihres Clusters manuell ändern möchten, empfehlen wir Ihnen, `dfs.replication` auf 2 oder höher einzustellen.

Konfigurationseinstellung	Beschreibung
dfs.replication	Die Anzahl der HDFS-Knoten, in die ein einziger Block (z. B. der Festplattenblock) kopiert wird, um eine RAID-ähnliche Umgebung zu erstellen. Bestimmt die Anzahl der HDFS-Knoten, die eine Kopie des Blocks enthalten.
io.sort.mb	Für die Sortierung verfügbarer Gesamtspeicher. Dieser Wert sollte das Zehnfache von "io.sort.factor" sein. Diese Einstellung kann auch für die Berechnung des vom Aufgabenknoten genutzten Gesamtspeichers durch Berechnen von "io.sort.mb" multipliziert mit "mapred.tasktracker.ap.tasks.maximum" verwendet werden.
io.sort.spill.percent	Wird während der Sortierung verwendet. An diesem Punkt beginnt die Verwendung des Datenträgers, da der für die Sortierung zugewiesene Speicherplatz knapp wird.
mapred.child.java.opts	Als veraltet gekennzeichnet. Verwenden Sie stattdessen "mapred.map.child.java.opts" und "mapred.reduce.child.java.opts". Die Java-Optionen, die TaskTracker beim Starten einer JVM für die Ausführung einer Aufgabe innerhalb verwendet. "-Xmx" ist ein üblicher Parameter zum Festlegen der maximalen Arbeitsspeichergröße.
mapred.map.child.java.opts	Die Java-Optionen, die TaskTracker beim Starten einer JVM für die Ausführung einer Map-Aufgabe innerhalb verwendet. "-Xmx" ist ein üblicher Parameter zum Festlegen der maximalen Heap-Arbeitsspeichergröße.
mapred.map.tasks.speculative.execution	Legt fest, ob Map-Aufgabenversuche derselben Aufgabe parallel gestartet werden können.
mapred.reduce.tasks.speculative.execution	Legt fest, ob Reduce-Aufgabenversuche derselben Aufgabe parallel gestartet werden können.

Konfigurationseinstellung	Beschreibung
mapred.map.max.attempts	Die maximale Anzahl an Map-Aufgabenversuchen. Wenn alle fehlschlagen, wird die Map-Aufgabe als fehlgesch lagen markiert.
mapred.reduce.child.java.opts	Die Java-Optionen, die TaskTracker beim Starten einer JVM für die Ausführung einer Reduce-Aufgabe innerhalb verwendet. "-Xmx" ist ein üblicher Parameter zum Festlegen der maximalen Heap-Arbeitsspeichergröße.
mapred.reduce.max.attempts	Die maximale Anzahl an Reduce-Aufgabenversuchen. Wenn alle fehlschlagen, wird die Map-Aufgabe als fehlgeschlagen markiert.
mapred.reduce.slowstart.com pleted.maps	Die Anzahl an Map-Aufgaben, die abgeschlossen werden, bevor Reduce-Aufgabenversuche durchgeführt werden. Bei zu geringer Wartezeit kann der Fehler „Too many fetch" in Versuchen ausgelöst werden.
mapred.reuse.jvm.num.tasks	Eine Aufgabe wird innerhalb einer einzelnen JVM ausgeführt. Gibt an, wie viele Aufgaben dieselbe JVM wiederverwenden dürfen.
mapred.tasktracker.map.task s.maximum	Die maximale Anzahl von Aufgaben, die während des Map-Vorgangs pro Aufgabenknoten parallel ausgeführt werden können.
mapred.tasktracker.reduce.t asks.maximum	Die maximale Anzahl von Aufgaben, die während des Reduce-Vorgangs pro Aufgabenknoten parallel ausgeführ t werden können.

Wenn Ihre Cluster-Aufgaben arbeitsspeicherintensiv sind, können Sie die Leistung verbessern, indem Sie weniger Aufgaben pro Core-Knoten verwenden und die Heap-Größe des JobTrackers reduzieren.

Schritt 7: Eingabedaten überprüfen

Schauen Sie sich Ihre Eingabedaten an. Sind diese gleichmäßig auf Ihre Schlüsselwerte verteilt? Bei einer starken Datenschiefe in Richtung eines oder weniger Schlüsselwerte wird die Verarbeitungslast möglicherweise einer kleinen Anzahl von Knoten zugeordnet, während sich andere Knoten im Leerlauf befinden. Diese ungleichmäßige Verteilung der Arbeit kann zu einer langsameren Verarbeitung führen.

Um einen ungleichmäßigen Datensatz handelt es sich z. B., wenn ein Cluster ausgeführt wird, um Wörter alphabetisch anzuordnen, aber ein Datensatz zur Verfügung steht, dessen Wörter alle nur mit "a" beginnen. Beim Map-Vorgang wird dann der Knoten überfordert, der Werte verarbeitet, die mit "a" anfangen, während diejenigen Knoten nicht beschäftigt sind, die Wörter mit anderen Anfangsbuchstaben verarbeiten.

Problembehandlung bei einem Lake-Formation-Cluster

Dieser Abschnitt führt Sie durch die Fehlerbehebung bei Probleme, die häufig bei der Verwendung von Amazon EMR mit AWS Lake Formation auftreten.

