



Guide de l'utilisateur Amazon EMR Serverless

# Amazon EMR



# Amazon EMR: Guide de l'utilisateur Amazon EMR Serverless

Copyright © 2024 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Les marques et la présentation commerciale d'Amazon ne peuvent être utilisées en relation avec un produit ou un service qui n'est pas d'Amazon, d'une manière susceptible de créer une confusion parmi les clients, ou d'une manière qui dénigre ou discrédite Amazon. Toutes les autres marques commerciales qui ne sont pas la propriété d'Amazon appartiennent à leurs propriétaires respectifs, qui peuvent ou non être affiliés ou connectés à Amazon, ou sponsorisés par Amazon.

---

# Table of Contents

Qu'est-ce qu'Amazon EMR Serverless ? .....	1
Concepts .....	1
Version de sortie .....	1
Application .....	2
Exécution de tâche .....	3
Workers .....	3
Capacité pré-initialisée .....	3
EMRStudio .....	4
Conditions préalables pour démarrer .....	5
Inscrivez-vous pour un Compte AWS .....	5
Création d'un utilisateur doté d'un accès administratif .....	5
Accorder des autorisations .....	7
Octroi d'un accès par programmation .....	9
Configurez le AWS CLI .....	10
Ouvrez la console .....	11
Premiers pas .....	12
Autorisations .....	12
Stockage .....	12
Charges de travail interactives .....	12
Création d'un rôle d'exécution de tâches .....	13
Démarrage depuis la console .....	18
Étape 1 : Création d'une application .....	18
Étape 2 : Soumettre une exécution de tâche ou une charge de travail interactive .....	19
Étape 3 : Afficher l'interface utilisateur et les journaux de l'application .....	23
Étape 4 : Nettoyer .....	23
Commencer à partir du AWS CLI .....	24
Étape 1 : Création d'une application .....	24
Étape 2 : Soumettre une exécution de tâche .....	25
Étape 3 : Examiner le résultat .....	28
Étape 4 : Nettoyer .....	29
Interaction avec une application .....	31
États de l'application .....	31
Utilisation de la console EMR Studio .....	32
Création d'une application .....	32

Lister les applications .....	34
Gestion des applications .....	34
Utilisation de AWS CLI .....	34
Configuration d'une application .....	35
Comportement des applications .....	36
Capacité pré-initialisée .....	38
Configuration par défaut de l'application .....	41
Personnalisation d'une image .....	47
Prérequis .....	37
Étape 1 : créer une image personnalisée à partir d'images de base EMR sans serveur .....	49
Étape 2 : Valider l'image localement .....	50
Étape 3 : Chargez l'image dans votre ECR référentiel Amazon .....	51
Étape 4 : créer ou mettre à jour une application avec des images personnalisées .....	51
Étape 5 : Autoriser EMR Serverless à accéder au référentiel d'images personnalisé .....	53
Considérations et restrictions .....	54
Configuration de VPC l'accès .....	54
Créer une application .....	54
Configuration de l'application .....	57
Bonnes pratiques pour la planification des sous-réseaux .....	57
Options d'architecture .....	59
Utilisation de l'architecture x86_64 .....	59
Utilisation de l'architecture arm64 (Graviton) .....	60
Lancez de nouvelles applications avec Graviton .....	60
Convertissez des applications existantes en Graviton .....	60
Considérations .....	61
Téléchargement de données .....	63
Prérequis .....	63
Bien démarrer avec S3 Express One Zone .....	64
Exécution de tâches .....	66
États d'exécution de la tâche .....	66
Utilisation de la console EMR Studio .....	68
Envoi d'une tâche .....	68
Afficher les exécutions de tâches .....	70
Utilisation de AWS CLI .....	70
Utilisation de disques optimisés pour le shuffle .....	72
Principaux avantages .....	72

Premiers pas .....	73
Offres d'emploi en streaming .....	77
Considérations et restrictions .....	79
Premiers pas .....	79
Connecteurs de streaming .....	80
Gestion des journaux .....	83
Offres d'emploi Spark .....	83
Paramètres Spark .....	83
Propriétés de Spark .....	87
Exemples Spark .....	93
Offres d'emploi Hive .....	93
Paramètres de la ruche .....	94
Propriétés de la ruche .....	96
Exemples de ruches .....	111
Résilience des tâches .....	112
Surveillance d'une tâche à l'aide d'une politique de relance .....	116
Connexion avec politique de nouvelle tentative .....	116
Configuration du métastore .....	116
Utilisation de AWS Glue Data Catalog sous forme de métastore .....	117
Utilisation d'un métastore Hive externe .....	122
Accès S3 entre comptes .....	127
Prérequis .....	127
Utiliser une politique de compartiment S3 .....	127
Utiliser un rôle assumé .....	128
Exemples de rôles supposés .....	131
Résolution des erreurs .....	135
Erreur : limite dépassée pour la capacité maximale autorisée. ....	136
Erreur : la capacité maximale configurée a été dépassée. Réessayez ultérieurement. ....	136
Erreur : l'accès S3 est refusé. Vérifiez les autorisations d'accès S3 du rôle d'exécution des tâches sur les ressources S3 requises. ....	136
Erreur ModuleNotFoundError : aucun module n'a été nommé<module>. Reportez-vous au guide de l'utilisateur pour savoir comment utiliser les bibliothèques Python avec EMR Serverless. ....	136
Erreur : Impossible d'assumer le rôle d'exécution <role name>car celui-ci n'existe pas ou n'est pas configuré avec la relation de confiance requise. ....	137
Exécution de charges de travail interactives .....	138

Présentation .....	138
Prérequis .....	138
Autorisations .....	139
Configuration .....	140
Considérations .....	140
Exécution de charges de travail interactives via le point de terminaison Apache Livy .....	142
Prérequis .....	142
Autorisations nécessaires .....	142
Premiers pas .....	143
Considérations .....	150
Journalisation et surveillance .....	152
Stockage des journaux .....	152
Stockage géré .....	153
Amazon S3 .....	154
Amazon CloudWatch .....	155
Bûches rotatives .....	158
Chiffrement des journaux .....	159
Stockage géré .....	159
Compartiments Amazon S3 .....	160
Amazon CloudWatch .....	160
Autorisations nécessaires .....	161
Configuration de Log4j2 .....	164
Log4j2 et Spark .....	164
Surveillance .....	168
Candidatures et emplois .....	169
Métriques du moteur Spark .....	177
Métriques d'utilisation .....	182
Automatiser avec EventBridge .....	183
Exemples d'EMR Événements sans serveur EventBridge .....	184
Balisage des ressources .....	187
Qu'est-ce qu'un tag ? .....	187
Balisage de ressources .....	188
Limites relatives au balisage .....	189
Utilisation des tags .....	189
Didacticiels .....	191
Utilisation de Java 17 .....	191

JAVA_HOME .....	191
spark-defaults .....	192
Utiliser Hudi .....	193
Utilisation d'Iceberg .....	194
Utilisation des bibliothèques Python .....	195
Utilisation des fonctionnalités natives de Python .....	195
Création d'un environnement virtuel Python .....	195
Configuration des PySpark tâches pour utiliser les bibliothèques Python .....	197
Utilisation de différentes versions de Python .....	198
Utilisation de Delta Lake OSS .....	199
Amazon EMR versions 6.9.0 et supérieures .....	199
Amazon EMR versions 6.8.0 et antérieures .....	201
Soumission de tâches depuis Airflow .....	202
Utilisation des fonctions définies par l'utilisateur de Hive .....	204
Utilisation d'images personnalisées .....	206
Utiliser une version personnalisée de Python .....	206
Utiliser une version personnalisée de Java .....	207
Créer une image de science des données .....	207
Traitement des données géospatiales avec Apache Sedona .....	208
Utilisation de Spark sur Amazon Redshift .....	208
Lancement d'une application Spark .....	209
Authentification dans Amazon Redshift .....	210
Lecture et écriture vers Amazon Redshift .....	213
Considérations .....	215
Connexion à DynamoDB .....	216
Étape 1 : télécharger sur Amazon S3 .....	216
Étape 2 : Création d'une table Hive .....	217
Étape 3 : Copier vers DynamoDB .....	218
Étape 4 : requête depuis DynamoDB .....	220
Configurer l'accès intercompte .....	222
Considérations .....	224
Sécurité .....	226
Bonnes pratiques de sécurité .....	227
Application du principe du moindre privilège .....	227
Isolation du code d'application non fiable .....	227
Autorisations de contrôle d'accès basées sur les rôles ( ) RBAC .....	227

Protection des données .....	227
Chiffrement au repos .....	229
Chiffrement en transit .....	231
Identity and Access Management (IAM) .....	232
Public ciblé .....	232
Authentification par des identités .....	233
Gestion des accès à l'aide de politiques .....	237
Comment fonctionne EMR Serverless avec IAM .....	240
Utilisation des rôles liés à un service .....	246
Rôles d'exécution des tâches pour Amazon EMR Serverless .....	252
Politiques d'accès des utilisateurs .....	254
Politiques de contrôle d'accès basées sur les balises .....	258
Politiques basées sur l'identité .....	261
Mises à jour des politiques .....	264
Résolution des problèmes .....	265
Lake Formation pour FGAC .....	267
Présentation .....	267
Comment ça marche .....	268
Activer la Formation du Lake .....	270
Activer les autorisations d'exécution .....	271
Configurer les autorisations d'exécution .....	272
Soumission d'une exécution de tâche .....	272
Opérations prises en charge .....	273
Considérations .....	274
Résolution des problèmes .....	276
Chiffrement inter-travailleurs .....	277
Activation du TLS chiffrement mutuel sur EMR Serverless .....	277
Secrets Manager pour la protection des données .....	278
Comment fonctionnent les secrets .....	279
Créer un secret .....	279
Spécifier des références secrètes .....	279
Autoriser l'accès au secret .....	282
Faites pivoter le secret .....	284
Subventions d'accès S3 pour le contrôle de l'accès aux données .....	284
Présentation .....	284
Lancer une application .....	285



Considérations .....	286
CloudTrail pour la journalisation .....	286
EMRInformations sans serveur dans CloudTrail .....	287
Comprendre les EMR entrées des fichiers journaux sans serveur .....	288
Validation de conformité .....	289
Résilience .....	291
Sécurité de l'infrastructure .....	291
Analyse de la configuration et des vulnérabilités .....	292
Points de terminaison et quotas .....	293
Points de terminaison de service .....	293
Quotas de service .....	297
APIlimites .....	298
Autres considérations .....	54
Versions .....	302
EMR Serverless 7.2.0 .....	302
EMR Serverless 7.1.0 .....	303
EMR Serverless 7.0.0 .....	303
EMR Serverless 6,15,0 .....	304
EMR Serverless 6,14.0 .....	304
EMR Serverless 6,13.0 .....	305
EMR Serverless 6,12,0 .....	305
EMR Serverless 6,11,0 .....	305
EMR Serverless 6.10.0 .....	306
EMR Serverless 6,9.0 .....	306
EMR Serverless 6,8.0 .....	307
EMR Serverless 6.7.0 .....	308
Modifications spécifiques au moteur .....	308
EMR Serverless 6.6.0 .....	308
Historique de la documentation .....	310
.....	cccxi

# Qu'est-ce qu'Amazon EMR Serverless ?

Amazon EMR Serverless est une option de déploiement pour Amazon EMR qui fournit un environnement d'exécution sans serveur. Cela simplifie le fonctionnement des applications d'analyse qui utilisent les derniers frameworks open source, tels qu'Apache Spark et Apache Hive. Avec EMR Serverless, vous n'avez pas besoin de configurer, d'optimiser, de sécuriser ou d'exploiter des clusters pour exécuter des applications avec ces frameworks.

Le mode Serverless vous permet d'éviter le surprovisionnement ou le sous-provisionnement des ressources pour vos tâches de traitement des données. EMR Serverless détermine automatiquement les ressources dont l'application a besoin, obtient ces ressources pour traiter vos tâches et libère les ressources une fois les tâches terminées. Pour les cas d'utilisation où les applications ont besoin d'une réponse en quelques secondes, comme l'analyse interactive des données, vous pouvez pré-initialiser les ressources dont l'application a besoin lorsque vous créez l'application.

Avec EMR Serverless, vous continuerez à bénéficier des avantages d'Amazon EMR, tels que la compatibilité open source, la simultanéité et des performances d'exécution optimisées pour les frameworks les plus courants.

EMR Serverless convient aux clients qui souhaitent utiliser facilement des applications à l'aide de frameworks open source. Il permet un démarrage rapide des tâches, une gestion automatique des capacités et un contrôle simple des coûts.

## Concepts

Dans cette section, nous abordons les termes et concepts du EMR sans serveur qui apparaissent tout au long de notre guide de l'utilisateur EMR sans serveur.

### Version de sortie

Une EMR version d'Amazon est un ensemble d'applications open source issues de l'écosystème des mégadonnées. Chaque version inclut différentes applications, composants et fonctionnalités de Big Data que vous sélectionnez pour le déploiement et la configuration de EMR Serverless afin qu'ils puissent exécuter vos applications. Lorsque vous créez une application, vous devez spécifier sa version de publication. Choisissez la EMR version d'Amazon et la version du framework open source que vous souhaitez utiliser dans votre application. Pour en savoir plus sur les versions préliminaires, voir [Versions publiées d'Amazon EMR Serverless](#).

## Application

Avec EMR Serverless, vous pouvez créer une ou plusieurs applications EMR Serverless qui utilisent des frameworks d'analyse open source. Pour créer une application, vous devez spécifier les attributs suivants :

- La EMR version publiée par Amazon pour la version du framework open source que vous souhaitez utiliser. Pour déterminer la version de votre version, voir [Versions publiées d'Amazon EMR Serverless](#).
- Le runtime spécifique que vous souhaitez que votre application utilise, tel qu'Apache Spark ou Apache Hive.

Après avoir créé une candidature, vous pouvez y soumettre des tâches de traitement des données ou des demandes interactives.

Chaque application EMR sans serveur s'exécute sur un Amazon Virtual Private Cloud (VPC) sécurisé, à l'exception des autres applications. De plus, vous pouvez utiliser AWS Identity and Access Management (IAM) politiques pour définir les utilisateurs et les rôles autorisés à accéder à l'application. Vous pouvez également définir des limites pour contrôler et suivre les coûts d'utilisation engagés par l'application.

Envisagez de créer plusieurs applications lorsque vous devez effectuer les opérations suivantes :

- Utilisez différents frameworks open source
- Utilisez différentes versions de frameworks open source pour différents cas d'utilisation
- Effectuez des tests A/B lors de la mise à niveau d'une version à une autre
- Maintenir des environnements logiques distincts pour les scénarios de test et de production
- Fournissez des environnements logiques distincts aux différentes équipes avec des contrôles des coûts et un suivi de l'utilisation indépendants
- Séparez les différentes line-of-business applications

EMRServerless est un service régional qui simplifie la manière dont les charges de travail s'exécutent dans plusieurs zones de disponibilité d'une région. Pour en savoir plus sur l'utilisation des applications avec EMR Serverless, consultez [Interaction avec une application](#).

## Exécution de tâche

Une exécution de tâche est une demande soumise à une application EMR sans serveur que l'application exécute de manière asynchrone et suit jusqu'à son achèvement. Parmi les tâches, citons une requête HiveQL que vous soumettez à une application Apache Hive ou un script de traitement de données que vous soumettez à PySpark une application Apache Spark. Lorsque vous soumettez une tâche, vous devez spécifier un rôle d'exécution, créé dans IAM, que la tâche utilise pour accéder AWS ressources, telles que les objets Amazon S3. Vous pouvez envoyer plusieurs demandes d'exécution de tâche à une application, et chaque exécution de tâche peut utiliser un rôle d'exécution différent pour accéder AWS ressources. Une application EMR sans serveur commence à exécuter des tâches dès qu'elle les reçoit et exécute plusieurs demandes de tâches simultanément. Pour en savoir plus sur la façon dont EMR Serverless exécute les tâches, consultez [Exécution de tâches](#).

## Workers

Une application EMR sans serveur utilise en interne des travailleurs pour exécuter vos charges de travail. Les tailles par défaut de ces travailleurs sont basées sur votre type d'application et sur la EMR version publiée par Amazon. Lorsque vous planifiez l'exécution d'une tâche, vous pouvez modifier ces tailles.

Lorsque vous soumettez une tâche, EMR Serverless calcule les ressources dont l'application a besoin pour la tâche et planifie les travailleurs. EMRServerless décompose vos charges de travail en tâches, télécharge des images, approvisionne et configure les travailleurs, puis les met hors service une fois le travail terminé. EMRServerless augmente ou diminue automatiquement les effectifs en fonction de la charge de travail et du parallélisme requis à chaque étape du travail. Ce dimensionnement automatique vous évite d'avoir à estimer le nombre de travailleurs dont l'application a besoin pour exécuter vos charges de travail.

## Capacité pré-initialisée

EMRServerless fournit une fonctionnalité de capacité pré-initialisée qui permet aux employés de rester initialisés et prêts à répondre en quelques secondes. Cette capacité crée efficacement un bassin de travailleurs chaleureux pour une application. Pour configurer cette fonctionnalité pour chaque application, définissez le `initial-capacity` paramètre d'une application. Lorsque vous configurez une capacité préinitialisée, les tâches peuvent démarrer immédiatement afin que vous puissiez implémenter des applications itératives et des tâches urgentes. Pour en savoir plus sur les travailleurs préinitialisés, consultez. [Configuration d'une application](#)

## EMRStudio

EMRStudio est la console utilisateur que vous pouvez utiliser pour gérer vos applications EMR sans serveur. Si aucun EMR studio n'existe dans votre compte lorsque vous créez votre première application EMR Serverless, nous en créons un automatiquement pour vous. Vous pouvez accéder à EMR Studio soit depuis la EMR console Amazon, soit activer l'accès fédéré depuis votre fournisseur d'identité (IdP) IAM via IAM Identity Center. Dans ce cas, les utilisateurs peuvent accéder à Studio et gérer des applications EMR sans serveur sans accès direct à la EMR console Amazon. Pour en savoir plus sur le fonctionnement des applications EMR sans serveur avec EMR Studio, consultez [Interaction avec votre application depuis la console EMR Studio](#) et [Exécution de tâches depuis la console EMR Studio](#).

# Conditions préalables pour démarrer avec EMR Serverless

## Rubriques

- [Inscrivez-vous pour un Compte AWS](#)
- [Création d'un utilisateur doté d'un accès administratif](#)
- [Accorder des autorisations](#)
- [Installez et configurez AWS CLI](#)
- [Ouvrez la console](#) .

## Inscrivez-vous pour un Compte AWS

Si vous n'avez pas de Compte AWS, procédez comme suit pour en créer un.

Pour vous inscrire à un Compte AWS

1. Ouvrez l'<https://portal.aws.amazon.com/billing/inscription>.
2. Suivez les instructions en ligne.

Dans le cadre de la procédure d'inscription, vous recevrez un appel téléphonique et vous saisirez un code de vérification en utilisant le clavier numérique du téléphone.

Lorsque vous vous inscrivez à un Compte AWS, un Utilisateur racine d'un compte AWS est créé. L'utilisateur root a accès à tous Services AWS et les ressources du compte. La meilleure pratique de sécurité consiste à attribuer un accès administratif à un utilisateur, et à utiliser uniquement l'utilisateur racine pour effectuer les [tâches nécessitant un accès utilisateur racine](#).

AWS vous envoie un e-mail de confirmation une fois le processus d'inscription terminé. À tout moment, vous pouvez consulter l'activité actuelle de votre compte et gérer votre compte en accédant à <https://aws.amazon.com/> et en choisissant Mon compte.

## Création d'un utilisateur doté d'un accès administratif

Une fois que vous vous êtes inscrit à un Compte AWS, sécurisez votre Utilisateur racine d'un compte AWS, activez AWS IAM Identity Center, et créez un utilisateur administratif afin de ne pas utiliser l'utilisateur root pour les tâches quotidiennes.

## Sécurisez votre Utilisateur racine d'un compte AWS

1. Connectez-vous au [AWS Management Console](#) en tant que propriétaire du compte en choisissant Utilisateur root et en saisissant votre Compte AWS adresse e-mail. Sur la page suivante, saisissez votre mot de passe.

Pour obtenir de l'aide pour vous connecter à l'aide de l'utilisateur root, consultez [la section Connexion en tant qu'utilisateur root](#) dans Connexion à AWS Guide de l'utilisateur

2. Activez l'authentification multifactorielle (MFA) pour votre utilisateur root.

Pour obtenir des instructions, voir [Activer un MFA appareil virtuel pour votre Compte AWS utilisateur root \(console\)](#) dans le guide de IAM l'utilisateur.

## Création d'un utilisateur doté d'un accès administratif

1. Activez IAM Identity Center.

Pour obtenir des instructions, voir [Activation AWS IAM Identity Center](#) dans le .AWS IAM Identity Center Guide de l'utilisateur

2. Dans IAM Identity Center, accordez un accès administratif à un utilisateur.

Pour un didacticiel sur l'utilisation du Répertoire IAM Identity Center comme source d'identité, voir [Configurer l'accès utilisateur avec la valeur par défaut Répertoire IAM Identity Center](#) dans le .AWS IAM Identity Center Guide de l'utilisateur

## Connexion en tant qu'utilisateur doté d'un accès administratif

- Pour vous connecter avec votre utilisateur IAM Identity Center, utilisez l'URL identifiant envoyé à votre adresse e-mail lorsque vous avez créé l'utilisateur IAM Identity Center.

Pour obtenir de l'aide pour vous connecter à l'aide d'un utilisateur d'IAM Identity Center, consultez la section [Connexion au AWS portail d'accès](#) dans le Connexion à AWS Guide de l'utilisateur

## Attribution d'un accès à d'autres utilisateurs

1. Dans IAM Identity Center, créez un ensemble d'autorisations conforme à la meilleure pratique consistant à appliquer les autorisations du moindre privilège.

Pour obtenir des instructions, voir [Créer un ensemble d'autorisations](#) dans le AWS IAM Identity Center Guide de l'utilisateur

2. Attribuez des utilisateurs à un groupe, puis attribuez un accès par authentification unique au groupe.

Pour obtenir des instructions, voir [Ajouter des groupes](#) dans le AWS IAM Identity Center Guide de l'utilisateur

## Accorder des autorisations

Dans les environnements de production, nous vous recommandons d'utiliser des politiques plus précises. Pour des exemples de telles politiques, voir [Exemples de politiques d'accès utilisateur pour EMR Serverless](#). Pour en savoir plus sur la gestion des accès, voir Gestion des [accès pour AWS ressources](#) du guide de IAM l'utilisateur.

Pour les utilisateurs qui ont besoin de démarrer avec EMR Serverless dans un environnement sandbox, utilisez une politique similaire à la suivante :

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EMRStudioCreate",
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:CreateStudioPresignedUrl",
        "elasticmapreduce:DescribeStudio",
        "elasticmapreduce:CreateStudio",
        "elasticmapreduce:ListStudios"
      ],
      "Resource": "*"
    },
    {
      "Sid": "EMRServerlessFullAccess",
      "Effect": "Allow",
      "Action": [
        "emr-serverless:*"
      ],
      "Resource": "*"
    }
  ],
}
```



```

    {
      "Sid": "AllowEC2ENICreationWithEMRTags",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface"
      ],
      "Resource": [
        "arn:aws:ec2:*:*:network-interface/*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:CalledViaLast": "ops.emr-serverless.amazonaws.com"
        }
      }
    },
    {
      "Sid": "AllowEMRServerlessServiceLinkedRoleCreation",
      "Effect": "Allow",
      "Action": "iam:CreateServiceLinkedRole",
      "Resource": "arn:aws:iam:*:*:role/aws-service-role/*"
    }
  ]
}

```

Pour activer l'accès, ajoutez des autorisations à vos utilisateurs, groupes ou rôles :

- Utilisateurs et groupes dans AWS IAM Identity Center:

Créez un jeu d'autorisations. Suivez les instructions de la [section Créer un ensemble d'autorisations](#) dans le AWS IAM Identity Center Guide de l'utilisateur

- Utilisateurs gérés IAM par le biais d'un fournisseur d'identité :

Créez un rôle pour la fédération d'identité. Suivez les instructions de la [section Création d'un rôle pour un fournisseur d'identité tiers \(fédération\)](#) dans le guide de IAM l'utilisateur.

- IAMutilisateurs :

- Créez un rôle que votre utilisateur peut assumer. Suivez les instructions de la section [Création d'un rôle pour un IAM utilisateur](#) dans le Guide de IAM l'utilisateur.
- (Non recommandé) Attachez une politique directement à un utilisateur ou ajoutez un utilisateur à un groupe d'utilisateurs. Suivez les instructions de la [section Ajouter des autorisations à un utilisateur \(console\)](#) dans le guide de IAM l'utilisateur.

## Octroi d'un accès par programmation

Les utilisateurs ont besoin d'un accès programmatique s'ils souhaitent interagir avec AWS à l'extérieur du AWS Management Console. La manière d'accorder un accès programmatique dépend du type d'utilisateur qui accède AWS.

Pour accorder aux utilisateurs un accès programmatique, choisissez l'une des options suivantes.

Quel utilisateur a besoin d'un accès programmatique ?	Pour	Par
Identité de la main-d'œuvre (Utilisateurs gérés dans IAM Identity Center)	Utilisez des informations d'identification temporaires pour signer les demandes programmatiques adressées au AWS CLI, AWS SDKs, ou AWS APIs.	Suivez les instructions de l'interface que vous souhaitez utiliser. <ul style="list-style-type: none"> <li>• Pour AWS CLI, voir <a href="#">Configuration du AWS CLI à utiliser AWS IAM Identity Center</a> dans le <a href="#">.AWS Command Line Interface Guide de l'utilisateur</a></li> <li>• Dans AWS SDKs, des outils et AWS APIs, voir <a href="#">Authentification du centre d'IAMidentité</a> dans le <a href="#">AWS SDKset guide de référence sur les outils</a>.</li> </ul>
IAM	Utilisez des informations d'identification temporaires pour signer les demandes programmatiques adressées au AWS CLI, AWS SDKs, ou AWS APIs.	En suivant les instructions de la section <a href="#">Utilisation d'informations d'identification temporaires avec AWS ressources</a> du guide de IAM l'utilisateur.
IAM	(Non recommandé) Utilisez des informations d'identification à long terme	Suivez les instructions de l'interface que vous souhaitez utiliser.

Quel utilisateur a besoin d'un accès programmatique ?	Pour	Par
	<p>pour signer les demandes programmatiques adressées au AWS CLI, AWS SDKs, ou AWS APIs.</p>	<ul style="list-style-type: none"> <li>• Pour AWS CLI, voir <a href="#">Authentification à l'aide des informations IAM d'identification de l'utilisateur</a> dans AWS Command Line Interface Guide de l'utilisateur</li> <li>• Dans AWS SDKset outils, voir <a href="#">Authentification à l'aide d'informations d'identification à long terme</a> dans le AWS SDKset guide de référence sur les outils.</li> <li>• Dans AWS APIs, voir <a href="#">Gestion des clés d'accès pour IAM les utilisateurs</a> dans le Guide de IAM l'utilisateur.</li> </ul>

## Installez et configurez AWS CLI

Si vous souhaitez utiliser EMR ServerlessAPIs, vous devez installer la dernière version du AWS Command Line Interface (AWS CLI). Vous n'avez pas besoin du AWS CLI pour utiliser EMR Serverless depuis la console EMR Studio, et vous pouvez commencer sans cela CLI en suivant les étapes décrites dans [Commencer à utiliser EMR Serverless depuis la console](#).

Pour configurer le AWS CLI

1. Pour installer la dernière version du AWS CLI pour macOS, Linux ou Windows, voir [Installation ou mise à jour de la dernière version du AWS CLI](#).
2. Pour configurer le AWS CLI et configuration sécurisée de votre accès à Services AWS, y compris EMR Serverless, voir [Configuration rapide avec aws configure](#).
3. Pour vérifier la configuration, entrez la DataBrew commande suivante à l'invite de commande.

```
aws emr-serverless help
```

AWS CLI les commandes utilisent la valeur par défaut Région AWS depuis votre configuration, sauf si vous l'avez définie avec un paramètre ou un profil. Pour configurer votre Région AWS avec un paramètre, vous pouvez ajouter le `--region` paramètre à chaque commande.

Pour configurer votre Région AWS avec un profil, ajoutez d'abord un profil nommé dans le `~/.aws/config` fichier ou le `%UserProfile%/.aws/config` fichier (pour Microsoft Windows). Suivez les étapes décrites dans la section Profils [nommés pour AWS CLI](#). Ensuite, définissez votre Région AWS et d'autres paramètres avec une commande similaire à celle de l'exemple suivant.