Der Zugriff auf den Data Lake ist nicht zulässig

Sie müssen sich ausdrücklich für die Datenfilterung auf Amazon-EMR-Clustern entscheiden, bevor Sie Daten in Ihrem Data Lake analysieren und verarbeiten können. Wenn der Datenzugriff fehlschlägt, wird in der Ausgabe Ihrer Notebookeinträge eine allgemeine `Access is not allowed` Meldung angezeigt.

Anweisungen dazu, wie Sie die Datenfilterung in Amazon EMR aktivieren und zulassen können, finden Sie unter Datenfilterung auf Amazon EMR zulassen im AWS Lake Formation-Entwicklerhandbuch.

Sitzungsablauf

Das Sitzungs-Timeout für EMR Notebooks und Zeppelin wird durch die Einstellung `Maximum CLI/API session duration` der IAM-Rolle zur Lake Formation gesteuert. Der Standardwert für diese Einstellung ist eine Stunde. Wenn ein Sitzungs-Timeout auftritt, wird in der Ausgabe Ihrer Notebook-Einträge die folgende Meldung angezeigt, wenn Sie versuchen, Spark SQL-Befehle auszuführen.

```
Error 401    HTTP ERROR: 401 Problem accessing /sessions/2/statements.
```

```
Reason:  JWT token included in request failed validation.
Powered by Jetty:// 9.3.24.v20180605
 org.springframework.web.client.HttpClientErrorException: 401 JWT token included in
 request failed validation…
```

Aktualisieren Sie die Seite, um Ihre Sitzung zu validieren. Sie werden aufgefordert, sich erneut über Ihren Identitätsanbieter zu authentifizieren und dann zu dem Notebook zurückgeleitet. Sie können nach der erneuten Authentifizierung weiter Abfragen ausführen.

Keine Berechtigungen für Benutzer in der angeforderten Tabelle

Beim Versuch, auf eine Tabelle zuzugreifen, auf die Sie keinen Zugriff haben, wird in der Ausgabe Ihrer Notebook-Einträge die folgende Ausnahme angezeigt, wenn Sie versuchen, Spark SQL-Befehle auszuführen.

```
org.apache.spark.sql.AnalysisException:
 org.apache.hadoop.hive.ql.metadata.HiveException: Unable to fetch table table.
Resource does not exist or requester is not authorized to access requested
 permissions.
(Service: AWSGlue; Status Code: 400; Error Code: AccessDeniedException; Request ID: …
```

Um auf die Tabelle zuzugreifen, müssen Sie dem Benutzer Zugriff gewähren, indem Sie die mit dieser Tabelle verknüpften Berechtigungen in Lake Formation aktualisieren.

Abfragen von kontenübergreifenden Daten, die mit Lake Formation geteilt wurden

Wenn Sie Amazon EMR verwenden, um auf Daten zuzugreifen, die von einem anderen Konto aus mit Ihnen geteilt wurden, versuchen einige Spark-Bibliotheken, den `Glue:GetUserDefinedFunctions`-API-Vorgang aufzurufen. Da die Versionen 1 und 2 der von AWS RAM verwalteten Berechtigungen diese Aktion nicht unterstützen, erhalten Sie die folgende Fehlermeldung:

```
"ERROR: User: arn:aws:sts::012345678901:assumed-role/my-
spark-role/i-06ab8c2b59299508a is not authorized to perform:
glue:GetUserDefinedFunctions on resource: arn:exampleCatalogResource
because no resource-based policy allows the glue:GetUserDefinedFunctions
action"
```

Um diesen Fehler zu beheben, muss der Data Lake-Administrator, der die Ressourcenfreigabe erstellt hat, die von AWS RAM verwalteten Berechtigungen aktualisieren, die der Ressourcenfreigabe zugeordnet sind. Version 3 der von AWS RAM verwalteten Berechtigungen ermöglicht es Prinzipalen, die `glue:GetUserDefinedFunctions`-Aktion auszuführen.

Wenn Sie eine neue Ressourcenfreigabe erstellen, wendet Lake Formation standardmäßig die neueste Version der von AWS RAM verwalteten Berechtigung an, sodass Sie nichts unternehmen müssen. Um den kontenübergreifenden Datenzugriff für bestehende Ressourcenfreigaben zu ermöglichen, müssen Sie die von AWS RAM verwalteten Berechtigungen auf Version 3 aktualisieren.

Die AWS RAM-Berechtigungen, die Ressourcen zugewiesen wurden, die mit Ihnen geteilt wurden, finden Sie unter AWS RAM. Die folgenden Berechtigungen sind in Version 3 enthalten:

```
Databases
  AWSRAMPermissionGlueDatabaseReadWriteForCatalog
  AWSRAMPermissionGlueDatabaseReadWrite

Tables
  AWSRAMPermissionGlueTableReadWriteForCatalog
  AWSRAMPermissionGlueTableReadWriteForDatabase

AllTables
  AWSRAMPermissionGlueAllTablesReadWriteForCatalog
  AWSRAMPermissionGlueAllTablesReadWriteForDatabase
```

So aktualisieren Sie die Version vorhandener Ressourcenfreigaben mit von AWS RAM verwalteten Berechtigungen

Sie (Data Lake-Administrator) können entweder von AWS RAM verwaltete Berechtigungen auf eine neuere Version aktualisieren, indem Sie den Anweisungen im AWS RAM-Benutzerhandbuch folgen, oder Sie können alle vorhandenen Berechtigungen für den Ressourcentyp widerrufen und sie erneut erteilen. Wenn Sie Berechtigungen widerrufen, wird die mit dem AWS RAM-Ressourcentyp verknüpfte Ressourcenfreigabe AWS RAM gelöscht. Wenn Sie Berechtigungen erneut gewähren, erstellt AWS RAM neue Ressourcenfreigaben, denen die neueste Version der von AWS RAM verwalteten Berechtigungen angehängt wird.

Einfügen in, Erstellen und Ändern von Tabellen

Das Einfügen von Daten in Tabellen in Datenbanken und das Erstellen und Ändern von Datenbanken, die durch Lake Formation Richtlinien geschützt sind, wird nicht unterstützt. Wenn Sie

diese Operationen ausführen, wird in der Ausgabe Ihrer Notebook-Einträge die folgende Ausnahme angezeigt, wenn Sie versuchen, Spark SQL-Befehle auszuführen:

```
java.io.IOException:
 com.amazon.ws.emr.hadoop.fs.shaded.com.amazonaws.services.s3.model.AmazonS3Exception:
           Access Denied (Service: Amazon S3; Status Code: 403; Error Code:
 AccessDenied; Request ID: …
```

Weitere Informationen finden Sie unter Einschränkungen der Amazon-EMR-Integration in AWS Lake Formation.

Schreiben von Anwendungen, die Cluster starten und verwalten

Themen

- Umfassendes Amazon-EMR-Java-Quellcodebeispiel
- Grundlegende Konzepte für API-Aufrufe
- So verwenden Sie SDKs zum Aufrufen von Amazon-EMR-APIs
- Amazon EMR Service Quotas verwalten

Sie können über das Aufrufen der Wrapper-Funktionen in einem der AWS-SDKs auf die Funktionalität der Amazon-EMR-API zugreifen. Die AWS-SDKs bieten sprachspezifische Wrapper-Funktionen für die API des Web-Services und vereinfachen die Verbindung mit dem Web-Service (sie kümmern sich für Sie um viele Verbindungsdetails). Weitere Informationen zum Aufrufen von Amazon EMR mit einem der SDKs finden Sie unter So verwenden Sie SDKs zum Aufrufen von Amazon-EMR-APIs.

> **Important**
>
> Die maximale Anforderungsrate für Amazon EMR beträgt eine Anforderung alle zehn Sekunden.

Umfassendes Amazon-EMR-Java-Quellcodebeispiel

Entwickler können die Amazon-EMR-API über benutzerdefinierten Java-Code aufrufen, um die über die Amazon-EMR-Konsole und CLI verfügbaren Funktionen zu nutzen. Dieser Abschnitt enthält die kompletten Schritte zur Installation von AWS Toolkit for Eclipse und voll funktionsfähigen Java-Quellcode zum Hinzufügen von Schritten zu einem Amazon-EMR-Cluster.

> **Note**
>
> Dieses Beispiel konzentriert sich auf Java. Amazon EMR unterstützt über verschiedene Amazon-EMR-SDKs jedoch auch andere Programmiersprachen. Weitere Informationen finden Sie unter So verwenden Sie SDKs zum Aufrufen von Amazon-EMR-APIs.

In diesem Java-Beispiel wird gezeigt, wie die folgenden Aufgaben mit der Amazon-EMR-API durchgeführt werden:

- Abrufen von AWS-Anmeldeinformationen und Senden der Informationen an Amazon EMR für API-Aufrufe
- Konfigurieren eines neuen, benutzerdefinierten Schritts und eines neuen, vordefinierten Schritts
- Hinzufügen neuer Schritte zu einem vorhandenen Amazon-EMR-Cluster
- Abrufen der Cluster-Schritt-IDs aus einem ausgeführten Cluster

> **Note**
>
> In diesem Beispiel wird gezeigt, wie Sie Schritte zu einem vorhandene, Cluster hinzufügen. Daher ist ein aktiver Cluster in Ihrem Konto erforderlich.

Bevor Sie beginnen, installieren Sie die Version von Eclipse IDE for Java EE Developers, die Ihrer Plattform entspricht. Weitere Informationen erhalten Sie unter Eclipse-Downloads.

Als Nächstes installieren Sie das Database Development Plug-in für Eclipse.

So installieren Sie das Database Development Plug-in für Eclipse

1. Öffnen Sie die Eclipse-IDE.
2. Wählen Sie Help (Hilfe) und dann Install New Software (Neue Software installieren) aus.
3. Geben Sie im Feld Work with: (Arbeiten mit:) **`http://download.eclipse.org/releases/kepler`** oder den Pfad ein, der der Versionsnummer Ihrer Eclipse IDE entspricht.
4. Wählen Sie in der Liste Database Development (Datenbankentwicklung) und Finish (Fertig stellen) aus.
5. Starten Sie Eclipse neu, wenn Sie dazu aufgefordert werden.

Als Nächstes installieren Sie das Toolkit für Eclipse, um hilfreiche, vorkonfigurierte Quellcode-Projektvorlagen nutzen zu können.

So installieren Sie das Toolkit für Eclipse

1. Öffnen Sie die Eclipse-IDE.

2. Wählen Sie Help (Hilfe) und dann Install New Software (Neue Software installieren) aus.
3. Geben Sie im Feld Work with: (Arbeiten mit:) **`https://aws.amazon.com/eclipse`** ein.
4. Wählen Sie in der Artikelliste die Option AWS Toolkit for Eclipse und Fertigstellen aus.
5. Starten Sie Eclipse neu, wenn Sie dazu aufgefordert werden.