```
[profile emr-serverless]
aws_access_key_id = ACCESS-KEY-ID-OF-IAM-USER
aws_secret_access_key = SECRET-ACCESS-KEY-ID-OF-IAM-USER
region = us-east-1
output = text
```

## Ouvrez la console .

La plupart des rubriques de cette section consacrées à la console partent de la console [Amazon EMR](#). Si vous n'êtes pas encore connecté à votre Compte AWS, connectez-vous, puis ouvrez la [EMRconsole Amazon](#) et passez à la section suivante pour continuer à utiliser AmazonEMR.

# Commencer à utiliser Amazon EMR Serverless

Ce didacticiel vous aide à démarrer avec EMR Serverless lorsque vous déployez un exemple de charge de travail Spark ou Hive. Vous allez créer, exécuter et déboguer votre propre application. Nous présentons les options par défaut dans la plupart des parties de ce didacticiel.

Avant de lancer une application EMR sans serveur, effectuez les tâches suivantes.

## Rubriques

- [Accorder des autorisations pour utiliser EMR Serverless](#)
- [Préparer le stockage pour le mode EMR Serverless](#)
- [Créer un EMR studio pour exécuter des charges de travail interactives](#)
- [Création d'un rôle d'exécution de tâches](#)
- [Commencer à utiliser EMR Serverless depuis la console](#)
- [Commencer à partir du AWS CLI](#)

## Accorder des autorisations pour utiliser EMR Serverless

Pour utiliser EMR Serverless, vous avez besoin d'un utilisateur ou d'un IAM rôle associé à une politique qui accorde des autorisations pour EMR Serverless. Pour créer un utilisateur et associer la politique appropriée à cet utilisateur, suivez les instructions figurant dans [Accorder des autorisations](#).

## Préparer le stockage pour le mode EMR Serverless

Dans ce didacticiel, vous allez utiliser un compartiment S3 pour stocker les fichiers de sortie et les journaux de l'exemple de charge de travail Spark ou Hive que vous exécuterez à l'aide d'une application EMR sans serveur. Pour créer un bucket, suivez les instructions de la section [Création d'un bucket](#) dans le guide de l'utilisateur de la console Amazon Simple Storage Service. Remplacez toute autre référence *DOC-EXAMPLE-BUCKET* à par le nom du compartiment nouvellement créé.

## Créer un EMR studio pour exécuter des charges de travail interactives

Si vous souhaitez utiliser EMR Serverless pour exécuter des requêtes interactives via des blocs-notes hébergés dans EMR Studio, vous devez spécifier un compartiment S3 et le [rôle de service](#)

[minimum pour que EMR Serverless](#) puisse créer un espace de travail. Pour connaître les étapes de configuration, consultez la section [Configurer un EMR studio](#) dans le guide EMR de gestion Amazon. Pour plus d'informations sur les charges de travail interactives, consultez [Exécutez des charges de travail interactives avec EMR Serverless via Studio EMR](#).

## Création d'un rôle d'exécution de tâches

Les exécutions de tâches dans EMR Serverless utilisent un rôle d'exécution qui fournit des autorisations détaillées à des Services AWS et des ressources au moment de l'exécution. Dans ce didacticiel, un compartiment S3 public héberge les données et les scripts. Le bucket *DOC-EXAMPLE-BUCKET* stocke la sortie.

Pour configurer un rôle d'exécution de tâche, créez d'abord un rôle d'exécution avec une politique de confiance afin que EMR Serverless puisse utiliser le nouveau rôle. Ensuite, associez la politique d'accès S3 requise à ce rôle. Les étapes suivantes vous guident tout au long du processus.

### Console

1. Accédez à la console IAM à l'adresse <https://console.aws.amazon.com/iam/>.
2. Dans le panneau de navigation de gauche, choisissez Rôles.
3. Sélectionnez Créer un rôle.
4. Pour le type de rôle, choisissez Politique de confiance personnalisée et collez la politique de confiance suivante. Cela permet aux tâches soumises à vos applications Amazon EMR Serverless d'accéder à d'autres Services AWS en votre nom.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "emr-serverless.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

5. Choisissez **Suivant** pour accéder à la page **Ajouter des autorisations**, puis choisissez **Créer une politique**.
6. La page **Créer une politique** s'ouvre dans un nouvel onglet. Collez la politique JSON ci-dessous.

**⚠ Important**

Remplacez *DOC-EXAMPLE-BUCKET* dans la politique ci-dessous par le nom réel du bucket créé dans [Préparer le stockage pour le mode EMR Serverless](#). Il s'agit d'une politique de base pour l'accès à S3. Pour d'autres exemples de rôles d'exécution de tâches, voir [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ReadAccessForEMRSamples",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3::*.elasticmapreduce",
        "arn:aws:s3::*.elasticmapreduce/*"
      ]
    },
    {
      "Sid": "FullAccessToOutputBucket",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3::DOC-EXAMPLE-BUCKET",
        "arn:aws:s3::DOC-EXAMPLE-BUCKET/*"
      ]
    }
  ]
}
```

```

    },
    {
      "Sid": "GlueCreateAndReadDataCatalog",
      "Effect": "Allow",
      "Action": [
        "glue:GetDatabase",
        "glue:CreateDatabase",
        "glue:GetDataBases",
        "glue:CreateTable",
        "glue:GetTable",
        "glue:UpdateTable",
        "glue>DeleteTable",
        "glue:GetTables",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:CreatePartition",
        "glue:BatchCreatePartition",
        "glue:GetUserDefinedFunctions"
      ],
      "Resource": ["*"]
    }
  ]
}

```

7. Sur la page Réviser la politique, entrez le nom de votre politique, tel que `EMRServerlessS3AndGlueAccessPolicy`.
8. Actualisez la page de politique d'autorisation de joindre, puis choisissez `EMRServerlessS3AndGlueAccessPolicy`.
9. Dans la page Nom, révision et création, pour Nom du rôle, entrez le nom de votre rôle, par exemple, `EMRServerlessS3RuntimeRole`. Pour créer ce IAM rôle, choisissez `Create role`.

## CLI

1. Créez un fichier nommé `emr-serverless-trust-policy.json` contenant la politique de confiance à utiliser pour le IAM rôle. Le fichier doit contenir la politique suivante.

```

{
  "Version": "2012-10-17",
  "Statement": [{
    "Sid": "EMRServerlessTrustPolicy",
    "Action": "sts:AssumeRole",

```



```

    "Effect": "Allow",
    "Principal": {
      "Service": "emr-serverless.amazonaws.com"
    }
  ]
}

```

2. Créez un IAM rôle nommé `EMRServerlessS3RuntimeRole`. Utilisez la politique de confiance que vous avez créée à l'étape précédente.

```

aws iam create-role \
  --role-name EMRServerlessS3RuntimeRole \
  --assume-role-policy-document file://emr-serverless-trust-policy.json

```

Notez la valeur ARN dans la sortie. Vous utilisez le nouveau rôle lors ARN de la soumission des offres d'emploi, ci-après dénommé *job-role-arn*.

3. Créez un fichier nommé `emr-sample-access-policy.json` qui définit la IAM politique de votre charge de travail. Cela fournit un accès en lecture au script et aux données stockées dans des compartiments S3 publics et un accès en lecture-écriture à *DOC-EXAMPLE-BUCKET*

#### Important

Remplacez *DOC-EXAMPLE-BUCKET* dans la politique ci-dessous par le nom réel du bucket créé dans [Préparer le stockage pour le mode EMR Serverless](#). Il s'agit d'une politique de base pour AWS Accès à Glue et S3. Pour d'autres exemples de rôles d'exécution de tâches, voir [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ReadAccessForEMRSamples",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ]
    }
  ]
}

```

```

    ],
    "Resource": [
        "arn:aws:s3::*.elasticmapreduce",
        "arn:aws:s3::*.elasticmapreduce/*"
    ]
  },
  {
    "Sid": "FullAccessToOutputBucket",
    "Effect": "Allow",
    "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket",
        "s3:DeleteObject"
    ],
    "Resource": [
        "arn:aws:s3::DOC-EXAMPLE-BUCKET",
        "arn:aws:s3::DOC-EXAMPLE-BUCKET/*"
    ]
  },
  {
    "Sid": "GlueCreateAndReadDataCatalog",
    "Effect": "Allow",
    "Action": [
        "glue:GetDatabase",
        "glue:CreateDatabase",
        "glue:GetDataBases",
        "glue:CreateTable",
        "glue:GetTable", Understanding default application behavior,
        including auto-start and auto-stop, as well as maximum capacity and worker
        configurations for configuring an application with &EMRServerless;.
        "glue:UpdateTable",
        "glue:DeleteTable",
        "glue:GetTables",
        "glue:GetPartition",
        "glue:GetPartitions",
        "glue:CreatePartition",
        "glue:BatchCreatePartition",
        "glue:GetUserDefinedFunctions"
    ],
    "Resource": ["*"]
  }
]

```

```
}
```

4. Créez une IAM politique nommée `EMRServerlessS3AndGlueAccessPolicy` avec le fichier de stratégie que vous avez créé à l'étape 3. Prenez note de ce qui ARN se trouve dans le résultat, car vous utiliserez ARN celui de la nouvelle politique à l'étape suivante.

```
aws iam create-policy \  
  --policy-name EMRServerlessS3AndGlueAccessPolicy \  
  --policy-document file://emr-sample-access-policy.json
```

Notez que la nouvelle politique apparaît ARN dans le résultat. Vous le remplacerez *policy-arn* à l'étape suivante.

5. Attachez la IAM politique `EMRServerlessS3AndGlueAccessPolicy` au rôle d'exécution du job `EMRServerlessS3RuntimeRole`.

```
aws iam attach-role-policy \  
  --role-name EMRServerlessS3RuntimeRole \  
  --policy-arn policy-arn
```

## Commencer à utiliser EMR Serverless depuis la console

### Étapes à suivre

- [Étape 1 : Création d'une application EMR sans serveur](#)
- [Étape 2 : Soumettre une exécution de tâche ou une charge de travail interactive](#)
- [Étape 3 : Afficher l'interface utilisateur et les journaux de l'application](#)
- [Étape 4 : Nettoyer](#)

### Étape 1 : Création d'une application EMR sans serveur

Créez une nouvelle application avec EMR Serverless comme suit.

1. Connectez-vous au AWS Management Console et ouvrez la EMR console Amazon à l'adresse <https://console.aws.amazon.com/emr>.
2. Dans le volet de navigation de gauche, choisissez `EMRServerless` pour accéder à la page d'accueil EMR Serverless.

3. Pour créer ou gérer des applications EMR sans serveur, vous avez besoin de l'interface utilisateur de EMR Studio.
  - Si vous possédez déjà un EMR studio dans Région AWS où vous souhaitez créer une application, puis sélectionnez Gérer les applications pour accéder à votre EMR studio, ou sélectionnez le studio que vous souhaitez utiliser.
  - Si vous n'avez pas de EMR studio dans Région AWS où vous souhaitez créer une application, choisissez Commencer, puis Choisissez Créer et lancez Studio. EMRServerless crée un EMR studio pour vous afin que vous puissiez créer et gérer des applications.
4. Dans l'interface utilisateur de Create studio qui s'ouvre dans un nouvel onglet, entrez le nom, le type et la version de publication de votre application. Si vous souhaitez uniquement exécuter des tâches par lots, sélectionnez Utiliser les paramètres par défaut pour les tâches par lots uniquement. Pour les charges de travail interactives, sélectionnez Utiliser les paramètres par défaut pour les charges de travail interactives. Vous pouvez également exécuter des tâches par lots sur des applications interactives grâce à cette option. Si nécessaire, vous pouvez modifier ces paramètres ultérieurement.

Pour plus d'informations, voir [Création d'un studio](#).
5. Sélectionnez Créer une application pour créer votre première application.

Passez à la section suivante [Étape 2 : Soumettre une exécution de tâche ou une charge de travail interactive](#) pour soumettre une exécution de tâche ou une charge de travail interactive.

## Étape 2 : Soumettre une exécution de tâche ou une charge de travail interactive

### Spark job run

Dans ce didacticiel, nous utilisons un PySpark script pour calculer le nombre d'occurrences de mots uniques dans plusieurs fichiers texte. Un compartiment S3 public en lecture seule stocke à la fois le script et le jeu de données.

Pour exécuter une tâche Spark

1. Téléchargez l'exemple de script `wordcount.py` dans votre nouveau compartiment à l'aide de la commande suivante.

```
aws s3 cp s3://us-east-1.elasticmapreduce/emr-containers/samples/wordcount/
scripts/wordcount.py s3://DOC-EXAMPLE-BUCKET/scripts/
```

2. Si vous terminez, vous [Étape 1 : Création d'une application EMR sans serveur](#) accédez à la page des détails de l'application dans EMR Studio. Là, choisissez l'option Soumettre le travail.
3. Sur la page Soumettre une tâche, effectuez les opérations suivantes.
  - Dans le champ Nom, entrez le nom que vous souhaitez appeler votre tâche exécutée.
  - Dans le champ Rôle d'exécution, entrez le nom du rôle que vous avez créé [Création d'un rôle d'exécution de tâches](#).
  - Dans le champ Emplacement du script `s3://DOC-EXAMPLE-BUCKET/scripts/wordcount.py`, saisissez S3URI.
  - Dans le champ Arguments du script, entrez `["s3://DOC-EXAMPLE-BUCKET/emr-serverless-spark/output"]`.
  - Dans la section des propriétés de Spark, choisissez Modifier sous forme de texte et entrez les configurations suivantes.

```
--conf spark.executor.cores=1 --conf spark.executor.memory=4g --
conf spark.driver.cores=1 --conf spark.driver.memory=4g --conf
spark.executor.instances=1
```

4. Pour démarrer l'exécution de la tâche, choisissez Soumettre la tâche.
5. Dans l'onglet Exécutions de tâches, vous devriez voir votre nouvelle tâche exécutée avec le statut En cours d'exécution.

## Hive job run

Dans cette partie du didacticiel, nous créons une table, insérons quelques enregistrements et exécutons une requête d'agrégation de comptes. Pour exécuter la tâche Hive, créez d'abord un fichier contenant toutes les requêtes Hive à exécuter dans le cadre d'une tâche unique, téléchargez le fichier sur S3 et spécifiez ce chemin S3 au démarrage de la tâche Hive.

### Pour exécuter une tâche Hive

1. Créez un fichier appelé `hive-query.q1` contenant toutes les requêtes que vous souhaitez exécuter dans votre tâche Hive.

```
create database if not exists emrserverless;
use emrserverless;
create table if not exists test_table(id int);
drop table if exists Values__Tmp__Table__1;
insert into test_table values (1),(2),(2),(3),(3),(3);
select id, count(id) from test_table group by id order by id desc;
```

2. `hive-query.q1` Téléchargez-le dans votre compartiment S3 à l'aide de la commande suivante.

```
aws s3 cp hive-query.q1 s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-
query.q1
```

3. Si vous terminez, vous [Étape 1 : Création d'une application EMR sans serveur](#) accédez à la page des détails de l'application dans EMR Studio. Là, choisissez l'option Soumettre le travail.
4. Sur la page Soumettre une tâche, effectuez les opérations suivantes.
  - Dans le champ Nom, entrez le nom que vous souhaitez appeler votre tâche exécutée.
  - Dans le champ Rôle d'exécution, entrez le nom du rôle que vous avez créé [Création d'un rôle d'exécution de tâches](#).
  - Dans le champ Emplacement du scripts `s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-query.q1`, saisissez S3URI.
  - Dans la section Propriétés de la ruche, choisissez Modifier sous forme de texte et entrez les configurations suivantes.

```
--hiveconf hive.log.explain.output=false
```

- Dans la section Configuration du Job, choisissez Modifier sous JSON, puis entrez ce qui suit JSON.

```
{
  "applicationConfiguration":
  [
    {
      "classification": "hive-site",
      "properties": {
        "hive.exec.scratchdir": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-
hive/hive/scratch",
```

```
        "hive.metastore.warehouse.dir": "s3://DOC-EXAMPLE-BUCKET/emr-  
serverless-hive/hive/warehouse",  
        "hive.driver.cores": "2",  
        "hive.driver.memory": "4g",  
        "hive.tez.container.size": "4096",  
        "hive.tez.cpu.vcores": "1"  
    }  
}]  
}
```

5. Pour démarrer l'exécution de la tâche, choisissez Soumettre la tâche.
6. Dans l'onglet Exécutions de tâches, vous devriez voir votre nouvelle tâche exécutée avec le statut En cours d'exécution.

## Interactive workload

Avec Amazon EMR 6.14.0 et versions ultérieures, vous pouvez utiliser des blocs-notes hébergés dans EMR Studio pour exécuter des charges de travail interactives pour Spark en mode Serverless. EMR Pour plus d'informations, notamment sur les autorisations et les conditions requises, consultez [Exécutez des charges de travail interactives avec EMR Serverless via Studio EMR](#).

Une fois que vous avez créé votre application et configuré les autorisations requises, procédez comme suit pour exécuter un bloc-notes interactif avec EMR Studio :

1. Accédez à l'onglet Espaces de travail dans EMR Studio. Si vous devez toujours configurer un emplacement de stockage Amazon S3 et un [rôle de service EMR Studio](#), sélectionnez le bouton Configurer le studio dans la bannière en haut de l'écran.
2. Pour accéder à un bloc-notes, sélectionnez un espace de travail ou créez-en un nouveau. Utilisez le lancement rapide pour ouvrir votre espace de travail dans un nouvel onglet.
3. Accédez à l'onglet qui vient d'être ouvert. Sélectionnez l'icône Calculer dans le menu de navigation de gauche. Sélectionnez EMR Serverless comme type de calcul.
4. Sélectionnez l'application interactive que vous avez créée dans la section précédente.
5. Dans le champ Rôle d'exécution, entrez le nom du IAM rôle que votre application EMR Serverless peut assumer pour l'exécution de la tâche. Pour en savoir plus sur les rôles d'exécution, consultez la section [Rôles d'exécution Job](#) dans le guide de l'utilisateur Amazon EMR Serverless.

6. Sélectionnez Joindre. Cela peut prendre jusqu'à une minute. La page sera actualisée une fois jointe.
7. Choisissez un noyau et lancez un bloc-notes. Vous pouvez également consulter des exemples de blocs-notes sur EMR Serverless et les copier dans votre espace de travail. Pour accéder aux exemples de blocs-notes, accédez au {...} menu de navigation de gauche et parcourez les blocs-notes dont le nom de fichier est indiqué `serverless` dans le bloc-notes.
8. Dans le bloc-notes, vous pouvez accéder au lien du journal du pilote et à un lien vers l'interface utilisateur d'Apache Spark, une interface en temps réel qui fournit des indicateurs pour surveiller votre travail. Pour plus d'informations, consultez la section [Surveillance des applications et des tâches EMR sans serveur](#) dans le guide de l'utilisateur Amazon EMR Serverless.

Lorsque vous associez une application à un espace de travail Studio, le démarrage de l'application se déclenche automatiquement si elle n'est pas déjà en cours d'exécution. Vous pouvez également prédémarrer l'application et la garder prête avant de l'associer à l'espace de travail.

### Étape 3 : Afficher l'interface utilisateur et les journaux de l'application

Pour afficher l'interface utilisateur de l'application, identifiez d'abord le travail exécuté. Une option pour l'interface utilisateur Spark ou Hive Tez est disponible dans la première ligne d'options pour cette tâche exécutée, en fonction du type de tâche. Sélectionnez l'option appropriée.

Si vous avez choisi l'interface utilisateur Spark, cliquez sur l'onglet Exécuteurs pour afficher les journaux des pilotes et des exécuteurs. Si vous avez choisi l'interface utilisateur Hive Tez, cliquez sur l'onglet Toutes les tâches pour afficher les journaux.

Une fois que le statut d'exécution de la tâche indique Success, vous pouvez consulter le résultat de la tâche dans votre compartiment S3.

### Étape 4 : Nettoyer

Bien que l'application que vous avez créée doive s'arrêter automatiquement après 15 minutes d'inactivité, nous vous recommandons tout de même de libérer des ressources que vous n'avez pas l'intention de réutiliser.



Pour supprimer l'application, accédez à la page Répertorier les applications. Sélectionnez l'application que vous avez créée et choisissez Actions → Arrêter pour arrêter l'application. Une fois que l'application est dans STOPPED cet état, sélectionnez-la et choisissez Actions → Supprimer.

Pour d'autres exemples d'exécution de tâches Spark et Hive, reportez-vous aux sections [Offres d'emploi Spark](#) et [Offres d'emploi Hive](#).

## Commencer à partir du AWS CLI

### Étape 1 : Création d'une application EMR sans serveur

Utilisez la [emr-serverless create-application](#) commande pour créer votre première application EMR sans serveur. Vous devez spécifier le type d'application et le label de EMR version Amazon associés à la version de l'application que vous souhaitez utiliser. Le nom de l'application est facultatif.

#### Spark

Pour créer une application Spark, exécutez la commande suivante.

```
aws emr-serverless create-application \  
  --release-label emr-6.6.0 \  
  --type "SPARK" \  
  --name my-application
```

#### Hive

Pour créer une application Hive, exécutez la commande suivante.

```
aws emr-serverless create-application \  
  --release-label emr-6.6.0 \  
  --type "HIVE" \  
  --name my-application
```

Notez l'ID de l'application renvoyé dans la sortie. Vous utiliserez cet identifiant pour démarrer la candidature et lors de la soumission des offres d'emploi, appelé ensuite *application-id*.

Avant de passer à [Étape 2 : Soumettre une tâche exécutée à votre application EMR Serverless](#), assurez-vous que votre application a atteint l'CREATED état correspondant au [get-application](#) API.

```
aws emr-serverless get-application \  
  --application-id application-id
```

EMRServerless crée des travailleurs pour répondre aux tâches que vous demandez. Par défaut, ils sont créés à la demande, mais vous pouvez également spécifier une capacité pré-initialisée en définissant le `initialCapacity` paramètre lors de la création de l'application. Vous pouvez également limiter la capacité maximale totale qu'une application peut utiliser avec le `maximumCapacity` paramètre. Pour en savoir plus sur ces options, consultez [Configuration d'une application](#).

## Étape 2 : Soumettre une tâche exécutée à votre application EMR Serverless

Votre application EMR Serverless est maintenant prête à exécuter des tâches.

### Spark

Dans cette étape, nous utilisons un PySpark script pour calculer le nombre d'occurrences de mots uniques dans plusieurs fichiers texte. Un compartiment S3 public en lecture seule stocke à la fois le script et le jeu de données. L'application envoie le fichier de sortie et les données du journal depuis le moteur d'exécution Spark vers le compartiment S3 que vous avez créé `/output` et les `/logs` répertoires qu'il contient.

Pour exécuter une tâche Spark

1. Utilisez la commande suivante pour copier le script d'exemple que nous allons exécuter dans votre nouveau compartiment.

```
aws s3 cp s3://us-east-1.elasticmapreduce/emr-containers/samples/wordcount/  
scripts/wordcount.py s3://DOC-EXAMPLE-BUCKET/scripts/
```

2. Dans la commande suivante, remplacez-le par *application-id* l'ID de votre application. Remplacez *job-role-arn* par le rôle d'exécution ARN que vous avez créé dans [Création d'un rôle d'exécution de tâches](#). Substituez *job-run-name* avec le nom que vous souhaitez appeler votre tâche exécutée. Remplacez toutes les *DOC-EXAMPLE-BUCKET* chaînes par le compartiment Amazon S3 que vous avez créé et ajoutez-les `/output` au chemin. Cela crée un nouveau dossier dans votre compartiment dans lequel EMR Serverless peut copier les fichiers de sortie de votre application.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --name job-run-name \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/scripts/wordcount.py",  
      "entryPointArguments": ["s3://DOC-EXAMPLE-BUCKET/emr-serverless-spark/  
output"],  
      "sparkSubmitParameters": "--conf spark.executor.cores=1  
--conf spark.executor.memory=4g --conf spark.driver.cores=1 --conf  
spark.driver.memory=4g --conf spark.executor.instances=1"  
    }  
  }'
```

3. Notez l'ID d'exécution de la tâche renvoyé dans la sortie. *job-run-id* Remplacez-le par cet ID dans les étapes suivantes.

## Hive

Dans ce didacticiel, nous créons une table, insérons quelques enregistrements et exécutons une requête d'agrégation de comptes. Pour exécuter la tâche Hive, créez d'abord un fichier contenant toutes les requêtes Hive à exécuter dans le cadre d'une tâche unique, téléchargez le fichier sur S3 et spécifiez ce chemin S3 lorsque vous démarrez la tâche Hive.

Pour exécuter une tâche Hive

1. Créez un fichier appelé `hive-query.q1` contenant toutes les requêtes que vous souhaitez exécuter dans votre tâche Hive.

```
create database if not exists emrserverless;  
use emrserverless;  
create table if not exists test_table(id int);  
drop table if exists Values__Tmp__Table__1;  
insert into test_table values (1),(2),(2),(3),(3),(3);  
select id, count(id) from test_table group by id order by id desc;
```

2. `hive-query.q1` Téléchargez-le dans votre compartiment S3 à l'aide de la commande suivante.

```
aws s3 cp hive-query.q1 s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-
query.q1
```

3. Dans la commande suivante, remplacez-le *application-id* par votre propre ID d'application. Remplacez *job-role-arn* par le rôle d'exécution ARN que vous avez créé dans [Création d'un rôle d'exécution de tâches](#). Remplacez toutes les *DOC-EXAMPLE-BUCKET* chaînes par le compartiment Amazon S3 que vous avez créé, puis ajoutez /output et /logs au chemin. Cela crée de nouveaux dossiers dans votre compartiment, dans lesquels EMR Serverless peut copier les fichiers de sortie et les fichiers journaux de votre application.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "hive": {
      "query": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-
query.q1",
      "parameters": "--hiveconf hive.log.explain.output=false"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "hive-site",
      "properties": {
        "hive.exec.scratchdir": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-
hive/hive/scratch",
        "hive.metastore.warehouse.dir": "s3://DOC-EXAMPLE-BUCKET/emr-
serverless-hive/hive/warehouse",
        "hive.driver.cores": "2",
        "hive.driver.memory": "4g",
        "hive.tez.container.size": "4096",
        "hive.tez.cpu.vcores": "1"
      }
    }],
    "monitoringConfiguration": {
      "s3MonitoringConfiguration": {
        "logUri": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/logs"
      }
    }
  }'
```

4. Notez l'ID d'exécution de la tâche renvoyé dans la sortie. *job-run-id* Remplacez-le par cet ID dans les étapes suivantes.

## Étape 3 : passez en revue le résultat de votre exécution de tâche

L'exécution de la tâche doit généralement prendre de 3 à 5 minutes.

### Spark

Vous pouvez vérifier l'état de votre tâche Spark à l'aide de la commande suivante.

```
aws emr-serverless get-job-run \  
  --application-id application-id \  
  --job-run-id job-run-id
```

Lorsque la destination de votre journal est définie sur `s3://DOC-EXAMPLE-BUCKET/emr-serverless-spark/logs`, vous pouvez trouver les journaux de cette tâche spécifique exécutée sous `s3://DOC-EXAMPLE-BUCKET/emr-serverless-spark/logs/applications/application-id/jobs/job-run-id`.

Pour les applications Spark, EMR Serverless envoie les journaux d'événements toutes les 30 secondes vers le `sparklogs` dossier de destination de votre journal S3. Lorsque votre tâche est terminée, les journaux d'exécution de Spark pour le pilote et les exécuteurs sont téléchargés dans des dossiers nommés de manière appropriée par le type de travailleur, tels que `driver` ou `executor`. La sortie de la PySpark tâche est transférée vers `s3://DOC-EXAMPLE-BUCKET/output/`

### Hive

Vous pouvez vérifier l'état de votre tâche Hive à l'aide de la commande suivante.

```
aws emr-serverless get-job-run \  
  --application-id application-id \  
  --job-run-id job-run-id
```

Lorsque la destination de votre journal est définie sur `s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/logs`, vous pouvez trouver les journaux de cette tâche spécifique exécutée sous `s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/logs/applications/application-id/jobs/job-run-id`.

Pour les applications Hive, EMR Serverless télécharge en permanence le pilote Hive HIVE\_DRIVER dans le dossier de votre destination de journal S3 et les journaux de tâches Tez TEZ\_TASK dans le dossier. Une fois que le job a atteint son SUCCEEDED état, le résultat de votre requête Hive est disponible à l'emplacement Amazon S3 que vous avez spécifié dans le monitoringConfiguration champ de configurationOverrides.

## Étape 4 : Nettoyer

Lorsque vous aurez terminé de travailler sur ce didacticiel, pensez à supprimer les ressources que vous avez créées. Nous vous recommandons de publier des ressources que vous n'avez pas l'intention de réutiliser.

### Supprimer votre candidature

Pour supprimer une application, utilisez la commande suivante.

```
aws emr-serverless delete-application \  
  --application-id application-id
```

### Supprimer votre bucket de log S3

Pour supprimer votre compartiment de journalisation et de sortie S3, utilisez la commande suivante. Remplacez *DOC-EXAMPLE-BUCKET* par le nom réel du compartiment S3 créé dans [Préparer le stockage pour le mode EMR Serverless](#).

```
aws s3 rm s3://DOC-EXAMPLE-BUCKET --recursive  
aws s3api delete-bucket --bucket DOC-EXAMPLE-BUCKET
```

### Supprimer votre rôle d'exécution des tâches

Pour supprimer le rôle d'exécution, détachez la politique du rôle. Vous pouvez ensuite supprimer à la fois le rôle et la politique.

```
aws iam detach-role-policy \  
  --role-name EMRServerlessS3RuntimeRole \  
  --policy-arn policy-arn
```

Pour supprimer le rôle, utilisez la commande suivante.

```
aws iam delete-role \  
  --role-name EMRServerlessS3RuntimeRole
```

Pour supprimer la politique attachée au rôle, utilisez la commande suivante.

```
aws iam delete-policy \  
  --policy-arn policy-arn
```

Pour d'autres exemples d'exécution de tâches Spark et Hive, consultez [Offres d'emploi Spark](#) et [Offres d'emploi Hive](#).

# Interaction avec une application

Cette section explique comment vous pouvez interagir avec votre application Amazon EMR Serverless à l'aide du AWS CLI et les valeurs par défaut pour les moteurs Spark et Hive.

## Rubriques

- [États de l'application](#)
- [Interaction avec votre application depuis la console EMR Studio](#)
- [Interaction avec votre application sur le AWS CLI](#)
- [Configuration d'une application](#)
- [Personnalisation d'une image EMR sans serveur](#)
- [Configuration de VPC l'accès](#)
- [Options d'architecture Amazon EMR Serverless](#)

## États de l'application

Lorsque vous créez une application avec EMR Serverless, l'application exécutée entre dans CREATING cet état. Elle passe ensuite par les états suivants jusqu'à ce qu'elle réussisse (se termine avec le code 0) ou qu'elle échoue (se termine avec un code non nul).


Les applications peuvent avoir les états suivants :

État	Description
Création	L'application est en cours de préparation et n'est pas encore prête à être utilisée.
Créé	L'application a été créée mais n'a pas encore provisionné de capacité. Vous pouvez modifier l'application pour modifier sa configuration initiale de capacité.
Démarrage en cours	L'application démarre et fournit de la capacité.



État	Description
Commencé	L'application est prête à accepter de nouveaux emplois. L'application accepte uniquement les offres d'emploi dans cet état.
Arrêt en cours	Tous les travaux sont terminés et l'application est en train de libérer ses capacités.
Arrêté(e)	L'application est arrêtée et aucune ressource n'est en cours d'exécution sur l'application. Vous pouvez modifier l'application pour modifier sa configuration initiale de capacité.
Terminé	L'application a été résiliée et ne figure pas dans votre liste de candidatures.

Le schéma suivant montre la trajectoire des états des applications EMR sans serveur.



## Interaction avec votre application depuis la console EMR Studio

Depuis la console EMR Studio, vous pouvez créer, afficher et gérer des applications EMR sans serveur. Pour accéder à la console EMR Studio, suivez les instructions de la [section Démarrage depuis la console](#).

### Création d'une application

La page Créer une application vous permet de créer une application EMR sans serveur en suivant ces étapes.

1. Dans le champ Nom, saisissez le nom que vous souhaitez donner à votre application.
2. Dans le champ Type, choisissez Spark ou Hive comme type d'application.
3. Dans le champ Version de version, choisissez le numéro EMR de version.
4. Dans les options d'architecture, choisissez l'architecture du jeu d'instructions à utiliser. Pour de plus amples informations, veuillez consulter [Options d'architecture Amazon EMR Serverless](#).
  - arm64 — ARM architecture 64 bits ; pour utiliser les processeurs Graviton
  - x86\_64 : architecture x86 64 bits ; pour utiliser des processeurs x86
5. Il existe deux options de configuration de l'application pour les champs restants : les paramètres par défaut et les paramètres personnalisés. Ces champs sont facultatifs.

Paramètres par défaut — Les paramètres par défaut vous permettent de créer rapidement une application avec une capacité pré-initialisée. Cela inclut un pilote et un exécuteur pour Spark, et un pilote et un Tez Task pour Hive. Les paramètres par défaut n'autorisent pas la connectivité réseau à votre VPCs. L'application est configurée pour s'arrêter en cas d'inactivité pendant 15 minutes et démarre automatiquement lors de la soumission de la tâche.

Paramètres personnalisés : les paramètres personnalisés vous permettent de modifier les propriétés suivantes.

- Capacité pré-initialisée : nombre de pilotes et d'exécuteurs ou de travailleurs Hive Tez Task, et taille de chaque travailleur.
- Limites d'application : capacité maximale d'une application.
- Comportement de l'application : comportement de démarrage et d'arrêt automatique de l'application.
- Connexions réseau : connectivité réseau aux VPC ressources.
- Balises : balises personnalisées que vous pouvez attribuer à l'application.

Pour plus d'informations sur la capacité préinitialisée, les limites des applications et le comportement des applications, consultez. [Configuration d'une application](#) Pour plus d'informations sur la connectivité réseau, consultez [Configuration de VPC l'accès](#).

6. Pour créer l'application, choisissez Create application.

## Lister les applications

Vous pouvez consulter toutes les applications EMR sans serveur existantes sur la page Liste des applications. Vous pouvez choisir le nom d'une application pour accéder à la page de détails de cette application.

## Gestion des applications

Vous pouvez effectuer les actions suivantes sur une application depuis la page Répertoire des applications ou depuis la page Détails d'une application spécifique.

### Lancer l'application

Choisissez cette option pour démarrer manuellement une application.

### Arrêter l'application

Choisissez cette option pour arrêter manuellement une application. Une application ne doit pas avoir de tâche en cours d'exécution pour être arrêtée. Pour en savoir plus sur les transitions d'état des applications, consultez [États de l'application](#).

### Configuration de l'application

Modifiez les paramètres facultatifs d'une application depuis la page Configurer l'application. Vous pouvez modifier la plupart des paramètres de l'application. Par exemple, vous pouvez modifier l'étiquette de publication d'une application pour la mettre à niveau vers une autre version d'AmazonEMR, ou vous pouvez passer de l'architecture x86\_64 à arm64. Les autres paramètres facultatifs sont les mêmes que ceux de la section Paramètres personnalisés de la page Créer une application. Pour plus d'informations sur les paramètres de l'application, consultez [Création d'une application](#).

### Supprimer l'application

Choisissez cette option pour supprimer manuellement une application. Vous devez arrêter une application pour pouvoir la supprimer. Pour en savoir plus sur les transitions d'état des applications, consultez [États de l'application](#).

## Interaction avec votre application sur le AWS CLI

À partir du AWS CLI, vous pouvez créer, décrire et supprimer des applications individuelles. Vous pouvez également répertorier toutes vos applications afin de les visualiser en un coup d'œil. Cette

section décrit comment effectuer ces actions. Pour d'autres opérations d'application, telles que le démarrage, l'arrêt et la mise à jour de votre application, consultez le manuel [EMRServerless API Reference](#). Pour des exemples d'utilisation du EMR Serverless à l'aide du AWS SDK for Java, consultez les [exemples de Java](#) dans notre GitHub référentiel. Pour des exemples d'utilisation du EMR Serverless à l'aide du AWS SDK for Python (Boto), consultez les [exemples de Python](#) dans notre GitHub dépôt.

Pour créer une application, utilisez `create-application`. Vous devez spécifier SPARK ou HIVE en tant qu'`application-type`. Cette commande renvoie le nom ARN, le nom et l'ID de l'application.

```
aws emr-serverless create-application \  
--name my-application-name \  
--type 'application-type' \  
--release-label release-version
```

Pour décrire une application, utilisez `get-application` et fournissez son `application-id`. Cette commande renvoie les configurations relatives à l'état et à la capacité de votre application.

```
aws emr-serverless get-application \  
--application-id application-id
```

Pour répertorier toutes vos applications, appelez `list-applications`. Cette commande renvoie les mêmes propriétés que `get-application`, mais inclut toutes vos applications.

```
aws emr-serverless list-applications
```

Pour supprimer votre application, appelez `delete-application` et fournissez votre `application-id`.

```
aws emr-serverless delete-application \  
--application-id application-id
```

## Configuration d'une application

Avec EMR Serverless, vous pouvez configurer les applications que vous utilisez. Par exemple, vous pouvez définir la capacité maximale qu'une application peut atteindre, configurer une capacité préinitialisée pour que les conducteurs et les employés soient prêts à réagir, et spécifier un ensemble

commun de configurations d'exécution et de surveillance au niveau de l'application. Les pages suivantes décrivent comment configurer des applications lorsque vous utilisez EMR Serverless.

## Rubriques

- [Comprendre le comportement des applications](#)
- [Capacité pré-initialisée](#)
- [Configuration d'application par défaut pour EMR Serverless](#)

## Comprendre le comportement des applications

### Comportement par défaut des applications

**Démarrage automatique** : une application est configurée par défaut pour démarrer automatiquement lors de la soumission de la tâche. Vous pouvez désactiver cette fonctionnalité.

**Arrêt automatique** : une application est configurée par défaut pour s'arrêter automatiquement lorsqu'elle est inactive pendant 15 minutes. Lorsqu'une application passe à STOPPED cet état, elle libère toute capacité préinitialisée configurée. Vous pouvez modifier le temps d'inactivité avant l'arrêt automatique d'une application ou désactiver cette fonctionnalité.

### Maximum capacity (Capacité maximum)

Vous pouvez configurer la capacité maximale qu'une application peut atteindre. Vous pouvez spécifier votre capacité maximale en termes de CPU mémoire (Go) et de disque (Go).

#### Note

Nous vous recommandons de configurer votre capacité maximale de manière à ce qu'elle soit proportionnelle à la taille des travailleurs pris en charge en multipliant le nombre de travailleurs par leur taille. Par exemple, si vous souhaitez limiter votre application à 50 travailleurs avec 2vCPUs, 16 Go de mémoire et 20 Go de disque, définissez votre capacité maximale à 100vCPUs, 800 Go pour la mémoire et 1 000 Go pour le disque.

## Configurations de travail supportées

Le tableau suivant indique les configurations de travail prises en charge et les tailles que vous pouvez spécifier pour EMR Serverless. Vous pouvez configurer différentes tailles pour les pilotes et les exécuteurs en fonction des besoins de votre charge de travail.

CPU	Mémoire	Stockage éphémère par défaut
1 v CPU	Minimum 2 Go, maximum 8 Go, par incréments de 1 Go	20 GO - 200 GO
2 v CPU	Minimum 4 Go, maximum 16 Go, par incréments de 1 Go	20 GO - 200 GO
4 v CPU	Minimum 8 Go, maximum 30 Go, par incréments de 1 Go	20 GO - 200 GO
8 v CPU	16 Go au minimum, 60 Go au maximum, par incréments de 4 Go	20 GO - 200 GO
16 v CPU	Minimum 32 Go, maximum 120 Go, par incréments de 8 Go	20 GO - 200 GO

CPU— Chaque travailleur peut avoir 1, 2, 4, 8 ou 16vCPUs.

Mémoire — Chaque travailleur dispose de mémoire, spécifiée en Go, dans les limites indiquées dans le tableau précédent. Les tâches Spark ont une surcharge de mémoire, ce qui signifie que la mémoire qu'elles utilisent est supérieure aux tailles de conteneur spécifiées. Cette surcharge est spécifiée avec les propriétés `spark.driver.memoryOverhead` et `spark.executor.memoryOverhead`. La surcharge a une valeur par défaut de 10 % de la mémoire du conteneur, avec un minimum de 384 Mo. Vous devez tenir compte de ces frais généraux lorsque vous choisissez la taille des travailleurs.

Par exemple, si vous choisissez 4 vCPUs pour votre instance de travail et une capacité de stockage préinitialisée de 30 Go, vous devez définir une valeur d'environ 27 Go comme mémoire d'exécuteur

pour votre tâche Spark. Cela maximise l'utilisation de votre capacité pré-initialisée. La mémoire utilisable serait de 27 Go, plus 10 % de 27 Go (2,7 Go), pour un total de 29,7 Go.

Disque : vous pouvez configurer chaque travailleur avec des disques de stockage temporaires d'une taille minimale de 20 Go et maximale de 200 Go. Vous ne payez que pour le stockage supplémentaire au-delà de 20 Go que vous configurez par utilisateur.

## Capacité pré-initialisée

EMRServerless fournit une fonctionnalité optionnelle qui permet au conducteur et aux employés de rester préinitialisés et prêts à réagir en quelques secondes. Cela crée efficacement un bassin de travailleurs chaleureux pour une application. Cette fonctionnalité est appelée capacité pré-initialisée. Pour configurer cette fonctionnalité, vous pouvez définir le `initialCapacity` paramètre d'une application en fonction du nombre de travailleurs que vous souhaitez pré-initialiser. Avec une capacité de travail préinitialisée, les tâches démarrent immédiatement. C'est idéal lorsque vous souhaitez implémenter des applications itératives et des tâches urgentes.

Lorsque vous soumettez une tâche, si des collaborateurs `initialCapacity` sont disponibles, la tâche utilise ces ressources pour démarrer son exécution. Si ces travailleurs sont déjà utilisés par d'autres tâches, ou si la tâche nécessite plus de ressources que celles disponibles `initialCapacity`, l'application demande et obtient des travailleurs supplémentaires, dans la limite maximale des ressources définies pour l'application. Lorsqu'une tâche termine son exécution, elle libère les travailleurs qu'elle a utilisés et le nombre de ressources disponibles pour l'application revient à zéro `initialCapacity`. Une application conserve les ressources même après `initialCapacity` la fin de l'exécution des tâches. L'application libère des ressources excédentaires au-delà du `initialCapacity` moment où les tâches n'en ont plus besoin pour s'exécuter.

La capacité pré-initialisée est disponible et prête à être utilisée au démarrage de l'application. La capacité pré-initialisée devient inactive lorsque l'application est arrêtée. Une application ne passe à l'`STARTED` état que si la capacité pré-initialisée demandée a été créée et est prête à être utilisée. Pendant toute la durée de l'`STARTED` état de l'application, EMR Serverless conserve la capacité préinitialisée disponible pour être utilisée ou utilisée par des tâches ou des charges de travail interactives. Cette fonctionnalité rétablit la capacité des conteneurs libérés ou défectueux. Cela permet de conserver le nombre de travailleurs spécifié par le `InitialCapacity` paramètre. L'état d'une application sans capacité préinitialisée peut immédiatement passer de `CREATED` à `STARTED`.

Vous pouvez configurer l'application pour libérer de la capacité préinitialisée si elle n'est pas utilisée pendant un certain temps, avec une durée par défaut de 15 minutes. Une candidature bloquée

démarré automatiquement lorsque vous soumettez une nouvelle offre d'emploi. Vous pouvez définir ces configurations de démarrage et d'arrêt automatiques lorsque vous créez l'application, ou vous pouvez les modifier lorsque l'application est dans un STOPPED état CREATED ou.

Vous pouvez modifier les `InitialCapacity` nombres et spécifier des configurations de calcul telles que CPU la mémoire et le disque pour chaque travailleur. Comme vous ne pouvez pas apporter de modifications partielles, vous devez spécifier toutes les configurations de calcul lorsque vous modifiez des valeurs. Vous ne pouvez modifier les configurations que lorsque l'application est à l'STOPPED état CREATED ou.

#### Note

Pour optimiser l'utilisation des ressources par votre application, nous vous recommandons d'aligner la taille de vos conteneurs sur les tailles de capacité de travail préinitialisées. Par exemple, si vous configurez la taille de votre exécuteur Spark à 2 CPUs et votre mémoire à 8 Go, mais que votre capacité de travail préinitialisée est de 4 CPUs avec 16 Go de mémoire, les exécuteurs Spark n'utilisent que la moitié des ressources des travailleurs lorsqu'ils sont affectés à cette tâche.

## Personnalisation de la capacité pré-initialisée pour Spark et Hive

Vous pouvez personnaliser davantage la capacité préinitialisée pour les charges de travail exécutées sur des frameworks de mégadonnées spécifiques. Par exemple, lorsqu'une charge de travail s'exécute sur Apache Spark, vous pouvez spécifier combien de travailleurs commencent en tant que pilotes et combien commencent en tant qu'exécuteurs. De même, lorsque vous utilisez Apache Hive, vous pouvez spécifier combien de travailleurs démarrent en tant que pilotes Hive et combien doivent exécuter des tâches Tez.

### Configuration d'une application exécutant Apache Hive avec une capacité pré-initialisée

La API requête suivante crée une application exécutant Apache Hive basée sur la EMR version `emr-6.6.0` d'Amazon. L'application démarre avec 5 pilotes Hive préinitialisés, chacun avec 2 V CPU et 4 Go de mémoire, et 50 programmes de travail Tez pré-initialisés, chacun avec 4 V CPU et 8 Go de mémoire. Lorsque les requêtes Hive s'exécutent sur cette application, elles utilisent d'abord les travailleurs pré-initialisés et commencent à s'exécuter immédiatement. Si tous les travailleurs pré-initialisés sont occupés et que d'autres tâches Hive sont soumises, l'application peut atteindre un total de 400 V CPU et 1 024 Go de mémoire. Vous pouvez éventuellement omettre la capacité du travailleur DRIVER ou du TEZ\_TASK travailleur.



```
aws emr-serverless create-application \  
  --type "HIVE" \  
  --name my-application-name \  
  --release-label emr-6.6.0 \  
  --initial-capacity '{  
    "DRIVER": {  
      "workerCount": 5,  
      "workerConfiguration": {  
        "cpu": "2vCPU",  
        "memory": "4GB"  
      }  
    },  
    "TEZ_TASK": {  
      "workerCount": 50,  
      "workerConfiguration": {  
        "cpu": "4vCPU",  
        "memory": "8GB"  
      }  
    }  
  }' \  
  --maximum-capacity '{  
    "cpu": "400vCPU",  
    "memory": "1024GB"  
  }'
```

## Configuration d'une application exécutant Apache Spark avec une capacité pré-initialisée

La API demande suivante crée une application qui exécute Apache Spark 3.2.0 sur la base de la EMR version 6.6.0 d'Amazon. L'application démarre avec 5 pilotes Spark préinitialisés, chacun avec 2 V CPU et 4 Go de mémoire, et 50 exécuteurs préinitialisés, chacun avec 4 V CPU et 8 Go de mémoire. Lorsque les tâches Spark s'exécutent sur cette application, elles utilisent d'abord les travailleurs pré-initialisés et commencent à s'exécuter immédiatement. Si tous les travailleurs préinitialisés sont occupés et que d'autres tâches Spark sont soumises, l'application peut atteindre un total de 400 V CPU et 1 024 Go de mémoire. Vous pouvez éventuellement omettre la capacité pour le DRIVER ou leEXECUTOR.

### Note

Spark ajoute une surcharge de mémoire configurable, avec une valeur par défaut de 10 %, à la mémoire demandée pour le pilote et les exécuteurs. Pour que les tâches utilisent

des travailleurs préinitialisés, la configuration initiale de la capacité de mémoire doit être supérieure à la mémoire demandée par la tâche et la surcharge.

```
aws emr-serverless create-application \  
--type "SPARK" \  
--name my-application-name \  
--release-label emr-6.6.0 \  
--initial-capacity '{  
  "DRIVER": {  
    "workerCount": 5,  
    "workerConfiguration": {  
      "cpu": "2vCPU",  
      "memory": "4GB"  
    }  
  },  
  "EXECUTOR": {  
    "workerCount": 50,  
    "workerConfiguration": {  
      "cpu": "4vCPU",  
      "memory": "8GB"  
    }  
  }  
}' \  
--maximum-capacity '{  
  "cpu": "400vCPU",  
  "memory": "1024GB"  
}'
```

## Configuration d'application par défaut pour EMR Serverless

Vous pouvez définir un ensemble commun de configurations d'exécution et de surveillance au niveau de l'application pour toutes les tâches que vous soumettez sous la même application. Cela réduit la surcharge supplémentaire associée à la nécessité de soumettre les mêmes configurations pour chaque tâche.

Vous pouvez modifier les configurations aux moments suivants :

- [Déclarez les configurations au niveau de l'application lors de la soumission de la tâche.](#)
- [Remplacez les configurations par défaut lors de l'exécution du job.](#)

Les sections suivantes fournissent plus de détails et fournissent un exemple pour un contexte plus détaillé.

## Déclarer des configurations au niveau de l'application

Vous pouvez spécifier les propriétés de journalisation et de configuration d'exécution au niveau de l'application pour les tâches que vous soumettez dans le cadre de l'application.

### **monitoringConfiguration**

Pour spécifier les configurations du journal pour les tâches que vous soumettez avec l'application, utilisez le [monitoringConfiguration](#) champ. Pour plus d'informations sur la journalisation pour EMR Serverless, consultez [Stockage des journaux](#).

### **runtimeConfiguration**

Pour spécifier les propriétés de configuration d'exécution, par exemple `spark-defaults`, fournissez un objet de configuration dans le `runtimeConfiguration` champ. Cela affecte les configurations par défaut de toutes les tâches que vous soumettez avec l'application. Pour plus d'informations, consultez [Paramètre de remplacement de la configuration Hive](#) et [Paramètre de remplacement de la configuration Spark](#).

Les classifications de configuration disponibles varient en fonction de la version EMR Serverless spécifique. Par exemple, les classifications pour Log4j personnalisées ne `spark-executor-log4j2` sont disponibles qu'avec les versions `6.8.0 spark-driver-log4j2` et supérieures. Pour obtenir la liste des propriétés spécifiques à l'application, reportez-vous [Propriétés de la tâche Spark](#) aux sections et [Propriétés des tâches Hive](#)

Vous pouvez également configurer les propriétés d'[Apache Log4j2](#), [AWS Secrets Manager pour la protection des](#) données et l'[exécution de Java 17](#) au niveau de l'application.

Pour transmettre les secrets de Secrets Manager au niveau de l'application, associez la politique suivante aux utilisateurs et aux rôles qui doivent créer ou mettre à jour des applications EMR sans serveur avec des secrets.

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

```

        "Effect": "Allow",
        "Action": [
            "secretsmanager:GetSecretValue",
            "secretsmanager:DescribeSecret",
            "kms:Decrypt"
        ],
        "Resource": "arn:aws:secretsmanager:your-secret-arn"
    }
}

```

Pour plus d'informations sur la création de politiques personnalisées pour les secrets, consultez [les exemples de politiques d'autorisation pour AWS Secrets Manager](#) dans le .AWS Secrets Manager Guide de l'utilisateur.

### Note

La `runtimeConfiguration` valeur que vous spécifiez au niveau de l'application `applicationConfiguration` correspond à [StartJobRunAPI](#).

## Exemple de déclaration

L'exemple suivant montre comment déclarer des configurations par défaut avec `create-application`.

```

aws emr-serverless create-application \
  --release-label release-version \
  --type SPARK \
  --name my-application-name \
  --runtime-configuration '[
    {
      "classification": "spark-defaults",
      "properties": {
        "spark.driver.cores": "4",
        "spark.executor.cores": "2",
        "spark.driver.memory": "8G",
        "spark.executor.memory": "8G",
        "spark.executor.instances": "2",

"spark.hadoop.javax.jdo.option.ConnectionDriverName": "org.mariadb.jdbc.Driver",

```

```

        "spark.hadoop.java.jdbc.option.ConnectionURL": "jdbc:mysql://db-host:db-
port/db-name",
        "spark.hadoop.java.jdbc.option.ConnectionUserName": "connection-user-
name",
        "spark.hadoop.java.jdbc.option.ConnectionPassword":
"EMR.secret@SecretID"
    }
},
{
    "classification": "spark-driver-log4j2",
    "properties": {
        "rootLogger.level": "error",
        "logger.IdentifierForClass.name": "classpathForSettingLogger",
        "logger.IdentifierForClass.level": "info"
    }
}
]' \
--monitoring-configuration '{
    "s3MonitoringConfiguration": {
        "logUri": "s3://DOC-EXAMPLE-BUCKET-LOGGING/logs/app-level"
    },
    "managedPersistenceMonitoringConfiguration": {
        "enabled": false
    }
}'

```

## Remplacer les configurations lors de l'exécution d'une tâche

Vous pouvez définir des remplacements de configuration pour la configuration de l'application et la configuration de surveillance à l'aide du [StartJobRunAPI](#). EMRServerless fusionne ensuite les configurations que vous spécifiez au niveau de l'application et au niveau du travail afin de déterminer les configurations pour l'exécution du travail.

Le niveau de granularité lors de la fusion est le suivant :

- [ApplicationConfiguration](#)- Type de classification, par exemplespark-defaults.
- [MonitoringConfiguration](#)- Type de configuration, par exemples3MonitoringConfiguration.

**Note**

La priorité des configurations que vous fournissez [StartJobRun](#) remplace les configurations que vous fournissez au niveau de l'application.

Pour plus d'informations sur les classements prioritaires, voir [Paramètre de remplacement de la configuration Hive](#) et [Paramètre de remplacement de la configuration Spark](#).

Lorsque vous démarrez une tâche, si vous ne spécifiez pas de configuration particulière, elle est héritée de l'application. Si vous déclarez les configurations au niveau de la tâche, vous pouvez effectuer les opérations suivantes :

- Remplacer une configuration existante : fournissez le même paramètre de configuration dans la `StartJobRun` demande avec vos valeurs de remplacement.
- Ajouter une configuration supplémentaire : ajoutez le nouveau paramètre de configuration dans la `StartJobRun` demande avec les valeurs que vous souhaitez spécifier.
- Supprimer une configuration existante : pour supprimer une configuration d'exécution d'application, fournissez la clé de la configuration que vous souhaitez supprimer et transmettez une déclaration vide `{}` pour la configuration. Nous ne recommandons pas de supprimer les classifications contenant les paramètres nécessaires à l'exécution d'une tâche. Par exemple, si vous essayez de supprimer les [propriétés requises pour une tâche Hive](#), la tâche échouera.

Pour supprimer une configuration de surveillance des applications, utilisez la méthode appropriée pour le type de configuration concerné :

- **cloudWatchLoggingConfiguration**- Pour le supprimer `cloudWatchLogging`, transmettez le drapeau activé en tant que `false`.
- **managedPersistenceMonitoringConfiguration**- Pour supprimer les paramètres de persistance gérés et revenir à l'état activé par défaut, transmettez une déclaration vide `{}` pour la configuration.
- **s3MonitoringConfiguration**- Pour supprimer `s3MonitoringConfiguration`, transmettez une déclaration vide `{}` pour la configuration.

### Exemple de dérogation

L'exemple suivant montre les différentes opérations que vous pouvez effectuer lors de la soumission d'une tâche sur `start-job-run`.

```

aws emr-serverless start-job-run \
  --application-id your-application-id \
  --execution-role-arn your-job-role-arn \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "s3://us-east-1.elasticmapreduce/emr-containers/samples/
wordcount/scripts/wordcount.py",
      "entryPointArguments": ["s3://DOC-EXAMPLE-BUCKET-OUTPUT/wordcount_output"]
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [
      {
        // Override existing configuration for spark-defaults in the
application
        "classification": "spark-defaults",
        "properties": {
          "spark.driver.cores": "2",
          "spark.executor.cores": "1",
          "spark.driver.memory": "4G",
          "spark.executor.memory": "4G"
        }
      },
      {
        // Add configuration for spark-executor-log4j2
        "classification": "spark-executor-log4j2",
        "properties": {
          "rootLogger.level": "error",
          "logger.IdentifierForClass.name": "classpathForSettingLogger",
          "logger.IdentifierForClass.level": "info"
        }
      },
      {
        // Remove existing configuration for spark-driver-log4j2 from the
application
        "classification": "spark-driver-log4j2",
        "properties": {}
      }
    ],
    "monitoringConfiguration": {
      "managedPersistenceMonitoringConfiguration": {
        // Override existing configuration for managed persistence
        "enabled": true
      }
    }
  }'

```

```
    },
    "s3MonitoringConfiguration": {
      // Remove configuration of S3 monitoring
    },
    "cloudWatchLoggingConfiguration": {
      // Add configuration for CloudWatch logging
      "enabled": true
    }
  }
}'
```

Au moment de l'exécution de la tâche, les classifications et configurations suivantes s'appliqueront en fonction du classement de priorité décrit dans [Paramètre de remplacement de la configuration Hive](#) et [Paramètre de remplacement de la configuration Spark](#).

- La classification `spark-defaults` sera mise à jour avec les propriétés spécifiées au niveau du poste. Seules les propriétés incluses `StartJobRun` seraient prises en compte pour cette classification.
- La classification `spark-executor-log4j2` sera ajoutée à la liste de classifications existante.
- La classification `spark-driver-log4j2` sera supprimée.
- Les configurations pour `managedPersistenceMonitoringConfiguration` seront mises à jour avec les configurations au niveau du travail.
- Les configurations pour `s3MonitoringConfiguration` seront supprimées.
- Les configurations pour `cloudWatchLoggingConfiguration` seront ajoutées aux configurations de surveillance existantes.

## Personnalisation d'une image EMR sans serveur

À partir d'Amazon EMR 6.9.0, vous pouvez utiliser des images personnalisées pour regrouper les dépendances des applications et les environnements d'exécution dans un conteneur unique avec Amazon EMR Serverless. Cela simplifie la gestion des dépendances de charge de travail et rend vos packages plus portables. Lorsque vous personnalisez votre image EMR Serverless, elle offre les avantages suivants :

- Installe et configure des packages optimisés pour vos charges de travail. Ces packages ne sont peut-être pas largement disponibles dans la distribution publique des environnements EMR d'exécution Amazon.



- Intègre le EMR mode Serverless aux processus actuels de création, de test et de déploiement établis au sein de votre organisation, y compris le développement et les tests locaux.
- Applique des processus de sécurité établis, tels que la numérisation d'images, qui répondent aux exigences de conformité et de gouvernance au sein de votre organisation.
- Vous permet d'utiliser vos propres versions JDK de Python pour vos applications.

EMRServerless fournit des images que vous pouvez utiliser comme base lorsque vous créez vos propres images. L'image de base fournit les fichiers JAR, la configuration et les bibliothèques essentiels pour que l'image interagisse avec EMR Serverless. Vous pouvez trouver l'image de base dans la [galerie ECR publique Amazon](#). Utilisez l'image correspondant au type d'application (Spark ou Hive) et à la version de votre version. Par exemple, si vous créez une application sur Amazon EMR version 6.9.0, utilisez les images suivantes.

Type	Image
Spark	public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest
Hive	public.ecr.aws/emr-serverless/hive/emr-6.9.0:latest

## Prérequis

Avant de créer une image personnalisée EMR sans serveur, remplissez ces conditions préalables.

1. Créez un ECR référentiel Amazon dans le même Région AWS que vous utilisez pour lancer des applications EMR sans serveur. Pour créer un dépôt ECR privé Amazon, consultez [Création d'un dépôt privé](#).
2. Pour autoriser les utilisateurs à accéder à votre ECR référentiel Amazon, ajoutez les politiques suivantes aux utilisateurs et aux rôles qui créent ou mettent à jour des applications EMR sans serveur avec des images provenant de ce référentiel.

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

```

    "Effect": "Allow",
    "Action": [
        "ecr:GetDownloadUrlForLayer",
        "ecr:BatchGetImage",
        "ecr:DescribeImages"
    ],
    "Resource": "ecr-repository-arn"
  }
]
}

```

Pour plus d'exemples de politiques basées sur l'ECRidentité d'Amazon, consultez les exemples de politiques basées sur l'[identité d'Amazon Elastic Container Registry](#).

## Étape 1 : créer une image personnalisée à partir d'images de base EMR sans serveur

Créez d'abord un [Dockerfile](#) qui commence par une FROM instruction utilisant votre image de base préférée. Après les FROM instructions, vous pouvez inclure toute modification que vous souhaitez apporter à l'image. L'image de base définit automatiquement le USER àhadoop. Il est possible que ce paramètre ne dispose pas des autorisations nécessaires pour toutes les modifications que vous incluez. Pour contourner le problème, réglez le USER paramètre surroot, modifiez votre image, puis USER redéfinissez le paramètre sur. hadoop:hadoop Pour consulter des exemples de cas d'utilisation courants, consultez[Utilisation d'images personnalisées avec EMR Serverless](#).