Als Nächstes erstellen Sie ein neues AWS-Java-Projekt und führen den Beispiel-Java-Quellcode aus.

So erstellen Sie ein neues AWS-Java-Projekt

1. Öffnen Sie die Eclipse-IDE.
2. Wählen Sie File (Datei), New (Neu) und Other (Sonstiges) aus.
3. Wählen Sie im Dialogfeld Einen Assistenten auswählen AWS-Java-Projekt und Weiter aus.
4. Geben Sie im Dialogfeld Neues AWS-Java-Projekt im Feld **`Project name:`** den Namen Ihres neuen Projekts ein, zum Beispiel **`EMR-sample-code`**.
5. Wählen Sie AWS-Konten konfigurieren … aus und geben Sie Ihren öffentlichen und privaten Zugriffsschlüssel ein. Wählen Sie dann Fertigstellen aus. Weitere Informationen zum Erstellen von Zugriffsschlüsseln finden Sie unter Wie erhalte ich Sicherheitsanmeldeinformationen? in Allgemeine Amazon-Web-Services-Referenz.

   > **Note**
   >
   > Sie sollten Zugriffsschlüssel nicht direkt in den Code einbetten. Das Amazon-EMR-SDK ermöglicht es Ihnen, Zugriffsschlüssel in bekannten Speicherorten abzulegen, sodass Sie sie nicht in den Code integrieren müssen.

6. Klicken Sie im neuen Java-Projekt mit der rechten Maustaste auf den src--Ordner und wählen Sie dann New (Neu) und Class (Klasse) aus.
7. Geben Sie im Dialogfeld Java Class (Java-Klasse) in das Feld Name einen Namen für Ihre neue Klasse ein (z. B. **`main`**).
8. Wählen Sie im Abschnitt Which method stubs would you like to create? (Welche Method-Stubs möchten Sie erstellen?) public static void main (String [] args) und Finish (Fertig stellen) aus.
9. Geben Sie den Java-Quellcode in Ihrer neuen Klasse ein und fügen Sie die entsprechenden import (Importieren)-Anweisungen für die Klassen und Methoden des Beispiels hinzu. Den vollständigen Quellcode finden Sie unten.

> **Note**
>
> Ersetzen Sie im folgenden Beispiel-Code die Beispiel-Cluster-ID (JobFlowId, *j-xxxxxxxxxxxx*) durch eine gültige Cluster-ID im Konto. Diese kann in der AWS Management Console oder mit dem folgenden AWS CLI-Befehl ermittelt werden:
>
> ```
> aws emr list-clusters --active | grep "Id"
> ```
>
> Ersetzen Sie außerdem den Amazon-S3-Beispielpfad *s3://path/to/my/jarfolder* durch den gültigen Pfad der JAR-Datei. Ersetzen Sie den Beispiel-Klassennamen (*com.my.Main1*) durch den richtigen Namen der Klasse in der JAR-Datei (falls relevant).

```
import com.amazonaws.AmazonClientException;
import com.amazonaws.auth.AWSCredentials;
import com.amazonaws.auth.AWSStaticCredentialsProvider;
import com.amazonaws.auth.profile.ProfileCredentialsProvider;
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduce;
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduceClientBuilder;
import com.amazonaws.services.elasticmapreduce.model.*;
import com.amazonaws.services.elasticmapreduce.util.StepFactory;

public class Main {

 public static void main(String[] args) {
  AWSCredentials credentials_profile = null;
  try {
   credentials_profile = new
 ProfileCredentialsProvider("default").getCredentials();
       } catch (Exception e) {
           throw new AmazonClientException(
                   "Cannot load credentials from .aws/credentials file. " +
                   "Make sure that the credentials file exists and the profile
 name is specified within it.",
                   e);
       }

  AmazonElasticMapReduce emr = AmazonElasticMapReduceClientBuilder.standard()
   .withCredentials(new AWSStaticCredentialsProvider(credentials_profile))
```

```
    .withRegion(Regions.US_WEST_1)
    .build();

  // Run a bash script using a predefined step in the StepFactory helper class
     StepFactory stepFactory = new StepFactory();
     StepConfig runBashScript = new StepConfig()
       .withName("Run a bash script")
       .withHadoopJarStep(stepFactory.newScriptRunnerStep("s3://jeffgoll/emr-
scripts/create_users.sh"))
       .withActionOnFailure("CONTINUE");

     // Run a custom jar file as a step
     HadoopJarStepConfig hadoopConfig1 = new HadoopJarStepConfig()
        .withJar("s3://path/to/my/jarfolder") // replace with the location of the
 jar to run as a step
        .withMainClass("com.my.Main1") // optional main class, this can be omitted
 if jar above has a manifest
        .withArgs("--verbose"); // optional list of arguments to pass to the jar
     StepConfig myCustomJarStep = new StepConfig("RunHadoopJar", hadoopConfig1);

     AddJobFlowStepsResult result = emr.addJobFlowSteps(new
 AddJobFlowStepsRequest()
    .withJobFlowId("j-xxxxxxxxxxxx") // replace with cluster id to run the steps
    .withSteps(runBashScript,myCustomJarStep));

          System.out.println(result.getStepIds());

 }
}
```

10. Wählen Sie Run (Ausführen), Run As (Ausführen als) und Java Application (Java-Anwendung) aus.
11. Wenn das Beispiel korrekt ausgeführt wird, wird eine Liste der IDs für die neuen Schritte in der Eclipse-IDE-Konsole angezeigt. Die korrekte Ausgabe sieht folgendermaßen oder ähnlich aus:

```
[s-39BLQZRJB2E5E, s-1L6A4ZU2SAURC]
```

Grundlegende Konzepte für API-Aufrufe

Themen

- Endpunkte für Amazon EMR
- Angeben von Cluster-Parametern in Amazon EMR
- Availability Zones in Amazon EMR
- So verwenden Sie weitere Dateien und Bibliotheken in Amazon-EMR-Clustern

Wenn Sie eine Anwendung entwickeln, die Amazon-EMR-API-Aufrufe durchführt, gibt es mehrere Konzepte, die Sie beim Aufruf einer der Wrapper-Funktionen in einem SDK einsetzen können.

Endpunkte für Amazon EMR

Ein Endpunkt ist eine URL, die als Eintrittspunkt für einen Webservice fungiert. Jede Webserviceanforderung muss einen Endpunkt umfassen. Der Endpunkt gibt die AWS-Region an, in der Cluster erstellt, beschrieben oder beendet werden. Er hat die Form `elasticmapreduce.`*`regionname`*`.amazonaws.com`. Wenn Sie den allgemeinen Endpunkt (`elasticmapreduce.amazonaws.com`) angeben, leitet Amazon EMR Ihre Anforderung an einen Endpunkt in der Standardregion weiter. Für Konten, die am oder nach dem 8. März 2013 erstellt wurden, lautet die Standardregion "us-west-2"; für ältere Konten ist die Standardregion "us-east-1".

Weitere Informationen über Regionen und Endpunkte für Amazon EMR finden Sie unter Regionen und Endpunkte im Allgemeine Amazon Web Services-Referenz.

Angeben von Cluster-Parametern in Amazon EMR

Die `Instances`-Parameter ermöglichen das Konfigurieren des Typs und der Anzahl der EC2-Instances zum Erstellen von Knoten für die Verarbeitung der Daten. Hadoop verteilt die Verarbeitung der Daten über mehrere Cluster-Knoten. Der Master-Knoten ist für die Integrität der Core- und Aufgabenknoten sowie für das Abfragen des Auftragsergebnisstatus der Knoten verantwortlich. Die Core- und Aufgabenknoten erledigen die tatsächliche Verarbeitung der Daten. Wenn Sie einen Cluster mit einem Knoten haben, agiert dieser als Master-Knoten und als Core-Knoten.

Der `KeepJobAlive`-Parameter in einer `RunJobFlow`-Anforderung bestimmt, ob der Cluster beendet wird, wenn der Cluster keine auszuführenden Schritte mehr hat. Legen Sie diesen Wert auf `False` fest, wenn Sie wissen, dass der Cluster wie erwartet ausgeführt wird. Bei der Fehlerbehebung des Auftragverlaufs und beim Hinzufügen von Schritten während der ausgesetzten Cluster-Ausführung legen Sie den Wert auf `True` fest. Das reduziert die Zeit und die Kosten für das Hochladen der Ergebnisse in Amazon Simple Storage Service (Amazon S3) der Neustart des Clusters nach dem Bearbeiten eines Schritts müsste wiederholt werden).

Wenn `KeepJobAlive` nach dem erfolgreichen Abschluss der Arbeit eines Clusters `true` ist, müssen Sie eine `TerminateJobFlows`-Anforderung senden. Andernfalls wird der Cluster weiter ausgeführt und generiert AWS-Gebühren.

Weitere Informationen zu den speziellen Eingabeparametern für `RunJobFlow` finden Sie unter RunJobFlow. Weitere Informationen zu den grundlegenden Parametern in der Anfrage finden Sie unter Allgemeine Anforderungsparameter.

Availability Zones in Amazon EMR

Amazon EMR arbeitet mit EC2-Instances als Knoten zur Cluster-Verarbeitung. Diese EC2-Instances arbeiten mit Standorten, die aus Regionen und Availability Zones bestehen. Regionen sind verteilt und befinden sich in unterschiedlichen geografischen Zonen. Availability Zones sind eigenständige Standorte innerhalb einer Region, die von Ausfällen anderen Availability Zones isoliert sind. Jede Availability Zone bietet eine kostengünstige Netzwerkkonnektivität mit geringer Latenz zu anderen Availability Zones in der gleichen Region. Eine Liste der Regionen und Endpunkte für Amazon EMR finden Sie unter Regionen und Endpunkte in der Allgemeine Amazon Web Services-Referenz.

Der `AvailabilityZone`-Parameter gibt den grundlegenden Speicherort des Clusters an. Dieser Parameter ist optional. Wir empfehlen seine Verwendung. Wenn `AvailabilityZone` nicht angegeben ist, wählt Amazon EMR automatisch den besten `AvailabilityZone`-Wert für den Cluster aus. Der Parameter kann z. B. dann nützlich sein, wenn Sie Ihre Instances mit anderen aktiven Instances gemeinsam platzieren möchten und Ihr Cluster Daten aus diesen Instances lesen oder schreiben muss. Weitere Informationen finden Sie im Amazon-EC2-Benutzerhandbuch für Linux-Instances.

So verwenden Sie weitere Dateien und Bibliotheken in Amazon-EMR-Clustern

Es kann vorkommen, dass Sie weiteren Dateien oder benutzerdefinierte Bibliotheken für Ihre Mapper oder Reducer-Anwendungen verwenden möchten. Sie können beispielsweise eine Bibliothek nutzen, die eine PDF-Datei in eine Textdatei konvertiert.