```

# Dockerfile
FROM public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest

USER root
# MODIFICATIONS GO HERE

# EMRS will run the image as hadoop
USER hadoop:hadoop

```

Une fois que vous avez le Dockerfile, créez l'image à l'aide de la commande suivante.

```

# build the docker image
docker build . -t aws-account-id.dkr.ecr.region.amazonaws.com/my-repository[:tag]or[@digest]

```

## Étape 2 : Valider l'image localement

EMRServerless fournit un outil hors ligne qui permet de vérifier statiquement votre image personnalisée pour valider les fichiers de base, les variables d'environnement et les configurations d'image correctes. Pour plus d'informations sur l'installation et l'exécution de l'outil, consultez [l'image CLI GitHub Amazon EMR Serverless](#).

Après avoir installé l'outil, exécutez la commande suivante pour valider une image :

```
amazon-emr-serverless-image \
validate-image -r emr-6.9.0 -t spark \
-i aws-account-id.dkr.ecr.region.amazonaws.com/my-repository:tag/@digest
```

Vous devriez voir un résultat similaire à ce qui suit.

```
Amazon EMR Serverless - Image CLI
Version: 0.0.1
... Checking if docker cli is installed
... Checking Image Manifest
[INFO] Image ID: 9e2f4359cf5beb466a8a2ed047ab61c9d37786c555655fc122272758f761b41a
[INFO] Created On: 2022-12-02T07:46:42.586249984Z
[INFO] Default User Set to hadoop:hadoop : PASS
[INFO] Working Directory Set to : PASS
[INFO] Entrypoint Set to /usr/bin/entrypoint.sh : PASS
[INFO] HADOOP_HOME is set with value: /usr/lib/hadoop : PASS
[INFO] HADOOP_LIBEXEC_DIR is set with value: /usr/lib/hadoop/libexec : PASS
[INFO] HADOOP_USER_HOME is set with value: /home/hadoop : PASS
[INFO] HADOOP_YARN_HOME is set with value: /usr/lib/hadoop-yarn : PASS
[INFO] HIVE_HOME is set with value: /usr/lib/hive : PASS
[INFO] JAVA_HOME is set with value: /etc/alternatives/jre : PASS
[INFO] TEZ_HOME is set with value: /usr/lib/tez : PASS
[INFO] YARN_HOME is set with value: /usr/lib/hadoop-yarn : PASS
[INFO] File Structure Test for hadoop-files in /usr/lib/hadoop: PASS
[INFO] File Structure Test for hadoop-jars in /usr/lib/hadoop/lib: PASS
[INFO] File Structure Test for hadoop-yarn-jars in /usr/lib/hadoop-yarn: PASS
[INFO] File Structure Test for hive-bin-files in /usr/bin: PASS
[INFO] File Structure Test for hive-jars in /usr/lib/hive/lib: PASS
[INFO] File Structure Test for java-bin in /etc/alternatives/jre/bin: PASS
[INFO] File Structure Test for tez-jars in /usr/lib/tez: PASS
-----
Overall Custom Image Validation Succeeded.
-----
```

## Étape 3 : Chargez l'image dans votre ECR référentiel Amazon

Transférez votre ECR image Amazon vers votre ECR référentiel Amazon à l'aide des commandes suivantes. Assurez-vous de disposer des IAM autorisations appropriées pour transférer l'image vers votre référentiel. Pour plus d'informations, consultez la [section Envoyer une image](#) dans le guide de ECR l'utilisateur Amazon.

```
# login to ECR repo
aws ecr get-login-password --region region | docker login --username AWS --password-
stdin aws-account-id.dkr.ecr.region.amazonaws.com

# push the docker image
docker push aws-account-id.dkr.ecr.region.amazonaws.com/my-repository:tag/@digest
```

## Étape 4 : créer ou mettre à jour une application avec des images personnalisées

Cliquez sur l'onglet AWS Management Console onglet ou AWS CLI onglet en fonction de la façon dont vous souhaitez lancer votre application, puis effectuez les étapes suivantes.

### Console

1. Connectez-vous à la console EMR Studio à l'adresse <https://console.aws.amazon.com/emr>. Accédez à votre application ou créez-en une nouvelle en suivant les instructions de la section [Créer une application](#).
2. Pour spécifier des images personnalisées lorsque vous créez ou mettez à jour une application EMR sans serveur, sélectionnez Paramètres personnalisés dans les options de configuration de l'application.
3. Dans la section Paramètres d'image personnalisés, cochez la case Utiliser l'image personnalisée avec cette application.
4. Collez l'ECR image Amazon URI dans le URI champ Image. EMRServerless utilise cette image pour tous les types de travailleurs de l'application. Vous pouvez également choisir Différentes images personnalisées et coller une ECR image Amazon différente URIs pour chaque type de travailleur.

## CLI

- Créez une application avec le `image-configuration` paramètre. EMRServerless applique ce paramètre à tous les types de travailleurs.

```
aws emr-serverless create-application \  
--release-label emr-6.9.0 \  
--type SPARK \  
--image-configuration '{  
    "imageUri": "aws-account-id.dkr.ecr.region.amazonaws.com/my-repository:tag/  
@digest"  
'
```

Pour créer une application avec des paramètres d'image différents pour chaque type de travailleur, utilisez le `worker-type-specifications` paramètre.

```
aws emr-serverless create-application \  
--release-label emr-6.9.0 \  
--type SPARK \  
--worker-type-specifications '{  
    "Driver": {  
        "imageConfiguration": {  
            "imageUri": "aws-account-id.dkr.ecr.region.amazonaws.com/my-  
repository:tag/@digest"  
        }  
    },  
    "Executor" : {  
        "imageConfiguration": {  
            "imageUri": "aws-account-id.dkr.ecr.region.amazonaws.com/my-  
repository:tag/@digest"  
        }  
    }  
'
```

Pour mettre à jour une application, utilisez le `image-configuration` paramètre. EMRServerless applique ce paramètre à tous les types de travailleurs.

```
aws emr-serverless update-application \  
--application-id application-id \  
--image-configuration '{
```

```
"imageUri": "aws-account-id.dkr.ecr.region.amazonaws.com/my-repository:tag/  
@digest"  
'
```

## Étape 5 : Autoriser EMR Serverless à accéder au référentiel d'images personnalisé

Ajoutez la politique de ressources suivante au ECR référentiel Amazon pour permettre au principal du service EMR Serverless d'utiliser les `download` demandes `getdescribe`, et provenant de ce référentiel.

```
{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Sid": "Emr Serverless Custom Image Support",  
      "Effect": "Allow",  
      "Principal": {  
        "Service": "emr-serverless.amazonaws.com"  
      },  
      "Action": [  
        "ecr:BatchGetImage",  
        "ecr:DescribeImages",  
        "ecr:GetDownloadUrlForLayer"  
      ],  
      "Condition": {  
        "StringEquals": {  
          "aws:SourceArn": "arn:aws:emr-serverless:region:aws-account-id:/  
applications/application-id"  
        }  
      }  
    }  
  ]  
}
```

La meilleure pratique en matière de sécurité consiste à ajouter une clé de `aws:SourceArn` condition à la politique du référentiel. La clé de condition IAM globale `aws:SourceArn` garantit que EMR Serverless utilise le référentiel uniquement pour une applicationARN. Pour plus d'informations sur les politiques relatives aux ECR référentiels Amazon, consultez [Création d'un référentiel privé](#).

## Considérations et restrictions

Lorsque vous travaillez avec des images personnalisées, tenez compte des points suivants :

- Utilisez l'image de base correcte qui correspond au type (Spark ou Hive) et à l'étiquette de version (par exemple `emr-6.9.0`) de votre application.
- EMR Serverless ignore les `[ENTRYPOINT]` instructions `[CMD]` contenues dans le fichier Docker. Utilisez les instructions courantes du fichier Docker, telles que `[COPY]` `[RUN]`, et `[WORKDIR]`.
- Vous ne devez pas modifier `JAVA_HOME` les variables `SPARK_HOME` d'`HIVE_HOME` environnement `TEZ_HOME` lorsque vous créez une image personnalisée.
- La taille des images personnalisées ne peut pas dépasser 5 Go.
- Si vous modifiez des fichiers binaires ou des fichiers JAR dans les images de EMR base d'Amazon, cela peut entraîner des échecs de lancement d'applications ou de tâches.
- Le ECR référentiel Amazon doit se trouver dans le même Région AWS que vous utilisez pour lancer des applications EMR sans serveur.

## Configuration de VPC l'accès

Vous pouvez configurer des applications EMR sans serveur pour qu'elles se connectent à vos magasins de données VPC, tels que les clusters Amazon Redshift, les bases de données Amazon ou les RDS compartiments Amazon S3 avec points de terminaison. VPC Votre application EMR Serverless dispose d'une connectivité sortante vers les magasins de données qu'il contient. VPC Par défaut, EMR Serverless bloque l'accès entrant à vos applications afin d'améliorer la sécurité.

### Note

Vous devez configurer VPC l'accès si vous souhaitez utiliser une base de données de métastore Hive externe pour votre application. [Pour plus d'informations sur la configuration d'un métastore Hive externe, consultez la section Configuration du métastore.](#)

## Créer une application

Sur la page Créer une application, vous pouvez choisir des paramètres personnalisés et spécifier les VPC sous-réseaux et les groupes de sécurité que les applications EMR sans serveur peuvent utiliser.

## VPCs

Choisissez le nom du cloud privé virtuel (VPC) qui contient vos magasins de données. La page Créer une application répertorie toutes les VPCs applications que vous avez choisies Région AWS.

## Sous-réseaux

Choisissez les sous-réseaux dans lesquels se VPC trouve votre banque de données. La page Créer une application répertorie tous les sous-réseaux des magasins de données de votreVPC.

Les sous-réseaux sélectionnés doivent être des sous-réseaux privés. Cela signifie que les tables de routage associées aux sous-réseaux ne doivent pas comporter de passerelles Internet.

Pour la connectivité sortante à Internet, les sous-réseaux doivent disposer de routes sortantes utilisant une passerelle. NAT Pour configurer une NAT passerelle, consultez la section [Utilisation des NAT passerelles](#).

Pour la connectivité Amazon S3, les sous-réseaux doivent avoir une NAT passerelle ou un VPC point de terminaison configuré. Pour configurer un point de VPC terminaison S3, consultez la section [Créer un point de terminaison de passerelle](#).

Pour la connectivité à d'autres Services AWS en dehors deVPC, comme Amazon DynamoDB, vous devez configurer des points de terminaison VPC ou une passerelle. NAT Pour configurer les VPC points de terminaison pour Services AWS, voir Utilisation [des VPC points de terminaison](#).

Les employés peuvent se connecter aux magasins de données au sein de votre VPC entreprise via le trafic sortant. Par défaut, EMR Serverless bloque l'accès entrant aux employés afin d'améliorer la sécurité.

Lorsque vous utilisez AWS Config, EMR Serverless crée un enregistrement d'élément Elastic Network Interface pour chaque travailleur. Pour éviter les coûts liés à cette ressource, pensez AWS : : EC2 : : NetworkInterface à la désactiver AWS Config.

### Note

Nous vous recommandons de sélectionner plusieurs sous-réseaux dans plusieurs zones de disponibilité. Cela est dû au fait que les sous-réseaux que vous choisissez déterminent les zones de disponibilité disponibles pour le lancement d'une application EMR sans serveur. Chaque travailleur consommera une adresse IP sur le sous-réseau où il est lancé. Assurez-vous que les sous-réseaux spécifiés possèdent suffisamment d'adresses IP pour le nombre de travailleurs que vous prévoyez de lancer. Pour plus d'informations sur la planification des



sous-réseaux, consultez [the section called “Bonnes pratiques pour la planification des sous-réseaux”](#).

## Groupes de sécurité

Choisissez un ou plusieurs groupes de sécurité qui peuvent communiquer avec vos magasins de données. La page Créer une application répertorie tous les groupes de sécurité de votre VPC. EMR Serverless associe ces groupes de sécurité à des interfaces réseau élastiques associées à vos VPC sous-réseaux.

### Note

Nous vous recommandons de créer un groupe de sécurité distinct pour les applications EMR sans serveur. Cela permet d'isoler et de gérer les règles du réseau plus efficacement. Par exemple, pour communiquer avec les clusters Amazon Redshift, vous pouvez définir les règles de trafic entre les groupes de sécurité Redshift et EMR Serverless, comme illustré dans l'exemple ci-dessous.

### Exemple Exemple — Communication avec les clusters Amazon Redshift

1. Ajoutez une règle pour le trafic entrant au groupe de sécurité Amazon Redshift depuis l'un des EMR groupes de sécurité Serverless.

Type	Protocole	Plage de ports	Source
Tout TCP	TCP	5439	emr-serverless-security-group

2. Ajoutez une règle pour le trafic sortant de l'un des groupes de sécurité EMR Serverless. Vous pouvez effectuer cette opération de deux manières. Tout d'abord, vous pouvez ouvrir le trafic sortant à tous les ports.

Type	Protocole	Plage de ports	Destination
Tout le trafic	TCP	ALL	0.0.0.0/0

Vous pouvez également restreindre le trafic sortant vers les clusters Amazon Redshift. Cela n'est utile que lorsque l'application doit communiquer avec les clusters Amazon Redshift et rien d'autre.

Type	Protocole	Plage de ports	Source
Tout TCP	TCP	5439	redshift-security-group

## Configuration de l'application

Vous pouvez modifier la configuration réseau d'une application EMR sans serveur existante à partir de la page Configurer l'application.

### Afficher les détails de l'exécution des tâches

Sur la page détaillée de l'exécution du job, vous pouvez voir le sous-réseau utilisé par votre job pour une exécution spécifique. Notez qu'une tâche ne s'exécute que dans un sous-réseau sélectionné parmi les sous-réseaux spécifiés.

## Bonnes pratiques pour la planification des sous-réseaux

AWS les ressources sont créées dans un sous-réseau qui est un sous-ensemble d'adresses IP disponibles dans un Amazon VPC. Par exemple, un réseau doté d'un masque de réseau /16 possède jusqu'à 65 536 adresses IP disponibles qui peuvent être réparties en plusieurs réseaux plus petits à l'aide de masques de sous-réseau. Par exemple, vous pouvez diviser cette plage en deux sous-réseaux, chacun utilisant le masque /17 et 32 768 adresses IP disponibles. Un sous-réseau réside dans une zone de disponibilité et ne peut pas s'étendre sur plusieurs zones.

Les sous-réseaux doivent être conçus en tenant compte des limites de dimensionnement de votre application EMR Serverless. Par exemple, si vous avez une application qui demande 4 vCpu travailleurs et peut être étendue jusqu'à 4 000 vCpu, votre application aura besoin d'au plus 1 000 travailleurs pour un total de 1 000 interfaces réseau. Nous vous recommandons de créer des sous-réseaux dans plusieurs zones de disponibilité. Cela permet à EMR Serverless de réessayer votre tâche ou de fournir une capacité préinitialisée dans une autre zone de disponibilité dans le cas peu

probable d'une défaillance d'une zone de disponibilité. Par conséquent, chaque sous-réseau d'au moins deux zones de disponibilité doit avoir plus de 1 000 adresses IP disponibles.

Vous avez besoin de sous-réseaux dont la taille de masque est inférieure ou égale à 22 pour approvisionner 1 000 interfaces réseau. Tout masque supérieur à 22 ne répondra pas à cette exigence. Par exemple, un masque de sous-réseau de /23 fournit 512 adresses IP, tandis qu'un masque de /22 fournit 1024 et un masque de /21 fournit 2048 adresses IP. Vous trouverez ci-dessous un exemple de 4 sous-réseaux avec un masque /22 dans un VPC masque réseau /16 qui peuvent être alloués à différentes zones de disponibilité. Il existe une différence de cinq entre les adresses IP disponibles et utilisables, car les quatre premières adresses IP et la dernière adresse IP de chaque sous-réseau sont réservées par AWS.

ID de sous-réseau (subnet)	Adresse du sous-réseau	Masque de sous-réseau	Plage d'adresses IP	Adresses IP disponibles	Adresses IP utilisables
1	10,0.0.0	255,255,252,0/22	10.0.0.0 - 10.0.3.255	1,024	1 019
2	10.0.4.0	255,255,252,0/22	10.0.4.0 - 10.0.7.255	1,024	1 019
3	10,0.8.0	255,255,252,0/22	10.0.4.0 - 10.0.7.255	1,024	1 019
4	10,0.12,0	255,255,252,0/22	10,0.12,0 - 10,0.15,255	1,024	1 019

Vous devez évaluer si votre charge de travail convient le mieux à des travailleurs de plus grande taille. L'utilisation de travailleurs de plus grande taille nécessite moins d'interfaces réseau. Par exemple, l'utilisation de 16 vCpu travailleurs avec une limite de dimensionnement des applications de 4 000 vCpu nécessitera au maximum 250 travailleurs pour un total de 250 adresses IP disponibles pour configurer les interfaces réseau. Vous avez besoin de sous-réseaux répartis dans plusieurs zones de disponibilité avec une taille de masque inférieure ou égale à 24 pour approvisionner 250 interfaces réseau. Toute taille de masque supérieure à 24 propose moins de 250 adresses IP.

Si vous partagez des sous-réseaux entre plusieurs applications, chaque sous-réseau doit être conçu en tenant compte des limites d'échelle collectives de toutes vos applications. Par exemple, si vous

avez 3 applications demandant 4 vCpu travailleurs et que chacune peut atteindre 4 000 vCpu avec un quota basé sur le service de 12 000 vCpu au niveau du compte, chaque sous-réseau aura besoin de 3 000 adresses IP disponibles. Si le nombre d'adresses IP VPC que vous souhaitez utiliser n'est pas suffisant, essayez d'augmenter le nombre d'adresses IP disponibles. Vous pouvez le faire en associant des blocs Classless Inter-Domain Routing (CIDR) supplémentaires à votre VPC. Pour plus d'informations, consultez [Associer des IPv4 CIDR blocs supplémentaires à votre VPC](#) dans le guide de VPC l'utilisateur Amazon.

Vous pouvez utiliser l'un des nombreux outils disponibles en ligne pour générer rapidement des définitions de sous-réseaux et passer en revue la plage d'adresses IP disponibles.

## Options d'architecture Amazon EMR Serverless

L'architecture du jeu d'instructions de votre application Amazon EMR Serverless détermine le type de processeurs que l'application utilise pour exécuter la tâche. Amazon EMR propose deux options d'architecture pour votre application : x86\_64 et arm64. EMRServerless est automatiquement mis à jour vers la dernière génération d'instances dès qu'elles sont disponibles, afin que vos applications puissent utiliser les nouvelles instances sans que vous ayez à faire des efforts supplémentaires.

### Rubriques

- [Utilisation de l'architecture x86\\_64](#)
- [Utilisation de l'architecture arm64 \(Graviton\)](#)
- [Lancement de nouvelles applications avec le support de Graviton](#)
- [Configuration des applications existantes pour utiliser Graviton](#)
- [Considérations relatives à l'utilisation de Graviton](#)

## Utilisation de l'architecture x86\_64

L'architecture x86\_64 est également connue sous le nom de x86 64 bits ou x64. x86\_64 est l'option par défaut pour EMR les applications sans serveur. Cette architecture utilise des processeurs x86 et est compatible avec la plupart des outils et bibliothèques tiers.

La plupart des applications sont compatibles avec la plate-forme matérielle x86 et peuvent fonctionner correctement sur l'architecture x86\_64 par défaut. Toutefois, si votre application est compatible avec 64 bits ARM, vous pouvez passer à arm64 pour utiliser les processeurs Graviton afin d'améliorer les performances, la puissance de calcul et la mémoire. Exécuter des instances sur une

architecture arm64 coûte moins cher que lorsque vous exécutez des instances de taille égale sur une architecture x86.

## Utilisation de l'architecture arm64 (Graviton)

AWS Les processeurs Graviton sont conçus sur mesure par AWS avec des cœurs ARM Neoverse 64 bits et tire parti de l'architecture arm64 (également connue sous le nom d'Arch64 ou 64 bits). ARM Le AWS La gamme de processeurs Graviton disponible sur EMR Serverless inclut les processeurs Graviton3 et Graviton2. Ces processeurs offrent un rapport prix/performances supérieur pour les charges de travail Spark et Hive par rapport aux charges de travail équivalentes exécutées sur l'architecture x86\_64. EMRServerless utilise automatiquement la dernière génération de processeurs lorsqu'elle est disponible, sans aucun effort de votre part pour passer à la dernière génération de processeurs.

## Lancement de nouvelles applications avec le support de Graviton

Utilisez l'une des méthodes suivantes pour lancer une application utilisant l'architecture arm64.

### AWS CLI

Pour lancer une application à l'aide de processeurs Graviton depuis AWS CLI, spécifiez ARM64 comme architecture paramètre dans le `create-applicationAPI`. Indiquez les valeurs appropriées pour votre application dans les autres paramètres.

```
aws emr-serverless create-application \  
  --name my-graviton-app \  
  --release-label emr-6.8.0 \  
  --type "SPARK" \  
  --architecture "ARM64" \  
  --region us-west-2
```

### EMR Studio

Pour lancer une application utilisant les processeurs Graviton de EMR Studio, choisissez arm64 comme option Architecture lorsque vous créez ou mettez à jour une application.

## Configuration des applications existantes pour utiliser Graviton

Vous pouvez configurer vos applications Amazon EMR Serverless existantes pour utiliser l'architecture Graviton (arm64) avec, SDK AWS CLI, ou EMR Studio.

## Pour convertir une application existante de x86 en arm64

1. Vérifiez que vous utilisez la dernière version majeure du [AWS CLI/SDK](#) qui prend en charge le paramètre d'architecture.
2. Vérifiez qu'aucune tâche n'est en cours d'exécution, puis arrêtez l'application.

```
aws emr-serverless stop-application \  
  --application-id application-id \  
  --region us-west-2
```

3. Pour mettre à jour l'application afin d'utiliser Graviton, spécifiez ARM64 le paramètre d'architecture dans le `update-applicationAPI`.

```
aws emr-serverless update-application \  
  --application-id application-id \  
  --architecture 'ARM64' \  
  --region us-west-2
```

4. Pour vérifier que l'architecture CPU de l'application est actuelle ARM64, utilisez le `get-applicationAPI`.

```
aws emr-serverless get-application \  
  --application-id application-id \  
  --region us-west-2
```

5. Lorsque vous êtes prêt, redémarrez l'application.

```
aws emr-serverless start-application \  
  --application-id application-id \  
  --region us-west-2
```

## Considérations relatives à l'utilisation de Graviton

Avant de lancer une application EMR sans serveur utilisant arm64 pour le support de Graviton, vérifiez les points suivants.

### Compatibilité avec les bibliothèques

Lorsque vous sélectionnez Graviton (arm64) comme option d'architecture, assurez-vous que les packages et bibliothèques tiers sont compatibles avec l'architecture 64 bits ARM. Pour plus

d'informations sur la façon d'empaqueter des bibliothèques Python dans un environnement virtuel Python compatible avec l'architecture que vous avez sélectionnée, consultez [Utilisation de bibliothèques Python avec EMR Serverless](#).

Pour en savoir plus sur la configuration d'une charge de travail Spark ou Hive pour une utilisation en 64 bits ARM, consultez le [AWS Le](#) référentiel Graviton Getting Started est activé. GitHub Ce référentiel contient des ressources essentielles qui peuvent vous aider à démarrer avec le système ARM basé sur Graviton.

# Transférez des données dans S3 Express One Zone avec EMR Serverless

Avec les EMR versions 7.2.0 et supérieures d'Amazon, vous pouvez utiliser EMR Serverless avec la classe de stockage [Amazon S3 Express One Zone](#) pour améliorer les performances lorsque vous exécutez des tâches et des charges de travail. S3 Express One Zone est une classe de stockage Amazon S3 à zone unique à hautes performances qui fournit un accès aux données constant à un chiffre en millisecondes pour la plupart des applications sensibles à la latence. À son lancement, S3 Express One Zone offre la latence la plus faible et les meilleures performances de stockage d'objets cloud dans Amazon S3.

## Prérequis

- Autorisations de zone S3 Express One : lorsque S3 Express One Zone effectue initialement une action similaire GET ou PUT sur un objet S3, la classe de stockage appelle `CreateSession` en votre nom. LIST Votre IAM politique doit autoriser `!s3express:CreateSession` afin que le S3A le connecteur peut invoquer le `CreateSessionAPI`. Pour obtenir un exemple de politique avec cette autorisation, voir la rubrique [Bien démarrer avec S3 Express One Zone](#).
- S3A connecteur — Pour configurer Spark afin d'accéder aux données d'un compartiment Amazon S3 utilisant la classe de stockage S3 Express One Zone, vous devez utiliser le connecteur Apache Hadoop S3A. Pour utiliser le connecteur, assurez-vous que tous les S3 URIs utilisent le `s3a` schéma. Si ce n'est pas le cas, vous pouvez modifier l'implémentation du système de fichiers que vous utilisez pour les schémas `s3` et `s3n`.

Pour modifier le schéma `s3`, spécifiez les configurations de cluster suivantes :

```
[
  {
    "Classification": "core-site",
    "Properties": {
      "fs.s3.impl": "org.apache.hadoop.fs.s3a.S3AFileSystem",
      "fs.AbstractFileSystem.s3.impl": "org.apache.hadoop.fs.s3a.S3A"
    }
  }
]
```



Pour modifier le schéma s3n, spécifiez les configurations de cluster suivantes :

```
[
  {
    "Classification": "core-site",
    "Properties": {
      "fs.s3n.impl": "org.apache.hadoop.fs.s3a.S3AFileSystem",
      "fs.AbstractFileSystem.s3n.impl": "org.apache.hadoop.fs.s3a.S3A"
    }
  }
]
```

## Bien démarrer avec S3 Express One Zone

Suivez ces étapes pour commencer à utiliser S3 Express One Zone.

1. [Créez un VPC point de terminaison](#). Ajoutez le point de terminaison `com.amazonaws.us-west-2.s3express` au VPC point de terminaison.
2. Suivez [Getting started with Amazon EMR Serverless](#) pour créer une application avec le label de EMR version 7.2.0 ou supérieur d'Amazon.
3. [Configurez votre application](#) pour utiliser le point de VPC terminaison nouvellement créé, un groupe de sous-réseaux privés et un groupe de sécurité.
4. Ajoutez l'`CreateSession` autorisation à votre rôle d'exécution des tâches.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Resource": "*",
      "Action": [
        "s3express:CreateSession"
      ]
    }
  ]
}
```

5. Exécutez votre travail. Notez que vous devez utiliser le S3A schéma pour accéder aux compartiments S3 Express One Zone.

```
aws emr-serverless start-job-run \  
--application-id <application-id> \  
--execution-role-arn <job-role-arn> \  
--name <job-run-name> \  
--job-driver '{  
  "sparkSubmit": {  
  
    "entryPoint": "s3a://<DOC-EXAMPLE-BUCKET>/scripts/wordcount.py",  
    "entryPointArguments":["s3a://<DOC-EXAMPLE-BUCKET>/emr-serverless-spark/output"],  
    "sparkSubmitParameters": "--conf spark.executor.cores=4  
--conf spark.executor.memory=8g --conf spark.driver.cores=4  
--conf spark.driver.memory=8g --conf spark.executor.instances=2  
--conf spark.hadoop.fs.s3a.change.detection.mode=none  
--conf spark.hadoop.fs.s3a.endpoint.region={<AWS_REGION>}  
--conf spark.hadoop.fs.s3a.select.enabled=false  
--conf spark.sql.sources.fastS3PartitionDiscovery.enabled=false  
  }'  
'
```

# Exécution de tâches

Après avoir soumis votre candidature, vous pouvez y soumettre des offres d'emploi. Cette section explique comment utiliser le AWS CLI pour exécuter ces tâches. Cette section identifie également les valeurs par défaut pour chaque type d'application disponible sur EMR Serverless.

## Rubriques

- [États d'exécution de la tâche](#)
- [Exécution de tâches depuis la console EMR Studio](#)
- [Exécution de tâches à partir du AWS CLI](#)
- [Utilisation de disques optimisés pour le shuffle](#)
- [Offres d'emploi en streaming](#)
- [Offres d'emploi Spark](#)
- [Offres d'emploi Hive](#)
- [EMR Résilience des Job sans serveur](#)
- [Configuration du métastore](#)
- [Accès aux données S3 dans un autre AWS compte depuis EMR Serverless](#)
- [Résolution des erreurs dans EMR Serverless](#)

## États d'exécution de la tâche

Lorsque vous soumettez une tâche exécutée à une file d'attente de tâches Amazon EMR Serverless, la tâche exécutée entre dans l'`SUBMITTED` état. L'état d'une tâche passe de « à » `SUBMITTED` `RUNNING` jusqu'à ce qu'il atteigne `FAILED` `SUCCESS`, ou `CANCELLING`.

Les exécutions de tâches peuvent avoir les états suivants :

État	Description
Soumis	État initial de la tâche lorsque vous soumettez une tâche exécutée à EMR Serverless. Le poste attend d'être programmé pour la candidature. EMR Serverless commence à prioriser et à planifier l'exécution du travail.

État	Description
En suspens	Le planificateur évalue l'exécution du travail afin de prioriser et de planifier l'exécution de l'application.
Programmé	EMRServerless a planifié l'exécution de la tâche pour l'application et alloue des ressources pour exécuter la tâche.
En cours d'exécution	EMRServerless a alloué les ressources dont la tâche a initialement besoin, et la tâche est en cours d'exécution dans l'application. Dans les applications Spark, cela signifie que le processus du pilote Spark est en état <code>running</code> .
Échec	EMRServerless n'a pas réussi à soumettre le travail exécuté à l'application, ou il s'est terminé sans succès. Consultez <code>StateDetails</code> pour plus d'informations sur cet échec de tâche.
Succès	L'exécution de la tâche s'est terminée avec succès.
Annulation	<code>CancelJobRun</code> API a demandé l'annulation de l'exécution du travail, ou le délai d'exécution du travail a expiré. EMRServerless essaie d'annuler la tâche dans l'application et de libérer les ressources.
Annulée	L'exécution de la tâche a été annulée avec succès et les ressources utilisées ont été libérées.