So speichern Sie eine Datei für den Mapper oder Reducer bei der Verwendung von Hadoop-Streaming zwischen

- Fügen Sie im JAR-`args`-Feld das folgende Argument hinzu:

```
-cacheFile s3://bucket/path_to_executable#local_path
```

Die Datei (`local_path`) befindet sich im Arbeitsverzeichnis des Mappers. Dieser kann auf die Datei verweisen.

So verwenden Sie SDKs zum Aufrufen von Amazon-EMR-APIs

Themen

- So erstellen Sie einen Amazon-EMR-Cluster mit der AWS SDK for Java

Die AWS-SDKs stellen Wrapper-Funktionen für die API bereit und übernehmen viele der Verbindungsdetails, wie Berechnen der Signaturen, Umgang mit Anforderungswiederholungen und Fehlerbehandlung. Die SDKs enthalten außerdem Beispiel-Code, Tutorials und weitere Ressourcen, die Sie beim Schreiben von Anwendungen unterstützen. die AWS aufrufen. Durch Aufrufen der Wrapper-Funktionen in einem SDK kann der Prozess zum Schreiben einer AWS-Anwendung erheblich vereinfacht werden.

Weitere Informationen zum Herunterladen und Verwenden der AWS-SDKs finden Sie in den SDKs unter Tools für Amazon Web Services.

So erstellen Sie einen Amazon-EMR-Cluster mit der AWS SDK for Java

Das AWS SDK for Java bietet drei Pakete mit Amazon-EMR-Funktionen:

- com.amazonaws.services.elasticmapreduce
- com.amazonaws.services.elasticmapreduce.model
- com.amazonaws.services.elasticmapreduce.util

Weitere Informationen zu diesen Paketen finden Sie in der AWS SDK for Java-API-Referenz.

Das folgende Beispiel veranschaulicht, wie die SDKs die Programmierung mit Amazon EMR vereinfachen. Das folgende Codebeispiel verwendet das `StepFactory`-Objekt (eine Hilfsklasse zum Erstellen von typischen Amazon-EMR-Schritttypen) zum Erstellen eines interaktiven Hive-Clusters mit aktiviertem Debugging.

```
import com.amazonaws.AmazonClientException;
import com.amazonaws.auth.AWSCredentials;
import com.amazonaws.auth.AWSStaticCredentialsProvider;
import com.amazonaws.auth.profile.ProfileCredentialsProvider;
```

```
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduce;
import com.amazonaws.services.elasticmapreduce.AmazonElasticMapReduceClientBuilder;
import com.amazonaws.services.elasticmapreduce.model.*;
import com.amazonaws.services.elasticmapreduce.util.StepFactory;

public class Main {

 public static void main(String[] args) {
  AWSCredentialsProvider profile = null;
  try {
   credentials_profile = new ProfileCredentialsProvider("default"); // specifies any
 named profile in .aws/credentials as the credentials provider
       } catch (Exception e) {
           throw new AmazonClientException(
                   "Cannot load credentials from .aws/credentials file. " +
                   "Make sure that the credentials file exists and that the profile
 name is defined within it.",
                   e);
       }

  // create an EMR client using the credentials and region specified in order to create
 the cluster
  AmazonElasticMapReduce emr = AmazonElasticMapReduceClientBuilder.standard()
   .withCredentials(credentials_profile)
   .withRegion(Regions.US_WEST_1)
   .build();

       // create a step to enable debugging in the AWS Management Console
  StepFactory stepFactory = new StepFactory();
  StepConfig enabledebugging = new StepConfig()
      .withName("Enable debugging")
      .withActionOnFailure("TERMINATE_JOB_FLOW")
      .withHadoopJarStep(stepFactory.newEnableDebuggingStep());

       // specify applications to be installed and configured when EMR creates the
 cluster
  Application hive = new Application().withName("Hive");
  Application spark = new Application().withName("Spark");
  Application ganglia = new Application().withName("Ganglia");
  Application zeppelin = new Application().withName("Zeppelin");

  // create the cluster
  RunJobFlowRequest request = new RunJobFlowRequest()
          .withName("MyClusterCreatedFromJava")
```

```
          .withReleaseLabel("emr-5.20.0") // specifies the EMR release version label,
 we recommend the latest release
          .withSteps(enabledebugging)
          .withApplications(hive,spark,ganglia,zeppelin)
          .withLogUri("s3://path/to/my/emr/logs") // a URI in S3 for log files is
 required when debugging is enabled
          .withServiceRole("EMR_DefaultRole") // replace the default with a custom IAM
 service role if one is used
          .withJobFlowRole("EMR_EC2_DefaultRole") // replace the default with a custom
 EMR role for the EC2 instance profile if one is used
          .withInstances(new JobFlowInstancesConfig()
              .withEc2SubnetId("subnet-12ab34c56")
              .withEc2KeyName("myEc2Key")
              .withInstanceCount(3)
              .withKeepJobFlowAliveWhenNoSteps(true)
              .withMasterInstanceType("m4.large")
              .withSlaveInstanceType("m4.large"));

    RunJobFlowResult result = emr.runJobFlow(request);
    System.out.println("The cluster ID is " + result.toString());

 }

}
```

Sie müssen mindestens eine Service-Rolle und eine jobflow-Rolle entsprechend der EMR_DefaultRole und EMR_EC2_DefaultRole übergeben. Sie können dies durch Aufrufen dieses AWS CLI-Befehls für das gleiche Konto erledigen. Überprüfen Sie zuerst, ob die Rollen bereits vorhanden sind:

```
aws iam list-roles | grep EMR
```

Sowohl die Instance-Profil- (EMR_EC2_DefaultRole) als auch die Service-Rolle (EMR_DefaultRole) werden angezeigt, falls sie vorhanden sind:

```
"RoleName": "EMR_DefaultRole",
            "Arn": "arn:aws:iam::AccountID:role/EMR_DefaultRole"
            "RoleName": "EMR_EC2_DefaultRole",
            "Arn": "arn:aws:iam::AccountID:role/EMR_EC2_DefaultRole"
```

Wenn die Standardrollen nicht vorhanden sind, können Sie sie über den folgenden Befehl erstellen:

```
aws emr create-default-roles
```

Amazon EMR Service Quotas verwalten

Themen

- Was sind Amazon EMR Service Quotas?
- Amazon EMR Service Quotas verwalten
- Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden

Die Themen in diesem Abschnitt beschreiben EMR Service Quotas (früher als Service Limits bezeichnet), wie man sie im AWS Management Console verwaltet und wann es vorteilhaft ist, CloudWatch-Ereignisse anstelle von Service Quotas zu verwenden, um Cluster zu überwachen und Aktionen auszulösen.

Was sind Amazon EMR Service Quotas?

Das AWS-Konto verfügt über Service Quotas, früher als Limits bezeichnet, für jeden AWS-Service. Für den EMR-Service gibt es zwei Arten von Grenzwerten:

- Ressourcenbeschränkungen – Sie können EMR verwenden, um EC2-Ressourcen zu erstellen. Diese EC2-Ressourcen unterliegen jedoch Service Quotas. Die Ressourcenbeschränkungen in dieser Kategorie sind:
  - Die maximale Anzahl der aktiven Cluster, die gleichzeitig ausgeführt werden können.
  - Die maximale Anzahl aktiver Instances pro Instance-Gruppe.
- Limits für APIs – Bei der Verwendung von EMR-APIs gibt es zwei Arten von Einschränkungen:
  - Burst-Limit – Dies ist die maximale Anzahl von API-Aufrufen, die Sie gleichzeitig tätigen können. Beispielsweise ist die maximale Anzahl von AddInstanceFleet-API-Anforderungen, die Sie pro Sekunde machen können, standardmäßig auf 5 Aufrufe/Sekunde festgelegt. Dies bedeutet, dass das Burst-Limit der AddInstanceFleet-API bei 5 Aufrufen/Sekunde liegt oder dass Sie zu einem bestimmten Zeitpunkt maximal 5 AddInstanceFleet-API-Aufrufe durchführen können. Nachdem Sie das Burst-Limit verwendet haben, sind Ihre nachfolgenden Aufrufe jedoch durch das Ratenlimit begrenzt.
  - Ratenlimit – Dies ist die Wiederauffüllrate der Burst-Kapazität der API. Beispielsweise ist die Wiederauffüllrate von AddInstanceFleet-Aufrufen standardmäßig auf 0,5 Aufrufe/Sekunde

festgelegt. Das bedeutet, dass Sie, nachdem Sie das Burst-Limit erreicht haben, mindestens 2 Sekunden warten müssen (0,5 Aufrufe/Sekunde X 2 Sekunden = 1 Anruf), um den API-Aufruf zu tätigen. Wenn Sie vorher einen Aufruf tätigen, werden Sie vom EMR-Webservice gedrosselt. Zu jedem Zeitpunkt können Sie nur so viele Aufrufe tätigen, wie die Burst-Kapazität ausreicht, ohne dass dies gedrosselt wird. Mit jeder weiteren Sekunde, die Sie warten, erhöht sich Ihre Burst-Kapazität um 0,5 Aufrufe, bis sie das maximale Limit von 5, dem Burst-Limit, erreicht.

Amazon EMR Service Quotas verwalten

Service Quotas sind ein AWS-Feature, mit dem Sie Ihre Amazon EMR Service Quotas oder Limits von einem zentralen Ort aus anzeigen und verwalten können, indem Sie AWS Management Console, die API oder die CLI verwenden. Weitere Informationen zum Anzeigen von Quotas und zum Beantragen einer Erhöhung finden Sie unter AWS-Service Quotas in der Allgemeine Amazon Web Services-Referenz.

Für einige APIs ist die Einrichtung eines CloudWatch-Ereignisses möglicherweise eine bessere Option als die Erhöhung der Service Quotas. Sie können auch Zeit sparen, indem Sie CloudWatch verwenden, um Alarme einzustellen und Erhöhungsanforderungen proaktiv auszulösen, bevor Sie das Service Quota erreichen. Weitere Details finden Sie unter Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden.

Wann sollten EMR-Ereignisse in CloudWatch eingerichtet werden

Bei einigen Polling-APIs, wie DescribeCluster, DescribeStep und ListClusters, kann die Einrichtung eines CouldWatch-Ereignisses die Reaktionszeit auf Änderungen reduzieren und Ihre Service Quotas freisetzen. Wenn Sie beispielsweise eine Lambda-Funktion so eingerichtet haben, dass sie ausgeführt wird, wenn sich der Status eines Clusters ändert, z. B. wenn ein Schritt abgeschlossen oder ein Cluster beendet wird, können Sie diesen Auslöser verwenden, um die nächste Aktion in Ihrem Workflow zu starten, anstatt auf die nächste Abfrage zu warten. Andernfalls, wenn Sie über dedizierte Amazon-EC2-Instances oder Lambda-Funktionen verfügen, die ständig die EMR-API nach Änderungen abfragen, verschwenden Sie nicht nur Rechenressourcen, sondern könnten auch Ihr Service Quota erreichen.