# Exécution de tâches depuis la console EMR Studio

Vous pouvez envoyer des exécutions de tâches à des applications EMR sans serveur et consulter les tâches depuis la console EMR Studio. Pour créer ou accéder à votre application EMR Serverless sur la console EMR Studio, suivez les instructions de la section [Mise en route depuis la console](#).

## Envoi d'une tâche

Sur la page Soumettre une tâche, vous pouvez soumettre une tâche à une application EMR sans serveur comme suit.

### Spark

1. Dans le champ Nom, saisissez le nom de l'exécution de votre tâche.
2. Dans le champ Rôle d'exécution, entrez le nom du IAM rôle que votre application EMR Serverless peut assumer pour l'exécution de la tâche. Pour en savoir plus sur les rôles d'exécution, voir [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).
3. Dans le champ Emplacement du script, entrez l'emplacement Amazon S3 du script ou du script JAR que vous souhaitez exécuter. Pour les tâches Spark, le script peut être un fichier Python (.py) ou un fichier JAR (.jar).
4. Si l'emplacement de votre script est un JAR fichier, entrez le nom de classe qui est le point d'entrée de la tâche dans le champ Classe principale.
5. (Facultatif) Entrez des valeurs pour les autres champs.
  - Arguments du script — Entrez les arguments que vous souhaitez transmettre à votre script principal JAR ou à votre script Python. Votre code lit ces paramètres. Séparez chaque argument du tableau par une virgule.
  - Propriétés de Spark — Développez la section des propriétés de Spark et entrez les paramètres de configuration de Spark dans ce champ.

#### Note

Si vous spécifiez la taille du pilote et de l'exécuteur Spark, vous devez tenir compte de la surcharge mémoire. Spécifiez les valeurs de surcharge de mémoire dans les propriétés `spark.driver.memoryOverhead` et `spark.executor.memoryOverhead`. La surcharge mémoire a une valeur par défaut de 10 % de la mémoire du conteneur, avec un minimum

de 384 Mo. La mémoire de l'exécuteur et la surcharge de mémoire réunies ne peuvent pas dépasser la mémoire de travail. Par exemple, le maximum `spark.executor.memory` d'un travailleur de 30 Go doit être de 27 Go.

- Configuration de la tâche — Spécifiez n'importe quelle configuration de tâche dans ce champ. Vous pouvez utiliser ces configurations de tâches pour remplacer les configurations par défaut des applications.
  - Paramètres supplémentaires — Activez ou désactivez AWS Glue Data Catalog en tant que métastore et modifiez les paramètres du journal des applications. Pour en savoir plus sur les configurations de métastore, consultez [Configuration du métastore](#). Pour en savoir plus sur les options de journalisation des applications, consultez [Stockage des journaux](#).
  - Balises — Attribuez des balises personnalisées à l'application.
6. Choisissez Soumettre une tâche.

## Hive

1. Dans le champ Nom, saisissez le nom de l'exécution de votre tâche.
2. Dans le champ Rôle d'exécution, entrez le nom du IAM rôle que votre application EMR Serverless peut assumer pour l'exécution de la tâche.
3. Dans le champ Emplacement du script, entrez l'emplacement Amazon S3 du script ou du script JAR que vous souhaitez exécuter. Pour les jobs Hive, le script doit être un fichier Hive (`.sql`).
4. (Facultatif) Entrez des valeurs pour les autres champs.
  - Emplacement du script d'initialisation : entrez l'emplacement du script qui initialise les tables avant l'exécution du script Hive.
  - Propriétés de la ruche — Développez la section des propriétés de la ruche et entrez les paramètres de configuration de la ruche dans ce champ.
  - Configuration de la tâche : spécifiez n'importe quelle configuration de tâche. Vous pouvez utiliser ces configurations de tâches pour remplacer les configurations par défaut des applications. Pour les tâches Hive, `hive.exec.scratchdir` et `hive.metastore.warehouse.dir` sont des propriétés obligatoires dans la `hive-site` configuration.

```
{  
  "applicationConfiguration": [  

```

```
{
  "classification": "hive-site",
  "configurations": [],
  "properties": {
    "hive.exec.scratchdir": "s3://DOC-EXAMPLE_BUCKET/hive/scratch",
    "hive.metastore.warehouse.dir": "s3://DOC-EXAMPLE_BUCKET/hive/warehouse"
  }
},
"monitoringConfiguration": {}
}
```

- Paramètres supplémentaires — Activez ou désactivez AWS Glue Data Catalog en tant que métastore et modifiez les paramètres du journal des applications. Pour en savoir plus sur les configurations de métastore, consultez [Configuration du métastore](#) Pour en savoir plus sur les options de journalisation des applications, consultez [Stockage des journaux](#).
- Balises : attribuez des balises personnalisées à l'application.

5. Choisissez Soumettre une tâche.

## Afficher les exécutions de tâches

Dans l'onglet Exécutions de tâches sur la page Détails d'une application, vous pouvez consulter les exécutions de tâches et effectuer les actions suivantes pour les exécutions de tâches.

Annuler la tâche : pour annuler l'exécution d'une tâche en l'`RUNNING` état, choisissez cette option. Pour en savoir plus sur les transitions d'exécution de tâches, voir [États d'exécution de la tâche](#).

Cloner une tâche : pour cloner une tâche précédente et la soumettre à nouveau, choisissez cette option.

## Exécution de tâches à partir du AWS CLI

Vous pouvez créer, décrire et supprimer des tâches individuelles sur AWS CLI. Vous pouvez également répertorier tous vos emplois pour les consulter en un coup d'œil.

Pour soumettre une nouvelle offre d'emploi, utilisez `start-job-run`. Indiquez l'ID de l'application que vous souhaitez exécuter, ainsi que les propriétés spécifiques à la tâche. Pour des exemples de

Spark, consultez [Offres d'emploi Spark](#). Pour des exemples de Hive, voir [Offres d'emploi Hive](#). Cette commande renvoie votre application-idARN, et un nouveau job-id.

Chaque tâche exécutée a une durée de temporisation définie. Si le travail est exécuté au-delà de cette durée, EMR Serverless l'annulera automatiquement. Le délai d'expiration par défaut est de 12 heures. Lorsque vous démarrez l'exécution de votre tâche, vous pouvez configurer ce paramètre de délai d'attente à une valeur qui répond aux exigences de votre tâche. Configurez la valeur avec la propriété `executionTimeoutMinutes`.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --execution-timeout-minutes 15 \
  --job-driver '{
    "hive": {
      "query": "s3://DOC-EXAMPLE-BUCKET/scripts/create_table.sql",
      "parameters": "--hiveconf hive.exec.scratchdir=s3://DOC-EXAMPLE-BUCKET/hive/scratch --hiveconf hive.metastore.warehouse.dir=s3://DOC-EXAMPLE-BUCKET/hive/warehouse"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "hive-site",
      "properties": {
        "hive.client.cores": "2",
        "hive.client.memory": "4GIB"
      }
    }]
  }'
```

Pour décrire un travail, utilisez `get-job-run`. Cette commande renvoie les configurations spécifiques à la tâche et la capacité définie pour votre nouvelle tâche.

```
aws emr-serverless get-job-run \
  --job-run-id job-id \
  --application-id application-id
```

Pour répertorier vos offres d'emploi, utilisez `list-job-runs`. Cette commande renvoie un ensemble abrégé de propriétés qui inclut le type de tâche, l'état et d'autres attributs de haut niveau. Si vous ne souhaitez pas voir toutes vos tâches, vous pouvez spécifier le nombre maximum de tâches que vous



souhaitez voir, jusqu'à 50. L'exemple suivant indique que vous souhaitez voir vos deux dernières tâches s'exécuter.

```
aws emr-serverless list-job-runs \  
--max-results 2 \  
--application-id application-id
```

Pour annuler une tâche, utilisez `cancel-job-run`. Indiquez le `application-id` et le `job-id` nom du travail que vous souhaitez annuler.

```
aws emr-serverless cancel-job-run \  
--job-run-id job-id \  
--application-id application-id
```

Pour plus d'informations sur la façon d'exécuter des tâches à partir du AWS CLI, consultez le manuel [EMRServerless API Reference](#).

## Utilisation de disques optimisés pour le shuffle

Avec les EMR versions 7.1.0 et supérieures d'Amazon, vous pouvez utiliser des disques optimisés pour le shuffle lorsque vous exécutez des tâches Apache Spark ou Hive afin d'améliorer les performances des charges de travail intensives en E/S. Par rapport aux disques standard, les disques optimisés pour le shuffle offrent des performances supérieures IOPS (opérations d'E/S par seconde) pour accélérer le mouvement des données et réduire le temps de latence lors des opérations de shuffle. Les disques optimisés pour le shuffle vous permettent d'associer des tailles de disque allant jusqu'à 2 To par utilisateur, afin que vous puissiez configurer la capacité adaptée à vos exigences en matière de charge de travail.

### Principaux avantages

Les disques optimisés pour le shuffle offrent les avantages suivants.

- **Hautes IOPS performances** : les disques optimisés pour le shuffle offrent des performances supérieures à IOPS celles des disques standard, ce qui permet un brassage des données plus efficace et plus rapide lors des tâches Spark et Hive et d'autres charges de travail intensives en matière de brassage.
- **Taille de disque plus importante** : les disques optimisés pour le shuffle prennent en charge des tailles de disque allant de 20 Go à 2 To par utilisateur. Vous pouvez donc choisir la capacité appropriée en fonction de vos charges de travail.

## Premiers pas

Consultez les étapes suivantes pour utiliser des disques optimisés pour le shuffle dans vos flux de travail.

### Spark

1. Créez une application EMR Serverless version 7.1.0 à l'aide de la commande suivante.

```
aws emr-serverless create-application \  
  --type "SPARK" \  
  --name my-application-name \  
  --release-label emr-7.1.0 \  
  --region <AWS_REGION>
```

2. Configurez votre tâche Spark pour inclure les paramètres `spark.emr-serverless.driver.disk.type` et/ou pour qu'elle s'exécute avec des disques optimisés `spark.emr-serverless.executor.disk.type` pour le shuffle. Vous pouvez utiliser l'un des paramètres ou les deux, selon votre cas d'utilisation.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "/usr/lib/spark/examples/jars/spark-examples.jar",  
      "entryPointArguments": ["1"],  
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi  
      --conf spark.executor.cores=4  
      --conf spark.executor.memory=20g  
      --conf spark.driver.cores=4  
      --conf spark.driver.memory=8g  
      --conf spark.executor.instances=1  
      --conf spark.emr-serverless.executor.disk.type=shuffle_optimized"  
    }  
  }'
```

Pour plus d'informations, consultez la section [Propriétés des tâches Spark](#).

## Hive

1. Créez une application EMR Serverless version 7.1.0 à l'aide de la commande suivante.

```
aws emr-serverless create-application \  
  --type "HIVE" \  
  --name my-application-name \  
  --release-label emr-7.1.0 \  
  --region <AWS_REGION>
```

2. Configurez votre tâche Hive pour inclure les paramètres `hive.driver.disk.type` et/ou `hive.tez.disk.type` pour qu'elle s'exécute avec des disques optimisés pour le shuffle. Vous pouvez utiliser l'un des paramètres ou les deux, selon votre cas d'utilisation.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "hive": {  
      "query": "s3://<DOC-EXAMPLE-BUCKET>/emr-serverless-hive/query/hive-  
query.q1",  
      "parameters": "--hiveconf hive.log.explain.output=false"  
    }  
  }' \  
  --configuration-overrides '{  
    "applicationConfiguration": [{  
      "classification": "hive-site",  
      "properties": {  
        "hive.exec.scratchdir": "s3://<DOC-EXAMPLE-BUCKET>/emr-  
serverless-hive/hive/scratch",  
        "hive.metastore.warehouse.dir": "s3://<DOC-EXAMPLE-BUCKET>/emr-  
serverless-hive/hive/warehouse",  
        "hive.driver.cores": "2",  
        "hive.driver.memory": "4g",  
        "hive.tez.container.size": "4096",  
        "hive.tez.cpu.vcores": "1",  
        "hive.driver.disk.type": "shuffle_optimized",  
        "hive.tez.disk.type": "shuffle_optimized"  
      }  
    }  
  }'  
}'
```

Pour plus d'informations, consultez les [propriétés des tâches Hive](#).

## Configuration d'une application avec une capacité pré-initialisée

Consultez les exemples suivants pour créer des applications basées sur la EMR version 7.1.0 d'Amazon. Les propriétés de ces applications sont les suivantes :

- 5 pilotes Spark préinitialisés, chacun doté de 2 VCPU, de 4 Go de mémoire et de 50 Go de disque optimisé pour le shuffle.
- 50 exécuteurs préinitialisés, chacun doté de 4 VCPU, de 8 Go de mémoire et de 500 Go de disque optimisé pour le shuffle.

Lorsque cette application exécute des tâches Spark, elle consomme d'abord les tâches préinitialisées, puis fait évoluer les tâches à la demande jusqu'à la capacité maximale de 400 V CPU et 1 024 Go de mémoire. Vous pouvez éventuellement omettre la capacité pour l'un DRIVER ou EXECUTOR l'autre.

## Spark

```
aws emr-serverless create-application \  
  --type "SPARK" \  
  --name <my-application-name> \  
  --release-label emr-7.1.0 \  
  --initial-capacity '{  
    "DRIVER": {  
      "workerCount": 5,  
      "workerConfiguration": {  
        "cpu": "2vCPU",  
        "memory": "4GB",  
        "disk": "50GB",  
        "diskType": "SHUFFLE_OPTIMIZED"  
      }  
    },  
    "EXECUTOR": {  
      "workerCount": 50,  
      "workerConfiguration": {  
        "cpu": "4vCPU",  
        "memory": "8GB",  
        "disk": "500GB",  
        "diskType": "SHUFFLE_OPTIMIZED"      }  
    }  
  }'
```

```
    }  
  }  
}' \  
--maximum-capacity '{  
  "cpu": "400vCPU",  
  "memory": "1024GB"  
}'
```

## Hive

```
aws emr-serverless create-application \  
--type "HIVE" \  
--name <my-application-name> \  
--release-label emr-7.1.0 \  
--initial-capacity '{  
  "DRIVER": {  
    "workerCount": 5,  
    "workerConfiguration": {  
      "cpu": "2vCPU",  
      "memory": "4GB",  
      "disk": "50GB",  
      "diskType": "SHUFFLE_OPTIMIZED"  
    }  
  },  
  "EXECUTOR": {  
    "workerCount": 50,  
    "workerConfiguration": {  
      "cpu": "4vCPU",  
      "memory": "8GB",  
      "disk": "500GB",  
      "diskType": "SHUFFLE_OPTIMIZED"  
    }  
  }  
}' \  
--maximum-capacity '{  
  "cpu": "400vCPU",  
  "memory": "1024GB"  
}'
```

## Offres d'emploi en streaming

Une tâche de streaming dans EMR Serverless est un mode de travail qui vous permet d'analyser et de traiter des données de streaming en temps quasi réel. Ces tâches de longue durée interrogent les données de streaming et traitent les résultats en continu au fur et à mesure de leur arrivée. Les tâches de streaming sont particulièrement adaptées aux tâches qui nécessitent un traitement des données en temps réel, telles que les analyses en temps quasi réel, la détection des fraudes et les moteurs de recommandations. EMR Les tâches de streaming sans serveur offrent des optimisations, telles que la résilience intégrée des tâches, une surveillance en temps réel, une gestion améliorée des journaux et l'intégration avec des connecteurs de streaming.

Voici quelques exemples d'utilisation des jobs de streaming :

- **Analyses en temps quasi réel** : les tâches de streaming dans Amazon EMR Serverless vous permettent de traiter les données de streaming en temps quasi réel. Vous pouvez ainsi effectuer des analyses en temps réel sur des flux de données continus, tels que des données de journal, des données de capteurs ou des données de parcours de navigation afin d'en tirer des informations et de prendre des décisions en temps opportun sur la base des informations les plus récentes.
- **Détection des fraudes** : vous pouvez utiliser les tâches de streaming pour détecter les fraudes en temps quasi réel dans les transactions financières, les opérations de carte de crédit ou les activités en ligne lorsque vous analysez des flux de données et identifiez des modèles ou des anomalies suspects au fur et à mesure qu'ils se produisent.
- **Moteurs de recommandation** : les tâches de streaming peuvent traiter les données d'activité des utilisateurs et mettre à jour les modèles de recommandations. Cela ouvre la voie à des recommandations personnalisées et en temps réel basées sur les comportements et les préférences.
- **Analyse des réseaux sociaux** : les jobs de streaming peuvent traiter les données des réseaux sociaux, telles que les tweets, les commentaires et les publications, afin que les entreprises puissent suivre les tendances, analyser les sentiments et gérer la réputation de la marque en temps quasi réel.
- **Analyse de l'Internet des objets (IoT)** : les tâches de streaming peuvent gérer et analyser des flux de données à haut débit provenant d'appareils IoT, de capteurs et de machines connectées, afin que vous puissiez exécuter la détection des anomalies, la maintenance prédictive et d'autres cas d'utilisation de l'analytique IoT.
- **Analyse du flux de clics** : les tâches de streaming peuvent traiter et analyser les données du flux de clics provenant de sites Web ou d'applications mobiles. Les entreprises qui utilisent de telles

données peuvent effectuer des analyses pour en savoir plus sur le comportement des utilisateurs, personnaliser les expériences utilisateur et optimiser les campagnes marketing.

- Surveillance et analyse des journaux : les tâches de streaming peuvent également traiter les données des journaux provenant de serveurs, d'applications et de périphériques réseau. Cela vous permet de détecter les anomalies, de résoudre les problèmes, ainsi que de garantir l'état et les performances du système.

## Principaux avantages

Les tâches de streaming dans EMR Serverless garantissent automatiquement la résilience des tâches, qui est une combinaison des facteurs suivants :

- Réessai automatique — EMR Serverless réessaie automatiquement toutes les tâches qui ont échoué sans aucune intervention manuelle de votre part.
- Résilience de la zone de disponibilité (AZ) : EMR Serverless fait automatiquement passer les tâches de streaming à une AZ saine si l'AZ d'origine rencontre des problèmes.
- Gestion des journaux :
  - Rotation des journaux : pour une gestion plus efficace du stockage sur disque, EMR Serverless fait régulièrement pivoter les journaux pour les tâches de streaming de longue durée. Cela permet d'éviter l'accumulation de journaux qui pourrait consommer tout l'espace disque.
  - Compaction des journaux : vous aide à gérer et à optimiser efficacement les fichiers journaux dans le cadre d'une persistance gérée. Le compactage améliore également l'expérience de débogage lorsque vous utilisez le serveur d'historique Spark géré.

## Sources de données et récepteurs de données pris en charge

EMR Serverless fonctionne avec un certain nombre de sources de données d'entrée et de récepteurs de données de sortie :

- Sources de données d'entrée prises en charge : Amazon Kinesis Data Streams, Amazon Managed Streaming for Apache Kafka et clusters Apache Kafka autogérés. Par défaut, les EMR versions 7.1.0 et supérieures d'Amazon incluent le connecteur [Amazon Kinesis Data Streams](#). Vous n'avez donc pas besoin de créer ou de télécharger de packages supplémentaires.
- Récepteurs de données de sortie pris en charge : AWS Tableaux du catalogue de données Glue, Amazon S3, Amazon Redshift, My, Postgre SQL OracleSQL, Oracle, Microsoft, Apache IcebergSQL, Delta Lake et Apache Hudi.

## Considérations et restrictions

Lorsque vous utilisez des jobs de streaming, gardez à l'esprit les considérations et limites suivantes.

- Les jobs de streaming sont pris en charge par les [EMRversions 7.1.0 et supérieures d'Amazon](#).
- EMRServerless s'attend à ce que les tâches de streaming s'exécutent pendant une longue période. Vous ne pouvez donc pas définir un délai d'exécution pour limiter le temps d'exécution de la tâche.
- Les jobs de streaming ne sont compatibles qu'avec le moteur Spark, qui repose sur le [framework de streaming structuré](#).
- EMRServerless réessaie indéfiniment des tâches de streaming, et vous ne pouvez pas personnaliser le nombre maximum de tentatives. La prévention du thrash est automatiquement incluse pour arrêter la nouvelle tentative si le nombre de tentatives infructueuses a dépassé un seuil défini sur une fenêtre horaire. Le seuil par défaut est de cinq tentatives infructueuses en une heure. Vous pouvez configurer ce seuil pour qu'il soit compris entre 1 et 10 tentatives. Pour plus d'informations, consultez la section [Résilience des emplois](#).
- Les tâches de streaming comportent des points de contrôle pour enregistrer l'état d'exécution et la progression, afin que EMR Serverless puisse reprendre la tâche de streaming à partir du dernier point de contrôle. Pour plus d'informations, consultez la section [Restauration après un échec avec le point de contrôle dans](#) la documentation d'Apache Spark.

## Commencer à diffuser des jobs

Consultez les instructions suivantes pour savoir comment démarrer avec les jobs de streaming.

1. Suivez [Getting started with Amazon EMR Serverless pour créer une application](#). Notez que votre application doit exécuter [Amazon EMR version 7.1.0](#) ou supérieure.
2. Une fois que votre candidature est prête, définissez le mode paramètre STREAMING sur pour soumettre une tâche de streaming, comme suit AWS CLI exemple.

```
aws emr-serverless start-job-run \  
--application-id <APPLICATION_ID> \  
--execution-role-arn <JOB_EXECUTION_ROLE> \  
--mode 'STREAMING' \  
--job-driver '{  
  "sparkSubmit": {  
    "entryPoint": "s3://<streaming script>",  
    "entryPointArguments": ["s3://<DOC-EXAMPLE-BUCKET-OUTPUT>/output"],
```



```
"sparkSubmitParameters": "--conf spark.executor.cores=4
    --conf spark.executor.memory=16g
    --conf spark.driver.cores=4
    --conf spark.driver.memory=16g
    --conf spark.executor.instances=3"
  }
}'
```

## Connecteurs de streaming pris en charge

Les connecteurs de streaming facilitent la lecture des données depuis une source de streaming et peuvent également écrire des données sur un récepteur de streaming.

Les connecteurs de streaming pris en charge sont les suivants :

### Connecteur Amazon Kinesis Data Streams

Le connecteur [Amazon Kinesis Data Streams](#) pour Apache Spark permet de créer des applications de streaming et des pipelines qui consomment des données depuis Amazon Kinesis Data Streams et y écrivent des données. Le connecteur prend en charge une consommation de ventilateur améliorée avec un débit de lecture dédié pouvant atteindre 2 Mo/seconde par partition. Par défaut, Amazon EMR Serverless 7.1.0 et versions ultérieures inclut le connecteur, vous n'avez donc pas besoin de créer ou de télécharger de packages supplémentaires. Pour plus d'informations sur le connecteur, consultez la [spark-sql-kinesis-connector page sur GitHub](#).

L'exemple suivant montre comment démarrer une tâche avec la dépendance du connecteur Kinesis Data Streams.

```
aws emr-serverless start-job-run \
--application-id <APPLICATION_ID> \
--execution-role-arn <JOB_EXECUTION_ROLE> \
--mode 'STREAMING' \
--job-driver '{
  "sparkSubmit": {
    "entryPoint": "s3://<Kinesis-streaming-script>",
    "entryPointArguments": ["s3://<DOC-EXAMPLE-BUCKET-OUTPUT>/output"],
    "sparkSubmitParameters": "--conf spark.executor.cores=4
      --conf spark.executor.memory=16g
      --conf spark.driver.cores=4
      --conf spark.driver.memory=16g
      --conf spark.executor.instances=3"
```

```
--jars /usr/share/aws/kinesis/spark-sql-kinesis/lib/spark-streaming-  
sql-kinesis-connector.jar"  
    }  
}'
```

Pour vous connecter à Kinesis Data Streams, vous devez configurer EMR l'application Serverless VPC avec un accès et utiliser VPC un point de terminaison pour autoriser l'accès privé, ou utiliser NAT une passerelle pour obtenir un accès public. Pour plus d'informations, consultez la section [Configuration de VPC l'accès](#). Vous devez également vous assurer que votre rôle d'exécution des tâches dispose des autorisations de lecture et d'écriture nécessaires pour accéder aux flux de données requis. Pour en savoir plus sur la configuration d'un rôle d'exécution de tâches, consultez la section [Rôles d'exécution de tâches pour Amazon EMR Serverless](#). Pour une liste complète de toutes les autorisations requises, consultez la [spark-sql-kinesis-connector page sur GitHub](#).

## Connecteur Apache Kafka

Le connecteur Apache Kafka pour le streaming structuré Spark est un connecteur open source créé par la communauté Spark et est disponible dans un référentiel Maven. Ce connecteur permet aux applications de streaming structuré Spark de lire et d'écrire des données depuis Apache Kafka autogéré et Amazon Managed Streaming for Apache Kafka. Pour plus d'informations sur le connecteur, consultez le [guide d'intégration de Structured Streaming + Kafka](#) dans la documentation d'Apache Spark.

L'exemple suivant montre comment inclure le connecteur Kafka dans votre demande d'exécution de tâche.

```
aws emr-serverless start-job-run \  
--application-id <APPLICATION_ID> \  
--execution-role-arn <JOB_EXECUTION_ROLE> \  
--mode 'STREAMING' \  
--job-driver '{  
    "sparkSubmit": {  
        "entryPoint": "s3://<Kafka-streaming-script>",  
        "entryPointArguments": ["s3://<DOC-EXAMPLE-BUCKET-OUTPUT>/output"],  
        "sparkSubmitParameters": "--conf spark.executor.cores=4  
        --conf spark.executor.memory=16g  
        --conf spark.driver.cores=4  
        --conf spark.driver.memory=16g  
        --conf spark.executor.instances=3  
        --packages org.apache.spark:spark-sql-  
kafka-0-10_2.12:<KAFKA_CONNECTOR_VERSION>"
```

```
}
}'
```

La version du connecteur Apache Kafka dépend de votre version EMR Serverless et de la version de Spark correspondante. Pour trouver la bonne version de Kafka, consultez le Guide d'[intégration de Structured Streaming + Kafka](#).

Pour utiliser Amazon Managed Streaming for Apache Kafka avec IAM authentification, vous devez inclure une autre dépendance pour permettre au connecteur Kafka de se connecter à Amazon avec MSK IAM. Pour plus d'informations, consultez le [aws-msk-iam-auth référentiel sur GitHub](#). Vous devez également vous assurer que le rôle d'exécution des tâches dispose des IAM autorisations nécessaires. L'exemple suivant montre comment utiliser le connecteur avec IAM l'authentification.

```
aws emr-serverless start-job-run \
--application-id <APPLICATION_ID> \
--execution-role-arn <JOB_EXECUTION_ROLE> \
--mode 'STREAMING' \
--job-driver '{
  "sparkSubmit": {
    "entryPoint": "s3://<Kafka-streaming-script>",
    "entryPointArguments": ["s3://<DOC-EXAMPLE-BUCKET-OUTPUT>/output"],
    "sparkSubmitParameters": "--conf spark.executor.cores=4
      --conf spark.executor.memory=16g
      --conf spark.driver.cores=4
      --conf spark.driver.memory=16g
      --conf spark.executor.instances=3
      --packages org.apache.spark:spark-sql-
kafka-0-10_2.12:<KAFKA_CONNECTOR_VERSION>,software.amazon.msk:aws-msk-iam-
auth:<MSK_IAM_LIB_VERSION>"
  }
}'
```

Pour utiliser le connecteur Kafka et la bibliothèque IAM d'authentification d'Amazon, MSK vous devez configurer l'application EMR Serverless avec VPC accès. Vos sous-réseaux doivent avoir accès à Internet et utiliser une NAT passerelle pour accéder aux dépendances Maven. Pour plus d'informations, consultez la section [Configuration de VPC l'accès](#). Les sous-réseaux doivent disposer d'une connectivité réseau pour accéder au cluster Kafka. Cela est vrai que votre cluster Kafka soit autogéré ou que vous utilisiez Amazon Managed Streaming pour Apache Kafka Kafka.

## Gestion des journaux de tâches en streaming

### Rotation du journal

Les tâches de streaming prennent en charge la rotation des journaux des applications Spark et des journaux d'événements. La rotation des journaux empêche les longues tâches de streaming de générer des fichiers journaux volumineux susceptibles d'occuper tout l'espace disque disponible. La rotation des journaux vous permet d'économiser de l'espace disque et d'éviter les échecs de tâches dus à un espace disque insuffisant. Pour plus d'informations, consultez [Rotation des journaux](#).

### Compactage des bûches

Les tâches de streaming prennent également en charge le compactage des journaux d'événements Spark chaque fois que la journalisation gérée est disponible. Pour plus de détails sur la journalisation gérée, consultez la section [Journalisation avec le stockage géré](#). Les tâches de streaming peuvent s'exécuter pendant une longue période, et la quantité de données d'événements peut s'accumuler au fil du temps et augmenter considérablement la taille des fichiers journaux. Le serveur d'historique Spark lit et charge ces événements en mémoire pour l'interface utilisateur de l'application Spark. Ce processus peut entraîner des latences et des coûts élevés, en particulier si les journaux d'événements stockés dans Amazon S3 sont très volumineux.

Le compactage des journaux réduit la taille du journal des événements, de sorte que le serveur d'historique Spark n'a pas à charger plus de 1 Go de journaux d'événements à tout moment. Pour plus d'informations, consultez la section [Surveillance et instrumentation](#) dans la documentation d'Apache Spark.

## Offres d'emploi Spark

Vous pouvez exécuter des tâches Spark sur une application dont le type paramètre est défini sur SPARK. Les tâches doivent être compatibles avec la version de Spark compatible avec la version de EMR lancement d'Amazon. Par exemple, lorsque vous exécutez des tâches avec Amazon EMR version 6.6.0, celles-ci doivent être compatibles avec Apache Spark 3.2.0. Pour plus d'informations sur les versions de l'application pour chaque version, consultez [Versions publiées d'Amazon EMR Serverless](#).

## Paramètres de la tâche Spark

Lorsque vous utilisez le [StartJobRunAPI](#) pour exécuter une tâche Spark, vous pouvez spécifier les paramètres suivants.

## Paramètres requis

- [Rôle d'exécution de la tâche Spark](#)
- [Paramètre du pilote de tâche Spark](#)
- [Paramètre de remplacement de la configuration Spark](#)
- [Optimisation dynamique de l'allocation des ressources](#)

## Rôle d'exécution de la tâche Spark

Utilisez **executionRoleArn** pour spécifier le ARN IAM rôle que votre application utilise pour exécuter les tâches Spark. Ce rôle doit contenir les autorisations suivantes :

- Lisez à partir de compartiments S3 ou d'autres sources de données où résident vos données
- Lisez à partir de compartiments ou de préfixes S3 où réside votre PySpark script ou fichier JAR
- Écrivez dans les compartiments S3 où vous avez l'intention d'écrire votre sortie finale
- Écrire des journaux dans un compartiment ou un préfixe S3 qui spécifie `S3MonitoringConfiguration`
- Accès aux KMS clés si vous utilisez des KMS clés pour chiffrer les données de votre compartiment S3
- Accès au AWS Glue Data Catalog si vous utilisez Spark SQL

Si votre tâche Spark lit ou écrit des données depuis ou vers d'autres sources de données, spécifiez les autorisations appropriées pour ce IAM rôle. Si vous n'accordez pas ces autorisations au IAM rôle, la tâche risque d'échouer. Pour plus d'informations, consultez [Rôles d'exécution des tâches pour Amazon EMR Serverless](#) et [Stockage des journaux](#).

## Paramètre du pilote de tâche Spark

**jobDriver** À utiliser pour fournir des informations sur la tâche. Le paramètre du pilote de tâche n'accepte qu'une seule valeur pour le type de tâche que vous souhaitez exécuter. Pour une tâche Spark, la valeur du paramètre est `sparkSubmit`. Vous pouvez utiliser ce type de tâche pour exécuter Scala, Java PySpark, SparkR et toute autre tâche prise en charge via Spark submit. Les tâches Spark ont les paramètres suivants :

- **sparkSubmitParameters**— Il s'agit des paramètres Spark supplémentaires que vous souhaitez envoyer à la tâche. Utilisez ce paramètre pour remplacer les propriétés Spark par défaut, telles que

la mémoire du pilote ou le nombre d'exécuteurs, telles que celles définies dans les arguments `--conf` or `--class`.

- **entryPointArguments**— Il s'agit d'un tableau d'arguments que vous souhaitez transmettre à votre fichier principal JAR ou à votre fichier Python. Vous devez gérer la lecture de ces paramètres à l'aide de votre code entrypoint. Séparez chaque argument du tableau par une virgule.
- **entryPoint**— Il s'agit de la référence dans Amazon S3 au fichier principal JAR ou au fichier Python que vous souhaitez exécuter. Si vous utilisez un Scala ou un JavaJAR, spécifiez la classe d'entrée principale dans l'`--class` argument `sparkSubmitParameters` using the.

Pour plus d'informations, consultez la rubrique [Lancement d'applications à l'aide de spark-submit](#).

## Paramètre de remplacement de la configuration Spark

**configurationOverrides** À utiliser pour remplacer les propriétés de configuration au niveau de la surveillance et au niveau de l'application. Ce paramètre accepte un JSON objet contenant les deux champs suivants :

- **monitoringConfiguration**- Utilisez ce champ pour spécifier l'Amazon S3 URL (`s3MonitoringConfiguration`) où vous souhaitez que la tâche EMR sans serveur stocke les journaux de votre tâche Spark. Assurez-vous d'avoir créé ce compartiment avec le même Compte AWS qui héberge votre application, et dans le même Région AWS où se déroule votre travail.
- **applicationConfiguration**— Pour remplacer les configurations par défaut des applications, vous pouvez fournir un objet de configuration dans ce champ. Vous pouvez utiliser une syntaxe abrégée pour fournir la configuration ou vous pouvez faire référence à l'objet de configuration dans un JSON fichier. Les objets de configuration sont composés d'une classification, de propriétés et de configurations imbriquées en option. Les propriétés sont les paramètres que vous souhaitez remplacer dans ce fichier. Vous pouvez définir plusieurs classifications pour plusieurs applications dans un seul JSON objet.

### Note

Les classifications de configuration disponibles varient en fonction de la version EMR Serverless spécifique. Par exemple, les classifications pour Log4j personnalisées ne `spark-executor-log4j2` sont disponibles qu'avec les versions 6.8.0 `spark-driver-log4j2` et supérieures.

Si vous utilisez la même configuration dans une dérogation d'application et dans les paramètres d'envoi de Spark, les paramètres d'envoi de Spark sont prioritaires. Les configurations sont classées par ordre de priorité comme suit, du plus haut au plus bas :

- Configuration fournie par EMR Serverless lors de sa création. `SparkSession`
- Configuration que vous fournissez dans le cadre `sparkSubmitParameters` de l'--confargument.
- La configuration que vous fournissez dans le cadre de votre application remplace lorsque vous démarrez une tâche.
- Configuration que vous fournissez `runtimeConfiguration` lors de la création d'une application.
- Configurations optimisées EMR utilisées par Amazon pour cette version.
- Configurations open-source par défaut pour l'application.

Pour plus d'informations sur la déclaration de configurations au niveau de l'application et sur le remplacement de configurations lors de l'exécution d'une tâche, consultez [Configuration d'application par défaut pour EMR Serverless](#).

## Optimisation dynamique de l'allocation des ressources

`dynamicAllocationOptimization` À utiliser pour optimiser l'utilisation des ressources dans EMR Serverless. La définition de cette propriété sur `true` dans votre classification de configuration Spark indique à EMR Serverless d'optimiser l'allocation des ressources des exécuteurs afin de mieux aligner le taux auquel Spark demande et annule des exécuteurs avec le taux auquel EMR Serverless crée et libère des travailleurs. EMR Serverless réutilise ainsi de manière plus optimale les travailleurs d'une étape à l'autre, ce qui permet de réduire les coûts lors de l'exécution de tâches comportant plusieurs étapes tout en maintenant les mêmes performances.

Cette propriété est disponible dans toutes les EMR versions d'Amazon.

Voici un exemple de classification de configuration avec `dynamicAllocationOptimization`.

```
[
  {
    "Classification": "spark",
    "Properties": {
      "dynamicAllocationOptimization": "true"
    }
  }
]
```

]

Tenez compte des points suivants si vous utilisez l'optimisation de l'allocation dynamique :

- Cette optimisation est disponible pour les tâches Spark pour lesquelles vous avez activé l'allocation dynamique des ressources.
- Pour obtenir le meilleur rapport coût-efficacité, nous vous recommandons de configurer une limite d'échelle supérieure pour les travailleurs en utilisant soit le paramètre au niveau de la tâche, `spark.dynamicAllocation.maxExecutors` soit le paramètre de [capacité maximale au niveau de l'application](#) en fonction de votre charge de travail.
- Il se peut que vous ne constatiez pas d'amélioration des coûts dans les tâches plus simples. Par exemple, si votre tâche s'exécute sur un petit ensemble de données ou s'exécute en une seule étape, Spark n'a peut-être pas besoin d'un plus grand nombre d'exécuteurs ou de plusieurs événements de dimensionnement.
- Les tâches comportant une séquence composée d'une grande étape, d'étapes plus petites, puis d'une nouvelle étape de grande envergure peuvent connaître une régression au cours de l'exécution des tâches. Comme le EMR mode Serverless utilise les ressources de manière plus efficace, cela peut entraîner une diminution du nombre de travailleurs disponibles pour les étapes plus importantes, ce qui se traduit par un allongement du temps d'exécution.

## Propriétés de la tâche Spark

Le tableau suivant répertorie les propriétés Spark facultatives et leurs valeurs par défaut que vous pouvez remplacer lorsque vous soumettez une tâche Spark.

Clé	Description	Valeur par défaut
<code>spark.archives</code>	Liste d'archives séparées par des virgules que Spark extrait dans le répertoire de travail de chaque exécuteur . Les types de fichiers pris en charge incluent <code>.jar</code> <code>.tar.gz</code> , <code>.tgz</code> et <code>.zip</code> . Pour spécifier le nom du répertoire à extraire, ajoutez-	NULL



Clé	Description	Valeur par défaut
	le # après le nom du fichier que vous souhaitez extraire. Par exemple, <code>file.zip#directory</code> .	
<code>spark.authenticate</code>	Option qui active l'authentification des connexions internes de Spark.	TRUE
<code>spark.driver.cores</code>	Nombre de cœurs utilisés par le pilote.	4
<code>spark.driver.extraJavaOptions</code>	Options Java supplémentaires pour le pilote Spark.	NULL
<code>spark.driver.memory</code>	La quantité de mémoire utilisée par le pilote.	14 G
<code>spark.dynamicAllocation.enabled</code>	Option qui active l'allocation dynamique des ressources. Cette option augmente ou diminue le nombre d'exécuteurs enregistrés auprès de l'application, en fonction de la charge de travail.	TRUE
<code>spark.dynamicAllocation.executorIdleTimeout</code>	Durée pendant laquelle un exécuteur peut rester inactif avant que Spark ne le supprime. Cela ne s'applique que si vous activez l'allocation dynamique.	Années 60
<code>spark.dynamicAllocation.initialExecutors</code>	Le nombre initial d'exécuteurs à exécuter si vous activez l'allocation dynamique.	3

Clé	Description	Valeur par défaut
<code>spark.dynamicAllocation.maxExecutors</code>	Limite supérieure du nombre d'exécuteurs si vous activez l'allocation dynamique.	Pour les versions 6.10.0 et supérieures, <code>infinity</code>  Pour les versions 6.9.0 et antérieures, <code>100</code>
<code>spark.dynamicAllocation.minExecutors</code>	Limite inférieure du nombre d'exécuteurs si vous activez l'allocation dynamique.	<code>0</code>
<code>spark.emr-serverless.allocation.batch.size</code>	Le nombre de conteneurs à demander dans chaque cycle d'allocation d'exécuteur. Il y a un intervalle d'une seconde entre chaque cycle d'allocation.	<code>20</code>
<code>spark.emr-serverless.driver.disk</code>	Le disque du pilote Spark.	<code>20G</code>
<code>spark.emr-serverless.driverEnv.</code> <b>[KEY]</b>	Option qui ajoute des variables d'environnement au pilote Spark.	<code>NULL</code>
<code>spark.emr-serverless.executor.disk</code>	Le disque exécuteur Spark.	<code>20G</code>
<code>spark.emr-serverless.memoryOverheadFactor</code>	Définit la surcharge de mémoire à ajouter à la mémoire du conteneur du pilote et de l'exécuteur.	<code>0.1</code>
<code>spark.emr-serverless.driver.disk.type</code>	Type de disque connecté au pilote Spark.	<code>Standard</code>

Clé	Description	Valeur par défaut
<code>spark.emr-serverless.executor.disk.type</code>	Type de disque attaché aux exécuteurs Spark.	Standard
<code>spark.executor.cores</code>	Le nombre de cœurs utilisés par chaque exécuteur.	4
<code>spark.executor.extraJavaOptions</code>	Options Java supplémentaires pour l'exécuteur Spark.	NULL
<code>spark.executor.instances</code>	Nombre de conteneurs d'exécuteurs Spark à allouer.	3
<code>spark.executor.memory</code>	La quantité de mémoire utilisée par chaque exécuteur.	14 G
<code>spark.executorEnv. [KEY]</code>	Option qui ajoute des variables d'environnement aux exécuteurs Spark.	NULL
<code>spark.files</code>	Une liste de fichiers séparés par des virgules à placer dans le répertoire de travail de chaque exécuteur. Vous pouvez accéder aux chemins de ces fichiers dans l'exécuteur avec <code>SparkFiles.get(fileName)</code> .	NULL
<code>spark.hadoop.hive.metastore.client.factory.class</code>	La classe d'implémentation du métastore Hive.	NULL
<code>spark.jars</code>	JAR supplémentaires à ajouter au chemin de classe d'exécution du pilote et des exécuteurs.	NULL

Clé	Description	Valeur par défaut
<code>spark.network.crypto.enabled</code>	Option qui active le RPC chiffrement AES basé sur le chiffrement. Cela inclut le protocole d'authentification ajouté dans Spark 2.2.0.	FALSE
<code>spark.sql.warehouse.dir</code>	Emplacement par défaut pour les bases de données et les tables gérées.	Pour <code>\$PWD/spark-warehouse</code>
<code>spark.submit.pyFiles</code>	Liste séparée par des virgules de fichiers <code>.zip</code> , <code>.egg</code> ou <code>.py</code> à placer dans les applications PYTHONPATH Python.	NULL

Le tableau suivant répertorie les paramètres d'envoi par défaut de Spark.

Clé	Description	Valeur par défaut
<code>archives</code>	Liste d'archives séparées par des virgules que Spark extrait dans le répertoire de travail de chaque exécuteur.	NULL
<code>class</code>	Classe principale de l'application (pour les applications Java et Scala).	NULL
<code>conf</code>	Propriété de configuration arbitraire de Spark.	NULL
<code>driver-cores</code>	Nombre de cœurs utilisés par le pilote.	4

Clé	Description	Valeur par défaut
<code>driver-memory</code>	La quantité de mémoire utilisée par le pilote.	14 G
<code>executor-cores</code>	Le nombre de cœurs utilisés par chaque exécuteur.	4
<code>executor-memory</code>	La quantité de mémoire utilisée par l'exécuteur.	14 G
<code>files</code>	Liste de fichiers séparés par des virgules à placer dans le répertoire de travail de chaque exécuteur. Vous pouvez accéder aux chemins de ces fichiers dans l'exécuteur avec <code>SparkFiles.get( <i>fileName</i> )</code> .	NULL
<code>jars</code>	Une liste de fichiers jar séparés par des virgules à inclure dans les chemins de classe du pilote et de l'exécuteur.	NULL
<code>num-executors</code>	Le nombre d'exécuteurs à lancer.	3
<code>py-files</code>	Une liste séparée par des virgules de <code>.zip.egg</code> , ou de <code>.py</code> fichiers à placer sur les applications PYTHONPATH Python.	NULL
<code>verbose</code>	Option qui active une sortie de débogage supplémentaire.	NULL

## Exemples Spark

L'exemple suivant montre comment utiliser le StartJobRun API pour exécuter un script Python. Pour un end-to-end didacticiel utilisant cet exemple, voir [Commencer à utiliser Amazon EMR Serverless](#). Vous trouverez d'autres exemples d'exécution de PySpark tâches et d'ajout de dépendances Python dans le GitHub référentiel [EMRServerless Samples](#).

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "s3://us-east-1.elasticmapreduce/emr-containers/samples/  
wordcount/scripts/wordcount.py",  
      "entryPointArguments": ["s3://DOC-EXAMPLE-BUCKET-OUTPUT/wordcount_output"],  
      "sparkSubmitParameters": "--conf spark.executor.cores=1 --conf  
spark.executor.memory=4g --conf spark.driver.cores=1 --conf spark.driver.memory=4g --  
conf spark.executor.instances=1"  
    }  
  }'
```

L'exemple suivant montre comment utiliser le StartJobRun API pour exécuter un SparkJAR.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "/usr/lib/spark/examples/jars/spark-examples.jar",  
      "entryPointArguments": ["1"],  
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi --conf  
spark.executor.cores=4 --conf spark.executor.memory=20g --conf spark.driver.cores=4 --  
conf spark.driver.memory=8g --conf spark.executor.instances=1"  
    }  
  }'
```

## Offres d'emploi Hive

Vous pouvez exécuter des tâches Hive sur une application dont le type paramètre est défini sur HIVE Les tâches doivent être compatibles avec la version de Hive compatible avec la version de EMR lancement d'Amazon. Par exemple, lorsque vous exécutez des tâches sur une application

avec Amazon EMR version 6.6.0, votre tâche doit être compatible avec Apache Hive 3.1.2. Pour plus d'informations sur les versions de l'application pour chaque version, consultez [Versions publiées d'Amazon EMR Serverless](#).

## Paramètres du job Hive

Lorsque vous utilisez le [StartJobRunAPI](#) pour exécuter une tâche Hive, vous devez spécifier les paramètres suivants.

### Paramètres requis

- [Rôle d'exécution du job Hive](#)
- [Paramètre du pilote de tâche Hive](#)
- [Paramètre de remplacement de la configuration Hive](#)

## Rôle d'exécution du job Hive

Utilisez **executionRoleArn** pour spécifier le ARN IAM rôle que votre application utilise pour exécuter les tâches Hive. Ce rôle doit contenir les autorisations suivantes :

- Lisez à partir de compartiments S3 ou d'autres sources de données où résident vos données
- Lisez à partir de compartiments ou de préfixes S3 où résident votre fichier de requête Hive et votre fichier de requête d'initialisation
- Lisez et écrivez dans des compartiments S3 où se trouvent votre répertoire Hive Scratch et votre répertoire d'entrepôt Hive Metastore
- Écrivez dans les compartiments S3 où vous avez l'intention d'écrire votre sortie finale
- Écrire des journaux dans un compartiment ou un préfixe S3 qui spécifie `S3MonitoringConfiguration`
- Accès aux KMS clés si vous utilisez des KMS clés pour chiffrer les données de votre compartiment S3
- Accès au AWS Catalogue de données Glue

Si votre tâche Hive lit ou écrit des données depuis ou vers d'autres sources de données, spécifiez les autorisations appropriées pour ce IAM rôle. Si vous n'accordez pas ces autorisations au IAM rôle, votre tâche risque d'échouer. Pour de plus amples informations, veuillez consulter [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).

## Paramètre du pilote de tâche Hive

**jobDriver** À utiliser pour fournir des informations sur la tâche. Le paramètre du pilote de tâche n'accepte qu'une seule valeur pour le type de tâche que vous souhaitez exécuter. Lorsque vous spécifiez `hive` le type de tâche, EMR Serverless transmet une requête Hive au `jobDriver` paramètre. Les jobs Hive possèdent les paramètres suivants :

- **query**— Il s'agit de la référence dans Amazon S3 au fichier de requête Hive que vous souhaitez exécuter.
- **parameters**— Il s'agit des propriétés de configuration supplémentaires de Hive que vous souhaitez remplacer. Pour remplacer les propriétés, transmettez-les à ce paramètre en tant que `--hiveconf property=value`. Pour remplacer des variables, transmettez-les à ce paramètre sous `--hivevar key=value` la forme.
- **initQueryFile**— Il s'agit du fichier de requête init Hive. Hive exécute ce fichier avant votre requête et peut l'utiliser pour initialiser des tables.

## Paramètre de remplacement de la configuration Hive

**configurationOverrides** À utiliser pour remplacer les propriétés de configuration au niveau de la surveillance et au niveau de l'application. Ce paramètre accepte un JSON objet contenant les deux champs suivants :

- **monitoringConfiguration**— Utilisez ce champ pour spécifier l'Amazon S3 URL (`s3MonitoringConfiguration`) où vous souhaitez que la tâche EMR sans serveur stocke les journaux de votre tâche Hive. Assurez-vous de créer ce bucket avec le même Compte AWS qui héberge votre application, et dans le même Région AWS où se déroule votre travail.
- **applicationConfiguration**— Vous pouvez fournir un objet de configuration dans ce champ pour remplacer les configurations par défaut des applications. Vous pouvez utiliser une syntaxe abrégée pour fournir la configuration ou vous pouvez faire référence à l'objet de configuration dans un JSON fichier. Les objets de configuration sont composés d'une classification, de propriétés et de configurations imbriquées en option. Les propriétés sont les paramètres que vous souhaitez remplacer dans ce fichier. Vous pouvez définir plusieurs classifications pour plusieurs applications dans un seul JSON objet.



**Note**

Les classifications de configuration disponibles varient en fonction de la version EMR Serverless spécifique. Par exemple, les classifications pour Log4j personnalisées ne `spark-executor-log4j2` sont disponibles qu'avec les versions 6.8.0 `spark-driver-log4j2` et supérieures.

Si vous transmettez la même configuration dans une dérogation d'application et dans les paramètres Hive, les paramètres Hive sont prioritaires. La liste suivante classe les configurations de la priorité la plus élevée à la plus faible.

- Configuration que vous fournissez dans le cadre des paramètres Hive avec `--hiveconf property=value`.
- La configuration que vous fournissez dans le cadre de votre application remplace lorsque vous démarrez une tâche.
- Configuration que vous fournissez `runtimeConfiguration` lors de la création d'une application.
- Configurations optimisées EMR attribuées par Amazon pour la publication.
- Configurations open source par défaut pour l'application.

Pour plus d'informations sur la déclaration de configurations au niveau de l'application et sur le remplacement de configurations lors de l'exécution d'une tâche, consultez [Configuration d'application par défaut pour EMR Serverless](#).

## Propriétés des tâches Hive

Le tableau suivant répertorie les propriétés obligatoires que vous devez configurer lorsque vous soumettez une tâche Hive.

Paramètre	Description
<code>hive.exec.scratchdir</code>	Emplacement Amazon S3 où EMR Serverless crée des fichiers temporaires pendant l'exécution de la tâche Hive.

Paramètre	Description
<code>hive.metastore.warehouse.dir</code>	Emplacement Amazon S3 des bases de données pour les tables gérées dans Hive.

Le tableau suivant répertorie les propriétés optionnelles de Hive et leurs valeurs par défaut que vous pouvez remplacer lorsque vous soumettez une tâche Hive.

Paramètre	Description	Valeur par défaut
<code>fs.s3.customAWSCredentialsProvider</code>	Le AWS Fournisseur d'informations d'identification que vous souhaitez utiliser.	<code>com.amazonaws.auth.DefaultAWSCredentialsProviderChain</code>
<code>fs.s3a.aws.credentials.provider</code>	Le AWS Fournisseur d'informations d'identification que vous souhaitez utiliser avec un système de fichiers S3A.	<code>com.amazonaws.auth.DefaultAWSCredentialsProviderChain</code>
<code>hive.auto.convert.join</code>	Option qui active la conversion automatique des jointures communes en mapjoins, en fonction de la taille du fichier d'entrée.	TRUE
<code>hive.auto.convert.join.noconditionaltask</code>	Option qui active l'optimisation lorsque Hive convertit une jointure commune en mapjoin en fonction de la taille du fichier d'entrée.	TRUE
<code>hive.auto.convert.join.noconditionaltask.size</code>	Une jointure est convertie directement en une jointure mapjoin inférieure à cette taille.	La valeur optimale est calculée sur la base de la mémoire des tâches Tez

Paramètre	Description	Valeur par défaut
<code>hive.cbo.enable</code>	Option qui active les optimisations basées sur les coûts avec le framework Calcite.	TRUE
<code>hive.cli.tez.session.async</code>	Possibilité de démarrer une session Tez en arrière-plan pendant que votre requête Hive se compile. Lorsqu'il est défini sur <code>false</code> , Tez AM démarre après la compilation de votre requête Hive.	TRUE
<code>hive.compute.query.using.stats</code>	Option qui active Hive pour répondre à certaines requêtes avec des statistiques stockées dans le métastore. Pour les statistiques de base, définissez <code>hive.stats.autogather</code> sur <code>TRUE</code> . Pour une collection de requêtes plus avancée, exécutez <code>analyze table queries</code> .	TRUE
<code>hive.default.fileformat</code>	Format de fichier par défaut pour les <code>CREATE TABLE</code> instructions. Vous pouvez le remplacer explicitement si vous le spécifiez <code>STORED AS [FORMAT]</code> dans votre <code>CREATE TABLE</code> commande.	TEXTFILE
<code>hive.driver.cores</code>	Nombre de cœurs à utiliser pour le processus du pilote Hive.	2

Paramètre	Description	Valeur par défaut
<code>hive.driver.disk</code>	Taille du disque pour le pilote Hive.	20G
<code>hive.driver.disk.type</code>	Type de disque pour le pilote Hive.	Standard
<code>hive.tez.disk.type</code>	La taille du disque pour les ouvriers.	Standard
<code>hive.driver.memory</code>	La quantité de mémoire à utiliser par processus de pilote Hive. Le Hive CLI et le Tez Application Master partagent cette mémoire à parts égales avec 20 % de marge de manœuvre.	6 G
<code>hive.emr-serverless.launch.env.[ <i>KEY</i>]</code>	Option permettant de définir la variable d' <i>KEY</i> environnement dans tous les processus spécifiques à Hive, tels que votre pilote Hive, Tez AM et la tâche Tez.	
<code>hive.exec.dynamic.partition</code>	Options qui activent les partitions dynamiques dans DML/DDL.	TRUE

Paramètre	Description	Valeur par défaut
<code>hive.exec.dynamic.partition.mode</code>	Option qui indique si vous souhaitez utiliser le mode strict ou le mode non strict. En mode strict, vous devez spécifier au moins une partition statique au cas où vous remplaceriez accidentellement toutes les partitions. En mode non strict, toutes les partitions peuvent être dynamiques.	<code>strict</code>
<code>hive.exec.max.dynamic.partitions</code>	Le nombre maximum de partitions dynamiques créées par Hive au total.	1 000
<code>hive.exec.max.dynamic.partitions.per.node</code>	Nombre maximal de partitions dynamiques créées par Hive dans chaque nœud de mappage et de réduction.	100

Paramètre	Description	Valeur par défaut
<code>hive.exec.orc.split.strategy</code>	Attend l'une des valeurs suivantes : BIETL, ouHYBRID. Il ne s'agit pas d'une configuration au niveau de l'utilisateur. BIindique que vous souhaitez consacrer moins de temps à la génération fractionnée plutôt qu'à l'exécution de requêtes. ETLindique que vous souhaitez consacrer plus de temps à la génération fractionnée. HYBRIDspécifie un choix des stratégies ci-dessus sur la base de l'heuristique.	HYBRID
<code>hive.exec.reducers.bytes.per.reducer</code>	La taille de chaque réducteur . La valeur par défaut est de 256 Mo. Si la taille d'entrée est de 1 G, la tâche utilise 4 réducteurs.	256000000
<code>hive.exec.reducers.max</code>	Le nombre maximum de réducteurs.	256
<code>hive.exec.stagingdir</code>	Le nom du répertoire qui stocke les fichiers temporaires créés par Hive dans les emplacements des tables et dans l'emplacement du répertoire de travail spécifié dans la <code>hive.exec.scratchdir</code> propriété.	<code>.hive-staging</code>

Paramètre	Description	Valeur par défaut
<code>hive.fetch.task.conversion</code>	Attendez l'une des valeurs suivantes : NONEMINIMAL, ou MORE. Hive peut convertir certaines requêtes en une seule FETCH tâche. Cela permet de minimiser le temps de latence.	MORE
<code>hive.groupby.position.alias</code>	Option qui oblige Hive à utiliser un alias de position de colonne dans les GROUP BY instructions.	FALSE
<code>hive.input.format</code>	Format de saisie par défaut. Réglez sur <code>HiveInputFormat</code> si vous rencontrez des problèmes avec <code>CombineHiveInputFormat</code> .	<code>org.apache.hadoop.hive.q1.io.CombineHiveInputFormat</code>
<code>hive.log.explain.output</code>	Option qui active les explications des sorties étendues pour toute requête de votre journal Hive.	FALSE
<code>hive.log.level</code>	Le niveau de journalisation de Hive.	INFO
<code>hive.mapred.reduce.tasks.speculative.execution</code>	Option qui active le lancement spéculatif pour les réducteurs. Compatible uniquement avec Amazon EMR 6.10.x et versions antérieures.	TRUE

Paramètre	Description	Valeur par défaut
<code>hive.max-task-containers</code>	Le nombre maximum de conteneurs simultanés. La mémoire du mappeur configurée est multipliée par cette valeur pour déterminer la mémoire disponible qui divise l'utilisation du calcul et de la préemption des tâches.	1 000
<code>hive.merge.mapfiles</code>	Option qui entraîne la fusion de petits fichiers à la fin d'une tâche cartographique uniquement.	TRUE
<code>hive.merge.size.per.task</code>	Taille des fichiers fusionnés à la fin de la tâche.	256000000
<code>hive.merge.tezfiles</code>	Option qui active la fusion de petits fichiers à la fin d'un TezDAG.	FALSE
<code>hive.metastore.client.factory.class</code>	Nom de la classe d'usine qui produit les objets implémentant l' <code>IMetaStoreClient</code> interface.	<code>com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClientFactory</code>
<code>hive.metastore.glue.catalogid</code>	Si l'icône AWS Glue Data Catalog agit comme un métastore mais s'exécute dans un autre Compte AWS plutôt que les jobs, l'identifiant du Compte AWS où les jobs sont exécutés.	NULL



Paramètre	Description	Valeur par défaut
<code>hive.metastore.uris</code>	L'épargne URI que le client de métastore utilise pour se connecter à une métastore distante.	NULL
<code>hive.optimize.ppd</code>	Option qui active le transfert des prédicats vers le bas.	TRUE
<code>hive.optimize.ppd.storage</code>	Option qui active le transfert des prédicats vers les gestionnaires de stockage.	TRUE
<code>hive.orderby.position.alias</code>	Option qui oblige Hive à utiliser un alias de position de colonne dans les ORDER BY instructions.	TRUE
<code>hive.prewarm.enabled</code>	Option qui active le préchauffage du récipient pour Tez.	FALSE
<code>hive.prewarm.numcontainers</code>	Le nombre de récipients à préchauffer pour Tez.	10
<code>hive.stats.autogather</code>	Option permettant à Hive de collecter automatiquement des statistiques de base lors de la INSERT OVERWRITE commande.	TRUE
<code>hive.stats.fetch.column.stats</code>	Option qui désactive l'extraction des statistiques des colonnes depuis le métastore. L'extraction des statistiques des colonnes peut s'avérer coûteuse lorsque le nombre de colonnes est élevé.	FALSE

Paramètre	Description	Valeur par défaut
<code>hive.stats.gather.num.threads</code>	Le nombre de threads utilisés par les commandes <code>partialscan</code> et <code>noscan analyze</code> pour les tables partitionnées. Cela ne s'applique qu'aux formats de fichiers qui implémentent <code>StatsProvidingRecordReader</code> (likeORC).	10
<code>hive.strict.checks.cartesian.product</code>	Options qui activent des contrôles de jointure cartésiens stricts. Ces contrôles interdisent un produit cartésien (une jointure croisée).	FALSE
<code>hive.strict.checks.type.safety</code>	Option qui active des contrôles de sécurité de type stricts et désactive la comparaison entre <code>bigint</code> les deux <code>string</code> et <code>double</code> .	TRUE
<code>hive.support.quoted.identifiers</code>	Attend une valeur de <code>NONE</code> ou <code>COLUMN</code> . <code>NONE</code> implique que seuls les caractères alphanumériques et les traits de soulignement sont valides dans les identifiants. <code>COLUMN</code> implique que les noms de colonnes peuvent contenir n'importe quel caractère.	COLUMN

Paramètre	Description	Valeur par défaut
<code>hive.tez.auto.reducer.parallelism</code>	Option qui active la fonction de parallélisme du réducteur automatique Tez. Hive estime toujours la taille des données et définit des estimations de parallélisme. Tez échantillonne les tailles de sortie des sommets sources et ajuste les estimations au moment de l'exécution si nécessaire.	TRUE
<code>hive.tez.container.size</code>	La quantité de mémoire à utiliser par processus de tâche Tez.	6144
<code>hive.tez.cpu.vcores</code>	Le nombre de cœurs à utiliser pour chaque tâche Tez.	2
<code>hive.tez.disk.size</code>	Taille du disque pour chaque conteneur de tâches.	20G
<code>hive.tez.input.format</code>	Le format d'entrée pour la génération de splits dans le Tez AM.	<code>org.apache.hadoop.hive.q1.io.HiveInputFormat</code>
<code>hive.tez.min.partition.factor</code>	Limite inférieure de réducteurs spécifiée par Tez lorsque vous activez le parallélisme des réducteurs automatiques.	0.25
<code>hive.vectorized.execution.enabled</code>	Option qui active le mode vectorisé d'exécution des requêtes.	TRUE

Paramètre	Description	Valeur par défaut
<code>hive.vectorized.execution.reduce.enabled</code>	Option qui active le mode vectorisé du côté réduction de l'exécution d'une requête.	TRUE
<code>javax.jdo.option.ConnectionDriverName</code>	Nom de classe de pilote pour un JDBC metastore.	<code>org.apache.derby.jdbc.EmbeddedDriver</code>
<code>javax.jdo.option.ConnectionPassword</code>	Le mot de passe associé à une base de données de métastore.	NULL
<code>javax.jdo.option.ConnectionURL</code>	Chaîne de JDBC connexion pour un JDBC metastore.	<code>jdbc:derby:;databaseName=metastore_db;create=true</code>
<code>javax.jdo.option.ConnectionUserName</code>	Nom d'utilisateur associé à une base de données Metastore.	NULL
<code>mapreduce.input.fileinputformat.split.maxsize</code>	La taille maximale d'une division lors du calcul de la division lorsque votre format d'entrée est <code>org.apache.hadoop.hive.ql.io.CombineHiveInputFormat</code> . La valeur 0 indique l'absence de limite.	0
<code>tez.am.dag.cleanup.on.completion</code>	Option qui active le nettoyage des données de shuffle une fois terminé. DAG	TRUE

Paramètre	Description	Valeur par défaut
<code>tez.am.emr-serverless.launch.env.[ KEY]</code>	Option permettant de définir la variable d' <i>KEY</i> environnement dans le processus Tez AM. Pour Tez AM, cette valeur remplace la <code>hive.emr-serverless.launch.env.[ KEY]</code> valeur.	
<code>tez.am.log.level</code>	Le niveau de journalisation root que EMR Serverless transmet au maître de l'application Tez.	INFO
<code>tez.am.sleep.time.before.exit.millis</code>	EMRServerless devrait envoyer ATS les événements après cette période après la demande d'arrêt AM.	0
<code>tez.am.speculation.enabled</code>	Option qui entraîne le lancement spéculatif de tâches plus lentes. Cela peut aider à réduire la latence des tâches lorsque certaines tâches s'exécutent plus lentement en raison de machines défectueuses ou lentes. Compatible uniquement avec Amazon EMR 6.10.x et versions antérieures.	FALSE

Paramètre	Description	Valeur par défaut
<code>tez.am.task.max.failed.attempts</code>	Nombre maximal de tentatives susceptibles d'échouer pour une tâche donnée avant que celle-ci n'échoue. Ce nombre ne compte pas les tentatives annulées manuellement.	3
<code>tez.am.vertex.cleanup.height</code>	Distance à laquelle, si tous les sommets dépendants sont complets, Tez AM supprimera les données de mélange de sommets. Cette fonctionnalité est désactivée lorsque la valeur est 0. EMR Les versions 6.8.0 et ultérieures d'Amazon prennent en charge cette fonctionnalité.	0
<code>tez.client.asynchronous-stop</code>	Option qui oblige EMR Serverless à envoyer des ATS événements avant qu'il ne mette fin au pilote Hive.	FALSE
<code>tez.grouping.max-size</code>	Limite de taille supérieure (en octets) d'un fractionnement groupé. Cette limite permet d'éviter des scissions trop importantes.	1073741824
<code>tez.grouping.min-size</code>	Limite de taille inférieure (en octets) d'un fractionnement groupé. Cette limite permet d'éviter un trop grand nombre de petites divisions.	16777216

Paramètre	Description	Valeur par défaut
<code>tez.runtime.io.sort.mb</code>	La taille de la mémoire tampon souple lorsque Tez trie la sortie est triée.	La valeur optimale est calculée sur la base de la mémoire des tâches Tez
<code>tez.runtime.unordered.output.buffer.size-mb</code>	La taille de la mémoire tampon à utiliser si Tez n'écrit pas directement sur le disque.	La valeur optimale est calculée sur la base de la mémoire des tâches Tez
<code>tez.shuffle-vertex-manager.max-src-fraction</code>	Fraction des tâches source qui doivent être terminées avant que EMR Serverless ne planifie toutes les tâches pour le sommet actuel (dans le cas d'une ScatterGather connexion). Le nombre de tâches prêtes à être planifiées sur le sommet actuel varie linéairement entre <code>etmin-fraction</code> et <code>max-fraction</code> . Cela correspond à la valeur par défaut ou <code>tez.shuffle-vertex-manager.min-src-fraction</code> à la valeur la plus élevée.	0.75
<code>tez.shuffle-vertex-manager.min-src-fraction</code>	Fraction des tâches source qui doivent être effectuées avant que EMR Serverless ne planifie des tâches pour le sommet actuel (dans le cas d'une ScatterGather connexion).	0.25

Paramètre	Description	Valeur par défaut
<code>tez.task.emr-serverless.launch.env.[<i>KEY</i>]</code>	Option permettant de définir la variable d' <i>KEY</i> environnement dans le processus de tâche Tez. Pour les tâches Tez, cette valeur remplace la <code>hive.emr-serverless.launch.env.[<i>KEY</i>]</code> valeur.	
<code>tez.task.log.level</code>	Le niveau de journalisation root que EMR Serverless transmet aux tâches Tez.	INFO
<code>tez.yarn.ats.event.flush.timeout.millis</code>	Durée maximale pendant laquelle AM doit attendre que les événements soient supprimés avant de s'arrêter.	300 000

## Exemples d'emplois chez Hive

L'exemple de code suivant montre comment exécuter une requête Hive avec le `StartJobRunAPI`.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "hive": {
      "query": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-query.q1",
      "parameters": "--hiveconf hive.log.explain.output=false"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "hive-site",
      "properties": {
        "hive.exec.scratchdir": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/hive/scratch",
```



```

        "hive.metastore.warehouse.dir": "s3://DOC-EXAMPLE-BUCKET/emr-
serverless-hive/hive/warehouse",
        "hive.driver.cores": "2",
        "hive.driver.memory": "4g",
        "hive.tez.container.size": "4096",
        "hive.tez.cpu.vcores": "1"
    }
}
}'