Im Folgenden sind einige Fälle aufgeführt, in denen Sie von einer Umstellung auf eine ereignisgesteuerte Architektur profitieren könnten.

Fall 1: Beim Abfragen von EMR mithilfe der DescribeCluster-API ist der Abschluss der einzelnen Schritte erforderlich

Example Beim Abfragen von EMR mithilfe der DescribeCluster-API ist der Abschluss der einzelnen Schritte erforderlich

Ein gängiges Muster besteht darin, einen Schritt an einen laufenden Cluster zu senden und Amazon EMR nach dem Status des Schritts abzufragen, in der Regel mithilfe der DescribeCluster- oder DescribeStep-APIs. Diese Aufgabe kann auch mit minimaler Verzögerung erledigt werden, indem Sie sich in das Amazon-EMR-Schrittstatusänderungsereignis einklinken.

Dieses Ereignis enthält die folgenden Informationen in seiner Nutzlast.

```
{
  "version": "0",
  "id": "999cccaa-eaaa-0000-1111-123456789012",
  "detail-type": "EMR Step Status Change",
  "source": "aws.emr",
  "account": "123456789012",
  "time": "2016-12-16T20:53:09Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
    "severity": "ERROR",
    "actionOnFailure": "CONTINUE",
    "stepId": "s-ZYXWVUTSRQPON",
    "name": "CustomJAR",
    "clusterId": "j-123456789ABCD",
    "state": "FAILED",
    "message": "Step s-ZYXWVUTSRQPON (CustomJAR) in Amazon EMR cluster j-123456789ABCD
 (Development Cluster) failed at 2016-12-16 20:53 UTC."
  }
}
```

In der Detailmap könnte eine Lambda-Funktion nach „state“, „stepId“ oder „clusterId“ suchen, um relevante Informationen zu finden.

Fall 2: EMR nach verfügbaren Clustern abfragen, um Workflows auszuführen

Example EMR nach verfügbaren Clustern abfragen, um Workflows auszuführen

Ein Muster für Kunden, die mehrere Cluster ausführen, besteht darin, Workflows auf Clustern auszuführen, sobald sie verfügbar sind. Wenn viele Cluster ausgeführt werden und ein Workflow auf einem wartenden Cluster ausgeführt werden muss, könnte ein Muster darin bestehen, EMR mithilfe von DescribeCluster- oder ListClusters-API-Aufrufen nach verfügbaren Clustern abzufragen. Eine weitere Möglichkeit, die Verzögerung zu verringern, wenn Sie wissen, wann ein Cluster für einen Schritt bereit ist, besteht darin, das Amazon-EMR-Cluster-Statusänderungsereignis in zu verarbeiten.

Dieses Ereignis enthält die folgenden Informationen in seiner Nutzlast.

```
{
  "version": "0",
  "id": "999cccaa-eaaa-0000-1111-123456789012",
  "detail-type": "EMR Cluster State Change",
  "source": "aws.emr",
  "account": "123456789012",
  "time": "2016-12-16T20:43:05Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
    "severity": "INFO",
    "stateChangeReason": "{\"code\":\"\"}",
    "name": "Development Cluster",
    "clusterId": "j-123456789ABCD",
    "state": "WAITING",
    "message": "Amazon EMR cluster j-123456789ABCD ..."
  }
}
```

Für dieses Ereignis könnte eine Lambda-Funktion eingerichtet werden, um einen wartenden Workflow sofort an einen Cluster zu senden, sobald sich sein Status in WAITING ändert.

Fall 3: EMR nach Cluster-Terminierung abfragen

Example EMR nach Cluster-Terminierung abfragen

Kunden, die viele EMR-Cluster betreiben, fragen häufig bei Amazon EMR nach beendeten Clustern ab, sodass keine Arbeit mehr an Amazon EMR gesendet wird. Sie können dieses Muster mit den

API-Aufrufen DescribeCluster und ListClusters oder mithilfe des Cluster-Statusänderungs-Ereignisses von Amazon EMR implementieren.

Nach der Clusterbeendigung sieht das ausgegebene Ereignis wie im folgenden Beispiel aus.

```
{
  "version": "0",
  "id": "1234abb0-f87e-1234-b7b6-000000123456",
  "detail-type": "EMR Cluster State Change",
  "source": "aws.emr",
  "account": "123456789012",
  "time": "2016-12-16T21:00:23Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
    "severity": "INFO",
    "stateChangeReason": "{\"code\":\"USER_REQUEST\",\"message\":\"Terminated by user
 request\"}",
    "name": "Development Cluster",
    "clusterId": "j-123456789ABCD",
    "state": "TERMINATED",
    "message": "Amazon EMR Cluster jj-123456789ABCD (Development Cluster) has
 terminated at 2016-12-16 21:00 UTC with a reason of USER_REQUEST."
  }
}
```

Der Abschnitt „Detail“ der Nutzlast enthält die ClusterID und den Status, auf den reagiert werden kann.

AWS-Glossar

Die neueste AWS-Terminologie finden Sie im AWS-Glossar in der AWS-Glossar-Referenz.