```

Vous trouverez d'autres exemples d'exécution de tâches Hive dans le référentiel [EMRServerless Samples](#) GitHub .

## EMR Résilience des Job sans serveur

EMR Les versions 7.1.0 et supérieures sans serveur incluent la prise en charge de la résilience des tâches, de sorte que toutes les tâches échouées sont automatiquement relancées sans aucune intervention manuelle de votre part. Un autre avantage de la résilience des tâches est que EMR Serverless déplace les cycles de travail vers une autre zone de disponibilité (AZ) en cas de problème avec une AZ.

Pour activer la résilience d'une tâche, définissez la politique de nouvelle tentative pour cette tâche. Une politique de nouvelle tentative garantit que EMR Serverless redémarre automatiquement une tâche en cas d'échec. Les politiques de nouvelle tentative sont prises en charge pour les tâches par lots et en streaming. Vous pouvez donc personnaliser la résilience des tâches en fonction de votre cas d'utilisation. Le tableau suivant compare les comportements et les différences de résilience des tâches entre les tâches par lots et les tâches de streaming.

	Traitements par lots	Offres d'emploi en streaming
Comportement par défaut	Ne réexécute pas le job.	Réessaie toujours d'exécuter la tâche car l'application crée des points de contrôle pendant l'exécution de la tâche.
Point de nouvelle tentative	Les tâches par lots ne comportant pas de points de contrôle, EMR Serverless	Les tâches de streaming prennent en charge les points de contrôle. Vous pouvez donc configurer la requête de

	Traitements par lots	Offres d'emploi en streaming
	réexécute toujours la tâche depuis le début.	streaming pour enregistrer l'état d'exécution et progresser vers un point de contrôle dans Amazon S3. EMRServerless reprend l'exécution du job depuis le point de contrôle. Pour plus d'informations, consultez la section <a href="#">Restauration après un échec avec le point de contrôle dans</a> la documentation d'Apache Spark.
Nombre maximal de nouvelles tentatives	Permet un maximum de 10 tentatives.	Les tâches de streaming sont dotées d'un contrôle intégré de prévention des thrash, de sorte que l'application arrête de réessayer les tâches si elles échouent toujours au bout d'une heure. Le nombre de tentatives par défaut dans un délai d'une heure est de cinq tentatives. Vous pouvez configurer ce nombre de tentatives pour qu'il soit compris entre 1 et 10. Vous ne pouvez pas personnaliser le nombre maximum de tentatives. La valeur 1 indique qu'il n'y a pas eu de nouvelle tentative.

Lorsque EMR Serverless tente de réexécuter une tâche, il indexe également la tâche avec un numéro de tentative, afin que vous puissiez suivre le cycle de vie d'une tâche au fil de ses tentatives.

Vous pouvez utiliser les API opérations EMR sans serveur ou AWS CLI pour modifier la résilience au travail ou consulter les informations relatives à la résilience au travail. Pour plus d'informations, consultez le [APIguide EMR Serverless](#).

Par défaut, EMR Serverless ne réexécute pas les tâches par lots. Pour activer les nouvelles tentatives pour les tâches par lots, configurez le `maxAttempts` paramètre lorsque vous démarrez l'exécution d'une tâche par lots. Le `maxAttempts` paramètre s'applique uniquement aux tâches par lots. La valeur par défaut est 1, ce qui signifie qu'il ne faut pas réexécuter la tâche. Les valeurs acceptées sont comprises entre 1 et 10 inclus.

L'exemple suivant montre comment spécifier un nombre maximum de 10 tentatives lors du démarrage d'une tâche.

```
aws emr-serverless start-job-run
  --application-id <APPLICATION_ID> \
  --execution-role-arn <JOB_EXECUTION_ROLE> \
  --mode 'BATCH' \
  --retry-policy '{
    "maxAttempts": 10
  }' \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "/usr/lib/spark/examples/jars/spark-examples-does-not-
exist.jar",
      "entryPointArguments": ["1"],
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi"
    }
  }'
```

EMRServerless réessaie indéfiniment les tâches de streaming en cas d'échec. Pour éviter le thrash dû à des échecs irrécupérables répétés, utilisez le `maxFailedAttemptsPerHour` pour configurer le contrôle de prévention du thrash pour les nouvelles tentatives de travail en streaming. Ce paramètre vous permet de spécifier le nombre maximum de tentatives infructueuses autorisées une heure avant que EMR Serverless arrête de réessayer. La valeur par défaut est cinq. Les valeurs acceptées sont comprises entre 1 et 10 inclus.

```
aws emr-serverless start-job-run
  --application-id <APPLICATION_ID> \
  --execution-role-arn <JOB_EXECUTION_ROLE> \
  --mode 'STREAMING' \
  --retry-policy '{
```

```
    "maxFailedAttemptsPerHour": 7
  }' \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "/usr/lib/spark/examples/jars/spark-examples-does-not-
exist.jar",
      "entryPointArguments": ["1"],
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi"
    }
  }'
```

Vous pouvez également utiliser les autres API opérations d'exécution de tâches pour obtenir des informations sur les tâches. Par exemple, vous pouvez utiliser le `attempt` paramètre avec l'`GetJobRun` opération pour obtenir des détails sur une tentative de travail spécifique. Si vous n'incluez pas le `attempt` paramètre, l'opération renvoie des informations sur la dernière tentative.

```
aws emr-serverless get-job-run \
  --job-run-id job-run-id \
  --application-id application-id \
  --attempt 1
```

L'`ListJobRunAttempts` opération renvoie des informations sur toutes les tentatives liées à l'exécution d'une tâche.

```
aws emr-serverless list-job-run-attempts \
  --application-id application-id \
  --job-run-id job-run-id
```

L'`GetDashboardForJobRun` opération crée et renvoie un fichier URL que vous pouvez utiliser pour accéder à l'application UIs pour exécuter une tâche. Le `attempt` paramètre vous permet d'obtenir un URL pour une tentative spécifique. Si vous n'incluez pas le `attempt` paramètre, l'opération renvoie des informations sur la dernière tentative.

```
aws emr-serverless get-dashboard-for-job-run \
  --application-id application-id \
  --job-run-id job-run-id \
  --attempt 1
```

## Surveillance d'une tâche à l'aide d'une politique de relance

Le support de résilience des tâches ajoute également le nouvel événement EMRServerless job run retry. EMRServerless publie cet événement à chaque nouvelle tentative de la tâche. Vous pouvez utiliser cette notification pour suivre les nouvelles tentatives de la tâche. Pour plus d'informations sur les événements, consultez [Amazon EventBridge events](#).

## Connexion avec politique de nouvelle tentative

Chaque fois que EMR Serverless réessaie une tâche, la tentative génère son propre ensemble de journaux. Pour garantir que EMR Serverless puisse transmettre ces journaux à Amazon S3 et Amazon CloudWatch sans en remplacer aucun, EMR Serverless ajoute un préfixe au format du chemin du journal S3 et au nom du flux de CloudWatch journal pour inclure le numéro de tentative de la tâche.

Voici un exemple de ce à quoi ressemble le format.

```
'/applications/<applicationId>/jobs/<jobId>/attempts/<attemptNumber>/'.
```

Ce format garantit que EMR Serverless publie tous les journaux de chaque tentative de tâche vers son propre emplacement désigné dans Amazon S3 et CloudWatch. Pour plus de détails, consultez la section [Stockage des journaux](#).

### Note

EMRServerless n'utilise ce format de préfixe qu'avec toutes les tâches de streaming et toutes les tâches par lots pour lesquelles la nouvelle tentative est activée.

## Configuration du métastore

Un métastore Hive est un emplacement centralisé qui stocke les informations structurelles relatives à vos tables, notamment les schémas, les noms de partitions et les types de données. Avec EMR Serverless, vous pouvez conserver les métadonnées de cette table dans un métastore ayant accès à vos tâches.

Deux options s'offrent à vous pour un métastore Hive :

- Le AWS Catalogue de données Glue
- Un métastore Apache Hive externe

## Utilisation de AWS Glue Data Catalog sous forme de métastore

Vous pouvez configurer vos tâches Spark et Hive pour utiliser le AWS Glue Data Catalog comme métastore. Nous recommandons cette configuration lorsque vous avez besoin d'un métastore persistant ou d'un métastore partagé par différentes applications, services ou Comptes AWS. Pour plus d'informations sur le catalogue de données, voir [Remplissage du AWS Catalogue de données Glue](#). Pour plus d'informations sur AWS Tarification de la colle, voir [AWS Tarification de la colle](#).

Vous pouvez configurer votre tâche EMR sans serveur pour utiliser le AWS Glue Data Catalog soit dans le même format Compte AWS comme application, ou dans un autre Compte AWS.

### Configurez le AWS Catalogue de données Glue

Pour configurer le catalogue de données, choisissez le type d'application EMR sans serveur que vous souhaitez utiliser.

#### Spark

Lorsque vous utilisez EMR Studio pour exécuter vos tâches avec des applications Spark EMR sans serveur, le AWS Glue Data Catalog est le métastore par défaut.

Lorsque vous utilisez SDKs ou AWS CLI, vous pouvez définir la `spark.hadoop.hive.metastore.client.factory.class` configuration `com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClientFactory` dans les `sparkSubmit` paramètres de l'exécution de votre tâche. L'exemple suivant montre comment configurer le catalogue de données avec AWS CLI.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/code/pyspark/extreme_weather.py",  
      "sparkSubmitParameters": "--conf  
spark.hadoop.hive.metastore.client.factory.class=com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClientFactory  
--conf spark.driver.cores=1 --conf spark.driver.memory=3g --conf  
spark.executor.cores=4 --conf spark.executor.memory=3g"    }  
  }'
```

```
}  
}'
```

Vous pouvez également définir cette configuration lorsque vous créez une nouvelle configuration SparkSession dans votre code Spark.

```
from pyspark.sql import SparkSession  
  
spark = (  
    SparkSession.builder.appName("SparkSQL")  
    .config(  
        "spark.hadoop.hive.metastore.client.factory.class",  
        "com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClientFactory",  
    )  
    .enableHiveSupport()  
    .getOrCreate()  
)  
  
# we can query tables with SparkSQL  
spark.sql("SHOW TABLES").show()  
  
# we can also them with native Spark  
print(spark.catalog.listTables())
```

## Hive

Pour les applications Hive EMR sans serveur, le catalogue de données est le métastore par défaut. En d'autres termes, lorsque vous exécutez des tâches sur une application Hive EMR sans serveur, Hive enregistre les informations du métastore dans le catalogue de données. Compte AWS comme application. Vous n'avez pas besoin d'un cloud privé virtuel (VPC) pour utiliser le catalogue de données comme métastore.

Pour accéder aux tables du métastore Hive, ajoutez les éléments requis AWS Politiques de Glue décrites dans [Configuration IAM des autorisations pour AWS Glue](#).

## Configurer l'accès entre comptes pour EMR Serverless et AWS Catalogue de données Glue

Pour configurer l'accès entre comptes pour EMR Serverless, vous devez d'abord vous connecter à l'adresse suivante Comptes AWS:

- AccountA— Un Compte AWS où vous avez créé une application EMR sans serveur.
  - AccountB— Un Compte AWS qui contient un AWS Glue Data Catalog auquel vous souhaitez que votre tâche EMR sans serveur puisse accéder.
1. Assurez-vous qu'un administrateur ou une autre identité autorisée AccountB attache une politique de ressources au catalogue de données dans AccountB. Cette politique accorde AccountA des autorisations spécifiques entre comptes pour effectuer des opérations sur les ressources du AccountB catalogue.

```
{
  "Version" : "2012-10-17",
  "Statement" : [ {
    "Effect" : "Allow",
    "Principal": {
      "AWS": [
        "arn:aws:iam::accountA:role/job-runtime-role-A"
      ]
    },
    "Action" : [
      "glue:GetDatabase",
      "glue:CreateDatabase",
      "glue:GetDataBases",
      "glue:CreateTable",
      "glue:GetTable",
      "glue:UpdateTable",
      "glue>DeleteTable",
      "glue:GetTables",
      "glue:GetPartition",
      "glue:GetPartitions",
      "glue:CreatePartition",
      "glue:BatchCreatePartition",
      "glue:GetUserDefinedFunctions"
    ],
    "Resource": ["arn:aws:glue:region:AccountB:catalog"]
  } ]
}
```

2. Ajoutez une IAM politique au rôle d'exécution des tâches EMR sans serveur AccountA afin que ce rôle puisse accéder aux ressources du catalogue de données dans AccountB.

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



```

"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "glue:GetDatabase",
      "glue:CreateDatabase",
      "glue:GetDataBases",
      "glue:CreateTable",
      "glue:GetTable",
      "glue:UpdateTable",
      "glue>DeleteTable",
      "glue:GetTables",
      "glue:GetPartition",
      "glue:GetPartitions",
      "glue:CreatePartition",
      "glue:BatchCreatePartition",
      "glue:GetUserDefinedFunctions"
    ],
    "Resource": ["arn:aws:glue:region:AccountB:catalog"]
  }
]
}

```

3. Commencez à exécuter votre tâche. Cette étape est légèrement différente selon le type AccountA d'application EMR Serverless.

## Spark

Définissez la `spark.hadoop.hive.metastore.glue.catalogid` propriété dans la hive-site classification comme indiqué dans l'exemple suivant. Remplacez *ID du compte B-Catalog-ID* avec l'ID du catalogue de données dans AccountB.

```

aws emr-serverless start-job-run \
--application-id "application-id" \
--execution-role-arn "job-role-arn" \
--job-driver '{
  "sparkSubmit": {
    "query": "s3://DOC-EXAMPLE-BUCKET/hive/scripts/create_table.sql",
    "parameters": "--hiveconf hive.exec.scratchdir=s3://DOC-EXAMPLE-BUCKET/hive/scratch --hiveconf hive.metastore.warehouse.dir=s3://DOC-EXAMPLE-BUCKET/hive/warehouse"
  }
}' \

```

```
--configuration-overrides '{
  "applicationConfiguration": [{
    "classification": "hive-site",
    "properties": {
      "spark.hadoop.hive.metastore.glue.catalogid": "AccountB-catalog-id"
    }
  ]
}
```

## Hive

Définissez la `hive.metastore.glue.catalogid` propriété dans la `hive-site` classification comme indiqué dans l'exemple suivant. Remplacez *ID du compte B-Catalog-ID* avec l'ID du catalogue de données dans AccountB.

```
aws emr-serverless start-job-run \
--application-id "application-id" \
--execution-role-arn "job-role-arn" \
--job-driver '{
  "hive": {
    "query": "s3://DOC-EXAMPLE-BUCKET/hive/scripts/create_table.sql",
    "parameters": "--hiveconf hive.exec.scratchdir=s3://DOC-EXAMPLE-BUCKET/hive/scratch --hiveconf hive.metastore.warehouse.dir=s3://DOC-EXAMPLE-BUCKET/hive/warehouse"
  }
}' \
--configuration-overrides '{
  "applicationConfiguration": [{
    "classification": "hive-site",
    "properties": {
      "hive.metastore.glue.catalogid": "AccountB-catalog-id"
    }
  ]
}
```

## Considérations relatives à l'utilisation du AWS Catalogue de données Glue

Vous pouvez ajouter JARs un auxiliaire `ADD JAR` dans vos scripts Hive. Pour des considérations supplémentaires, voir [Considérations relatives à l'utilisation AWS Catalogue de données Glue](#).

## Utilisation d'un métastore Hive externe

Vous pouvez configurer vos tâches Spark et Hive EMR sans serveur pour vous connecter à un métastore Hive externe, tel qu'Amazon Aurora ou Amazon for My. RDS SQL Cette section explique comment configurer un métastore Amazon RDS Hive, configurer votre et configurer vos VPC tâches EMR sans serveur pour utiliser un métastore externe.

### Création d'un métastore Hive externe

1. Créez un Amazon Virtual Private Cloud (AmazonVPC) avec des sous-réseaux privés en suivant les instructions de la section [Create a VPC](#).
2. Créez votre application EMR Serverless avec vos nouveaux sous-réseaux Amazon VPC et privés. Lorsque vous configurez votre application EMR Serverless avec unVPC, elle fournit d'abord une interface elastic network pour chaque sous-réseau que vous spécifiez. Il attache ensuite le groupe de sécurité que vous avez spécifié à cette interface réseau. Cela permet à votre application de contrôler l'accès. Pour plus de détails sur la configuration de votreVPC, consultez [Configuration de VPC l'accès](#).
3. Créez une SQL base de données My SQL ou Aurora Postgre dans un sous-réseau privé de votre Amazon. VPC Pour plus d'informations sur la création d'une RDS base de données Amazon, consultez [Création d'une RDS instance de base de données Amazon](#).
4. Modifiez le groupe de sécurité de votre base de données My SQL ou Aurora pour autoriser JDBC les connexions depuis votre groupe de sécurité EMR Serverless en suivant les étapes de la section [Modification d'une RDS instance de base de données Amazon](#). Ajoutez une règle pour le trafic entrant au groupe de RDS sécurité depuis l'un de vos groupes de sécurité EMR Serverless.

Type	Protocole	Plage de ports	Source
Tout TCP	TCP	3306	emr-serve rless-sec urity-group

## Configuration des options Spark

### En utilisant JDBC

Pour configurer votre application Spark EMR sans serveur afin qu'elle se connecte à un métastore Hive basé sur une SQL instance Amazon RDS for My ou Amazon SQL Aurora My, utilisez une connexion JDBC. Passez le `mariadb-connector-java.jar` with `--jars` dans les `spark-submit` paramètres de votre exécution de tâche.

```
aws emr-serverless start-job-run \
  --application-id "application-id" \
  --execution-role-arn "job-role-arn" \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/scripts/spark-jdbc.py",
      "sparkSubmitParameters": "--jars s3://DOC-EXAMPLE-BUCKET/mariadb-connector-
java.jar
      --conf
      spark.hadoop.javax.jdo.option.ConnectionDriverName=org.mariadb.jdbc.Driver
      --conf spark.hadoop.javax.jdo.option.ConnectionUserName=<connection-user-
name>
      --conf spark.hadoop.javax.jdo.option.ConnectionPassword=<connection-
password>
      --conf spark.hadoop.javax.jdo.option.ConnectionURL=<JDBC-Connection-
string>
      --conf spark.driver.cores=2
      --conf spark.executor.memory=10G
      --conf spark.driver.memory=6G
      --conf spark.executor.cores=4"
    }
  }' \
  --configuration-overrides '{
    "monitoringConfiguration": {
      "s3MonitoringConfiguration": {
        "logUri": "s3://DOC-EXAMPLE-BUCKET/spark/logs/"
      }
    }
  }'
```

L'exemple de code suivant est un script Spark entrypoint qui interagit avec un métastore Hive sur Amazon. RDS

```
from os.path import expanduser, join, abspath
from pyspark.sql import SparkSession
from pyspark.sql import Row
# warehouse_location points to the default location for managed databases and tables
```

```
warehouse_location = abspath('spark-warehouse')
spark = SparkSession \
    .builder \
    .config("spark.sql.warehouse.dir", warehouse_location) \
    .enableHiveSupport() \
    .getOrCreate()
spark.sql("SHOW DATABASES").show()
spark.sql("CREATE EXTERNAL TABLE `sampledb`.`sparknyctaxi`(`dispatching_base_num`
  string, `pickup_datetime` string, `dropoff_datetime` string, `pulocationid` bigint,
  `dolocationid` bigint, `sr_flag` bigint) STORED AS PARQUET LOCATION 's3://<s3 prefix>/
nyctaxi_parquet/'")
spark.sql("SELECT count(*) FROM sampledb.sparknyctaxi").show()
spark.stop()
```

## Utilisation du service d'épargne

Vous pouvez configurer votre application EMR Serverless Hive pour qu'elle se connecte à un métastore Hive basé sur une instance Amazon for My RDS ou Amazon SQL Aurora My. SQL Pour ce faire, exécutez un serveur d'épargne sur le nœud principal d'un EMR cluster Amazon existant. Cette option est idéale si vous possédez déjà un EMR cluster Amazon avec un serveur d'épargne que vous souhaitez utiliser pour simplifier vos configurations de tâches EMR sans serveur.

```
aws emr-serverless start-job-run \
  --application-id "application-id" \
  --execution-role-arn "job-role-arn" \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/thriftscript.py",
      "sparkSubmitParameters": "--jars s3://DOC-EXAMPLE-BUCKET/mariadb-connector-
java.jar
      --conf spark.driver.cores=2
      --conf spark.executor.memory=10G
      --conf spark.driver.memory=6G
      --conf spark.executor.cores=4"
    }
  }' \
  --configuration-overrides '{
    "monitoringConfiguration": {
      "s3MonitoringConfiguration": {
        "logUri": "s3://DOC-EXAMPLE-BUCKET/spark/logs/"
      }
    }
  }
```

```
}'
```

L'exemple de code suivant est un script entrypoint (`thriftscript.py`) qui utilise le protocole Thrift pour se connecter à un métastore Hive. Notez que la `hive.metastore.uris` propriété doit être définie pour être lue depuis un métastore Hive externe.

```
from os.path import expanduser, join, abspath
from pyspark.sql import SparkSession
from pyspark.sql import Row
# warehouse_location points to the default location for managed databases and tables
warehouse_location = abspath('spark-warehouse')
spark = SparkSession \
    .builder \
    .config("spark.sql.warehouse.dir", warehouse_location) \
    .config("hive.metastore.uris", "thrift://thrift-server-host:thift-server-port") \
    .enableHiveSupport() \
    .getOrCreate()
spark.sql("SHOW DATABASES").show()
spark.sql("CREATE EXTERNAL TABLE sampledb.`sparknyctaxi`(`dispatching_base_num`
  string, `pickup_datetime` string, `dropoff_datetime` string, `pulocationid` bigint,
  `dolocationid` bigint, `sr_flag` bigint) STORED AS PARQUET LOCATION 's3://<s3 prefix>/
nyctaxi_parquet/'")
spark.sql("SELECT * FROM sampledb.sparknyctaxi").show()
spark.stop()
```

## Configurer les options Hive

### En utilisant JDBC

Si vous souhaitez spécifier un emplacement de base de données Hive externe sur une instance Amazon RDS My SQL ou Amazon Aurora, vous pouvez remplacer la configuration de métastore par défaut.

#### Note

Dans Hive, vous pouvez effectuer plusieurs écritures dans des tables de métastore en même temps. Si vous partagez des informations de métastore entre deux jobs, assurez-vous de ne pas écrire simultanément dans la même table de métastore, sauf si vous écrivez sur des partitions différentes de la même table de métastore.

Définissez les configurations suivantes dans la `hive-site` classification pour activer le métastore Hive externe.

```
{
  "classification": "hive-site",
  "properties": {
    "hive.metastore.client.factory.class":
"org.apache.hadoop.hive.ql.metadata.SessionHiveMetaStoreClientFactory",
    "javax.jdo.option.ConnectionDriverName": "org.mariadb.jdbc.Driver",
    "javax.jdo.option.ConnectionURL": "jdbc:mysql://db-host:db-port/db-name",
    "javax.jdo.option.ConnectionUserName": "username",
    "javax.jdo.option.ConnectionPassword": "password"
  }
}
```

### Utiliser un serveur d'épargne

Vous pouvez configurer votre application EMR Serverless Hive pour qu'elle se connecte à un métastore Hive basé sur Amazon for My RDS ou Amazon Aurora M. SQL ySQLInstance Pour ce faire, exécutez un serveur d'épargne sur le nœud principal d'un EMR cluster Amazon existant. Cette option est idéale si vous possédez déjà un EMR cluster Amazon qui exécute un serveur d'épargne et que vous souhaitez utiliser vos configurations de tâches EMR sans serveur.

Définissez les configurations suivantes dans la `hive-site` classification afin que EMR Serverless puisse accéder à la métastore d'épargne distante. Notez que vous devez définir la `hive.metastore.uris` propriété pour qu'elle puisse être lue depuis un métastore Hive externe.

```
{
  "classification": "hive-site",
  "properties": {
    "hive.metastore.client.factory.class":
"org.apache.hadoop.hive.ql.metadata.SessionHiveMetaStoreClientFactory",
    "hive.metastore.uris": "thrift://thrift-server-host:thrift-server-port"
  }
}
```

### Considérations relatives à l'utilisation d'un métastore externe

- Vous pouvez configurer des bases de données compatibles avec MariaDB en tant que JDBC métastore. Des exemples de ces bases RDS de données concernent MariaDB, SQL My et Amazon Aurora.

- Les métastores ne sont pas initialisés automatiquement. [Si votre métastore n'est pas initialisé avec un schéma pour votre version de Hive, utilisez l'outil Hive Schema.](#)
- EMRServerless ne prend pas en charge l'authentification Kerberos. Vous ne pouvez pas utiliser un serveur Thrift Metastore avec une authentification Kerberos avec des tâches Spark ou Hive EMR sans serveur.

## Accès aux données S3 dans un autre AWS compte depuis EMR Serverless

Vous pouvez exécuter des tâches Amazon EMR Serverless à partir d'un AWS et configurez-les pour accéder aux données contenues dans des compartiments Amazon S3 appartenant à un autre AWS . Cette page décrit comment configurer l'accès entre comptes à S3 depuis EMR Serverless.

Les tâches exécutées sur EMR Serverless peuvent utiliser une politique de compartiment S3 ou un rôle assumé pour accéder aux données d'Amazon S3 à partir d'un autre AWS .

### Prérequis

Pour configurer l'accès entre comptes pour Amazon EMR Serverless, vous devez effectuer des tâches en étant connecté à deux AWS comptes :

- **AccountA**— C'est le AWS compte sur lequel vous avez créé une application Amazon EMR Serverless. Avant de configurer l'accès entre comptes, vous devez disposer des éléments suivants sur ce compte :
  - Une application Amazon EMR Serverless dans laquelle vous souhaitez exécuter des tâches.
  - Rôle d'exécution de tâches disposant des autorisations requises pour exécuter des tâches dans l'application. Pour de plus amples informations, veuillez consulter [Rôles d'exécution des tâches pour Amazon EMR Serverless.](#)
- **AccountB**— C'est le AWS compte contenant le compartiment S3 auquel vous souhaitez que vos tâches Amazon EMR Serverless accèdent.

### Utiliser une politique de compartiment S3 pour accéder aux données S3 entre comptes

Pour accéder au compartiment S3 dans account B from account A, attachez la politique suivante au compartiment S3 dans account B.



```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "Example permissions 1",
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::AccountA:root"
      },
      "Action": [
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::bucket_name_in_AccountB"
      ]
    },
    {
      "Sid": "Example permissions 2",
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::AccountA:root"
      },
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:DeleteObject"
      ],
      "Resource": [
        "arn:aws:s3:::bucket_name_in_AccountB/*"
      ]
    }
  ]
}

```

Pour plus d'informations sur l'accès entre comptes S3 avec les politiques relatives aux compartiments S3, consultez l'[exemple 2 : le propriétaire du compartiment accorde des autorisations de compartiment entre comptes](#) dans le guide de l'utilisateur d'Amazon Simple Storage Service.

## Utiliser un rôle assumé pour accéder aux données S3 entre comptes

Une autre méthode pour configurer l'accès entre comptes pour Amazon EMR Serverless consiste à utiliser l'AssumeRole action du AWS Security Token Service (AWS STS). AWS STS est un

service Web mondial qui vous permet de demander des informations d'identification temporaires à privilèges limités pour les utilisateurs. Vous pouvez API passer des appels vers EMR Serverless et Amazon S3 avec les informations d'identification de sécurité temporaires que vous avez créées avec `AssumeRole`.

Les étapes suivantes illustrent comment utiliser un rôle assumé pour accéder aux données S3 entre comptes depuis EMR Serverless :

1. Créez un compartiment Amazon S3, *cross-account-bucket*, dans `AccountB`. Pour plus d'informations, consultez la section [Création d'un compartiment](#) dans le guide de l'utilisateur d'Amazon Simple Storage Service. Si vous souhaitez bénéficier d'un accès intercompte à DynamoDB, vous pouvez également créer une table DynamoDB dans `AccountB`. Pour plus d'informations, consultez la section [Création d'une table DynamoDB dans le manuel Amazon DynamoDB Developer Guide](#).
2. Créez un `Cross-Account-Role-B` IAM rôle dans `AccountB` lequel vous pouvez accéder au *cross-account-bucket*.
  - a. Connectez-vous au AWS Management Console et ouvrez la IAM console à l'adresse <https://console.aws.amazon.com/iam/>.
  - b. Choisissez Rôles et créez un nouveau rôle : `Cross-Account-Role-B`. Pour plus d'informations sur la création de IAM rôles, consultez la section [Création de IAM rôles](#) dans le Guide de IAM l'utilisateur.
  - c. Créez une IAM politique qui spécifie les autorisations `Cross-Account-Role-B` pour accéder au *cross-account-bucket* compartiment S3, comme le montre la déclaration de politique suivante. Attachez ensuite la IAM politique à `Cross-Account-Role-B`. Pour plus d'informations, consultez la section [Création IAM de politiques](#) dans le guide de IAM l'utilisateur.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "s3:*",
      "Resource": [
        "arn:aws:s3:::cross-account-bucket",
        "arn:aws:s3:::cross-account-bucket/*"
      ]
    }
  ]
}
```

```
}

```

Si vous avez besoin d'un accès DynamoDB, créez IAM une politique qui spécifie les autorisations d'accès à la table DynamoDB multicomptes. Attachez ensuite la IAM politique à `Cross-Account-Role-B`. Pour plus d'informations, consultez [Amazon DynamoDB : autorise l'accès à une table spécifique](#) dans IAM le guide de l'utilisateur.

Voici une politique permettant d'autoriser l'accès à la table `DynamoDBCrossAccountTable`.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "dynamodb:*",
      "Resource": "arn:aws:dynamodb:MyRegion:AccountB:table/CrossAccountTable"
    }
  ]
}
```

### 3. Modifiez la relation de confiance du rôle `Cross-Account-Role-B`.

- a. Pour configurer la relation de confiance pour le rôle, choisissez l'onglet Relations de confiance dans la IAM console pour le rôle `Cross-Account-Role-B` que vous avez créé à l'étape 2.
- b. Sélectionnez Modifier la relation de confiance.
- c. Ajoutez le document de politique suivant. Cela permet `AccountA` à `Job-Execution-Role-A` in d'assumer le `Cross-Account-Role-B` rôle.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::AccountA:role/Job-Execution-Role-A"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

4. Subvention Job-Execution-Role-A dans AccountA le AWS STS AssumeRole autorisation d'assumer Cross-Account-Role-B.
  - a. Dans la IAM console pour AWS compte AccountA, sélectionnez Job-Execution-Role-A.
  - b. Ajoutez la déclaration de politique générale suivante au rôle Job-Execution-Role-A pour autoriser l'action AssumeRole sur le rôle Cross-Account-Role-B.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "sts:AssumeRole",
      "Resource": "arn:aws:iam::AccountB:role/Cross-Account-Role-B"
    }
  ]
}
```

## Exemples de rôles supposés

Vous pouvez utiliser un seul rôle assumé pour accéder à toutes les ressources S3 d'un compte, ou avec Amazon EMR 6.11 et versions ultérieures, vous pouvez configurer plusieurs IAM rôles à assumer lorsque vous accédez à différents compartiments S3 entre comptes.

### Rubriques

- [Accédez aux ressources S3 avec un rôle assumé](#)
- [Accédez aux ressources S3 avec plusieurs rôles assumés](#)

### Accédez aux ressources S3 avec un rôle assumé

#### Note

Lorsque vous configurez une tâche pour utiliser un seul rôle assumé, toutes les ressources S3 de la tâche utilisent ce rôle, y compris le `entryPoint` script.

Si vous souhaitez utiliser un seul rôle assumé pour accéder à toutes les ressources S3 du compte B, spécifiez les configurations suivantes :

1. Spécifiez EMRFS la configuration `fs.s3.customAWSCredentialsProvider`  
`àspark.hadoop.fs.s3.customAWSCredentialsProvider=com.amazonaws.emr.AssumeRoleA`
2. Pour Spark, utilisez `spark.emr-serverless.driverEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN` et `spark.executorEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN` pour spécifier les variables d'environnement sur le pilote et les exécuteurs.
3. Pour Hive, utilisez `hive.emr-serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN` et `tez.am.emr-serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN`, et pour spécifier les variables `tez.task.emr-serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN` d'environnement sur le pilote Hive, le maître d'application Tez et les conteneurs de tâches Tez.

Les exemples suivants montrent comment utiliser un rôle assumé pour démarrer une tâche EMR sans serveur exécutée avec un accès entre comptes.

## Spark

L'exemple suivant montre comment utiliser un rôle assumé pour démarrer une tâche Spark EMR sans serveur exécutée avec un accès multicompte à S3.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "entrypoint_location",
      "entryPointArguments": [":argument_1:", ":argument_2:"],
      "sparkSubmitParameters": "--conf spark.executor.cores=4 --conf
spark.executor.memory=20g --conf spark.driver.cores=4 --conf spark.driver.memory=8g
--conf spark.executor.instances=1"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "spark-defaults",
      "properties": {
        "spark.hadoop.fs.s3.customAWSCredentialsProvider":
"spark.hadoop.fs.s3.customAWSCredentialsProvider=com.amazonaws.emr.AssumeRoleAWSCredentials"
```

```

        "spark.emr-serverless.driverEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN":
"arn:aws:iam::AccountB:role/Cross-Account-Role-B",
        "spark.executorEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN":
"arn:aws:iam::AccountB:role/Cross-Account-Role-B"
    }
  ]]
}'

```

## Hive

L'exemple suivant montre comment utiliser un rôle assumé pour démarrer une tâche EMR Serverless Hive exécutée avec un accès multicompte à S3.

```

aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "hive": {
      "query": "query_location",
      "parameters": "hive_parameters"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "hive-site",
      "properties": {
        "fs.s3.customAWSCredentialsProvider":
"com.amazonaws.emr.serverless.credentialsprovider.AssumeRoleAWSCredentialsProvider",
        "hive.emr-serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN":
"arn:aws:iam::AccountB:role/Cross-Account-Role-B",
        "tez.am.emr-serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN":
"arn:aws:iam::AccountB:role/Cross-Account-Role-B",
        "tez.task.emr-
serverless.launch.env.ASSUME_ROLE_CREDENTIALS_ROLE_ARN":
"arn:aws:iam::AccountB:role/Cross-Account-Role-B"
      }
    }
  ]]
}'

```

## Accédez aux ressources S3 avec plusieurs rôles assumés

Avec les versions 6.11.0 et supérieures EMR sans serveur, vous pouvez configurer plusieurs IAM rôles à assumer lorsque vous accédez à différents buckets multicomptes. Si vous souhaitez accéder à différentes ressources S3 avec différents rôles assumés dans le compte B, utilisez les configurations suivantes lorsque vous démarrez l'exécution de la tâche :

1. Spécifiez EMRFS la configuration `fs.s3.customAWSCredentialsProvider` à `com.amazonaws.emr.serverless.credentialsprovider.BucketLevelAssumeRoleCredential`
2. Spécifiez la EMRFS configuration `fs.s3.bucketLevelAssumeRoleMapping` pour définir le mappage entre le nom du compartiment S3 et le IAM rôle à assumer dans le compte B. La valeur doit être au format `debucket1->role1;bucket2->role2`.

Par exemple, vous pouvez utiliser `arn:aws:iam::AccountB:role/Cross-Account-Role-B-1` pour accéder au bucket `bucket1` et utiliser `arn:aws:iam::AccountB:role/Cross-Account-Role-B-2` pour accéder au bucket `bucket2`. Les exemples suivants montrent comment démarrer une tâche EMR sans serveur exécutée avec un accès entre comptes via plusieurs rôles assumés.

### Spark

L'exemple suivant montre comment utiliser plusieurs rôles assumés pour créer une exécution de tâche Spark EMR sans serveur.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "entrypoint_location",
      "entryPointArguments": [":argument_1:", ":argument_2:"],
      "sparkSubmitParameters": "--conf spark.executor.cores=4 --conf
spark.executor.memory=20g --conf spark.driver.cores=4 --conf spark.driver.memory=8g
--conf spark.executor.instances=1"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "spark-defaults",
      "properties": {
```

```

        "spark.hadoop.fs.s3.customAWSCredentialsProvider":
"com.amazonaws.emr.serverless.credentialsprovider.BucketLevelAssumeRoleCredentialsProvider"
        "spark.hadoop.fs.s3.bucketLevelAssumeRoleMapping":
"bucket1->arn:aws:iam::AccountB:role/Cross-Account-Role-B-1;bucket2-
>arn:aws:iam::AccountB:role/Cross-Account-Role-B-2"
    }
  ]}
}'

```

## Hive

Les exemples suivants montrent comment utiliser plusieurs rôles assumés pour créer une exécution de tâche EMR Serverless Hive.

```

aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "hive": {
      "query": "query_location",
      "parameters": "hive_parameters"
    }
  }' \
  --configuration-overrides '{
    "applicationConfiguration": [{
      "classification": "hive-site",
      "properties": {
        "fs.s3.customAWSCredentialsProvider":
"com.amazonaws.emr.serverless.credentialsprovider.AssumeRoleAWSCredentialsProvider",
        "fs.s3.bucketLevelAssumeRoleMapping": "bucket1-
>arn:aws:iam::AccountB:role/Cross-Account-Role-B-1;bucket2-
>arn:aws:iam::AccountB:role/Cross-Account-Role-B-2"
      }
    }
  ]}
}'

```

## Résolution des erreurs dans EMR Serverless

Utilisez les informations suivantes pour diagnostiquer et résoudre les problèmes courants que vous pouvez rencontrer lorsque vous travaillez avec Amazon EMR Serverless.



## Rubriques

- [Erreur : limite dépassée pour la capacité maximale autorisée.](#)
- [Erreur : la capacité maximale configurée a été dépassée. Réessayez ultérieurement.](#)
- [Erreur : l'accès S3 est refusé. Vérifiez les autorisations d'accès S3 du rôle d'exécution des tâches sur les ressources S3 requises.](#)
- [Erreur ModuleNotFoundError : aucun module n'a été nommé<module>. Reportez-vous au guide de l'utilisateur pour savoir comment utiliser les bibliothèques Python avec EMR Serverless.](#)
- [Erreur : Impossible d'assumer le rôle d'exécution <role name>car celui-ci n'existe pas ou n'est pas configuré avec la relation de confiance requise.](#)

### Erreur : limite dépassée pour la capacité maximale autorisée.

Cette erreur indique que EMR Serverless n'a pas pu soumettre la tâche car l'application a dépassé les limites de capacité maximale que vous avez configurées. Augmentez les limites de capacité maximale de l'application.

### Erreur : la capacité maximale configurée a été dépassée. Réessayez ultérieurement.

Cette erreur indique que EMR Serverless n'a pas pu démarrer une nouvelle tâche car l'application a dépassé les limites de capacité maximale que vous avez configurées. Augmentez les limites de capacité maximale de l'application.

### Erreur : l'accès S3 est refusé. Vérifiez les autorisations d'accès S3 du rôle d'exécution des tâches sur les ressources S3 requises.

Cette erreur indique que votre tâche n'a pas accès à vos ressources S3. Vérifiez que le rôle d'exécution de la tâche est autorisé à accéder aux ressources S3 que la tâche doit utiliser. Pour en savoir plus sur les rôles d'exécution, voir [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).

### Erreur ModuleNotFoundError : aucun module n'a été nommé<module>. Reportez-vous au guide de l'utilisateur pour savoir comment utiliser les bibliothèques Python avec EMR Serverless.

Cette erreur indique qu'aucun module Python n'était disponible pour le job Spark. Vérifiez que les bibliothèques Python dépendantes sont disponibles pour la tâche. Pour plus d'informations sur la

façon d'empaqueter des bibliothèques Python, consultez [Utilisation de bibliothèques Python avec EMR Serverless](#).

Erreur : Impossible d'assumer le rôle d'exécution <role name>car celui-ci n'existe pas ou n'est pas configuré avec la relation de confiance requise.

Cette erreur indique que le rôle d'exécution du travail que vous avez spécifié pour le travail n'existe pas ou qu'il n'a aucune relation de confiance pour les autorisations EMR sans serveur. Pour vérifier que le IAM rôle existe et que vous avez correctement configuré la politique de confiance du rôle, consultez les instructions dans [Rôles d'exécution des tâches pour Amazon EMR Serverless](#).

# Exécutez des charges de travail interactives avec EMR Serverless via Studio EMR

## Présentation

Une application interactive est une application EMR sans serveur dont les fonctionnalités interactives sont activées. Avec les applications interactives Amazon EMR Serverless, vous pouvez exécuter des charges de travail interactives avec des blocs-notes Jupyter gérés dans Amazon Studio. EMR Cela permet aux ingénieurs de données, aux scientifiques des données et aux analystes de données d'utiliser EMR Studio pour exécuter des analyses interactives avec des ensembles de données dans des magasins de données tels qu'Amazon S3 et Amazon DynamoDB.

Les cas d'utilisation des applications interactives dans EMR Serverless sont les suivants :

- Les ingénieurs de données utilisent l'IDExpérience de EMR Studio pour créer un ETL script. Le script ingère des données sur site, les transforme à des fins d'analyse et les stocke dans Amazon S3.
- Les data scientists utilisent des carnets pour explorer les ensembles de données et entraîner des modèles d'apprentissage automatique (ML) afin de détecter les anomalies dans les ensembles de données.
- Les analystes de données explorent les ensembles de données et créent des scripts qui génèrent des rapports quotidiens pour mettre à jour des applications telles que les tableaux de bord commerciaux.

## Prérequis

Pour utiliser des charges de travail interactives avec EMR Serverless, vous devez satisfaire aux exigences suivantes :

- EMR Les applications interactives sans serveur sont prises en charge avec Amazon EMR 6.14.0 et versions ultérieures.
- Pour accéder à votre application interactive, exécuter les charges de travail que vous soumettez et exécuter des blocs-notes interactifs depuis EMR Studio, vous avez besoin d'autorisations et de rôles spécifiques. Pour de plus amples informations, veuillez consulter [Autorisations requises pour les charges de travail interactives](#).

## Autorisations requises pour les charges de travail interactives

Outre les [autorisations de base requises pour accéder à EMR Serverless](#), vous devez configurer des autorisations supplémentaires pour votre IAM identité ou votre rôle :

Pour accéder à votre application interactive

Configurez les autorisations d'utilisateur et d'espace de travail pour EMR Studio. Pour plus d'informations, consultez [Configurer les autorisations utilisateur de EMR Studio](#) dans le guide EMR de gestion Amazon.

Pour exécuter les charges de travail que vous soumettez avec Serverless EMR

Configurez un rôle d'exécution des tâches. Pour de plus amples informations, veuillez consulter [Création d'un rôle d'exécution de tâches](#).

Pour exécuter les blocs-notes interactifs depuis Studio EMR

Ajoutez les autorisations supplémentaires suivantes à la IAM politique pour les utilisateurs du Studio :

- **emr-serverless:AccessInteractiveEndpoints**- Accorde l'autorisation d'accéder à l'application interactive que vous spécifiez et de vous y connecterResource. Cette autorisation est requise pour se connecter à une application EMR sans serveur à partir d'un espace de travail EMR Studio.
- **iam:PassRole**- Accorde l'autorisation d'accéder au rôle IAM d'exécution que vous prévoyez d'utiliser lorsque vous vous connectez à une application. L'PassRole autorisation appropriée est requise pour se connecter à une application EMR sans serveur à partir d'un espace de travail EMR Studio.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EMRServerlessInteractiveAccess",
      "Effect": "Allow",
      "Action": "emr-serverless:AccessInteractiveEndpoints",
      "Resource": "arn:aws:emr-serverless:Region:account:/applications/*"
    },
    {
      "Sid": "EMRServerlessRuntimeRoleAccess",
      "Effect": "Allow",
      "Action": "iam:PassRole",
```

```
    "Resource": "interactive-execution-role-ARN",
    "Condition": {
      "StringLike": {
        "iam:PassedToService": "emr-serverless.amazonaws.com"
      }
    }
  ]
}
```

## Configuration d'applications interactives

Suivez les étapes de haut niveau suivantes pour créer une application EMR sans serveur dotée de fonctionnalités interactives à partir d'Amazon EMR Studio dans le AWS Management Console.

1. Suivez les étapes décrites [Commencer à utiliser Amazon EMR Serverless](#) pour créer une application.
2. Lancez ensuite un espace de travail depuis EMR Studio et connectez-le à une application EMR sans serveur en tant qu'option de calcul. Pour plus d'informations, consultez l'onglet Charge de travail interactive à l'étape 2 de la documentation [EMRServerless Getting Started](#).

Lorsque vous attachez une application à un espace de travail Studio, le démarrage de l'application se déclenche automatiquement si elle n'est pas déjà en cours d'exécution. Vous pouvez également prédémarrer l'application et la garder prête avant de l'associer à l'espace de travail.

## Considérations relatives aux applications interactives

- EMR Les applications interactives sans serveur sont prises en charge avec Amazon EMR 6.14.0 et versions ultérieures.
- EMR Studio est le seul client intégré aux applications interactives EMR sans serveur. Les fonctionnalités de EMR Studio suivantes ne sont pas prises en charge par les applications interactives EMR sans serveur : collaboration dans l'espace de travail, SQL Explorateur et exécution programmatique de blocs-notes.
- Les applications interactives ne sont prises en charge que pour le moteur Spark.
- Les applications interactives prennent en charge les noyaux Python 3 PySpark et Spark Scala.
- Vous pouvez exécuter jusqu'à 25 blocs-notes simultanément sur une seule application interactive.

- Aucun point de terminaison ou API interface ne prend en charge les blocs-notes Jupyter auto-hébergés dotés d'applications interactives.
- Pour une expérience de démarrage optimisée, nous vous recommandons de configurer la capacité préinitialisée pour les pilotes et les exécuteurs, et de pré-démarrer votre application. Lorsque vous prédémarrez l'application, vous vous assurez qu'elle est prête lorsque vous souhaitez l'associer à votre espace de travail.

```
aws emr-serverless start-application \  
--application-id your-application-id
```

- Par défaut, autoStopConfig est activé pour les applications. Cela arrête l'application après 30 minutes d'inactivité. Vous pouvez modifier cette configuration dans le cadre de votre update-application demande create-application ou de votre demande.
- Lorsque vous utilisez une application interactive, nous vous recommandons de configurer une capacité pré-initialisée de noyaux, de pilotes et d'exécuteurs pour exécuter vos blocs-notes. Chaque session interactive Spark nécessite un noyau et un pilote. EMR Serverless gère donc un programme de travail de noyau pré-initialisé pour chaque pilote pré-initialisé. Par défaut, EMR Serverless conserve une capacité préinitialisée d'un utilisateur du noyau dans l'ensemble de l'application, même si vous ne spécifiez aucune capacité préinitialisée pour les pilotes. Chaque processeur de noyau utilise 4 V CPU et 16 Go de mémoire. Pour obtenir des informations sur les prix actuels, consultez la page de [EMRtarification d'Amazon](#).
- Vous devez disposer d'un quota CPU de service v suffisant dans votre Compte AWS pour exécuter des charges de travail interactives. Si vous n'exécutez pas de charges de travail compatibles avec Lake Formation, nous vous recommandons d'utiliser au moins 24 v. CPU Si c'est le cas, nous recommandons au moins 28 CPU v.
- EMRServerless arrête automatiquement les noyaux des ordinateurs portables s'ils sont inactifs depuis plus de 60 minutes. EMRServerless calcule le temps d'inactivité du noyau à partir de la dernière activité effectuée pendant la session du bloc-notes. Vous ne pouvez actuellement pas modifier le paramètre de délai d'inactivité du noyau.
- Pour activer Lake Formation avec des charges de travail interactives, définissez la configuration comme spark.emr-serverless.lakeformation.enabled étant true inférieure à la spark-defaults classification dans l'runtime-configurationobjet lorsque vous [créez une application EMR sans serveur](#). Pour en savoir plus sur l'activation de Lake Formation en mode EMR Serverless, consultez [Enabling Lake Formation in Amazon EMR](#).

# Exécutez des charges de travail interactives avec EMR Serverless via un point de terminaison Apache Livy

Avec les EMR versions 6.14.0 et supérieures d'Amazon, vous pouvez créer et activer un point de terminaison Apache Livy tout en créant une application EMR sans serveur et exécuter des charges de travail interactives via vos blocs-notes auto-hébergés ou avec un client personnalisé. Un point de terminaison Apache Livy offre les avantages suivants :

- Vous pouvez vous connecter en toute sécurité à un point de terminaison Apache Livy via les blocs-notes Jupyter et gérer les charges de travail Apache Spark avec l'interface d'Apache Livy. REST
- Utilisez les REST API opérations Apache Livy pour les applications Web interactives qui utilisent les données des charges de travail Apache Spark.

## Prérequis

Pour utiliser un point de terminaison Apache Livy avec EMR Serverless, vous devez répondre aux exigences suivantes :

- Suivez les étapes décrites dans [Getting started with Amazon EMR Serverless](#).
- Pour exécuter des charges de travail interactives via les points de terminaison Apache Livy, vous avez besoin de certaines autorisations et de certains rôles. Pour plus d'informations, consultez la section [Autorisations requises pour les charges de travail interactives](#).

## Autorisations nécessaires

Outre les autorisations requises pour accéder à EMR Serverless, vous devez également ajouter les autorisations suivantes à votre IAM rôle pour accéder à un point de terminaison Apache Livy et exécuter des applications :

- `emr-serverless:AccessLivyEndpoints`— autorise l'accès et la connexion à l'application compatible Livy que vous spécifiez comme. Resource Vous avez besoin de cette autorisation pour exécuter les REST API opérations disponibles depuis le point de terminaison Apache Livy.
- `iam:PassRole`— autorise l'accès au rôle d'IAM exécution lors de la création de la session Apache Livy. EMR Serverless utilisera ce rôle pour exécuter vos charges de travail.

- `emr-serverless:GetDashboardForJobRun`— autorise la génération de l'interface utilisateur de Spark Live et des liens vers les journaux des pilotes et donne accès aux journaux dans le cadre des résultats de la session Apache Livy.

```
{
  "Version": "2012-10-17",
  "Statement": [{
    "Sid": "EMRServerlessInteractiveAccess",
    "Effect": "Allow",
    "Action": "emr-serverless:AccessLivyEndpoints",
    "Resource": "arn:aws:emr-serverless:<AWS_REGION>:account:/applications/*"
  },
  {
    "Sid": "EMRServerlessRuntimeRoleAccess",
    "Effect": "Allow",
    "Action": "iam:PassRole",
    "Resource": "execution-role-ARN",
    "Condition": {
      "StringLike": {
        "iam:PassedToService": "emr-serverless.amazonaws.com"
      }
    }
  },
  {
    "Sid": "EMRServerlessDashboardAccess",
    "Effect": "Allow",
    "Action": "emr-serverless:GetDashboardForJobRun",
    "Resource": "arn:aws:emr-serverless:<AWS_REGION>:account:/applications/*"
  }
  ]
}
```

## Premiers pas

1. Pour créer une application compatible avec Apache Livy, exécutez la commande suivante.

```
aws emr-serverless create-application \
--name my-application-name \
--type 'application-type' \
--release-label <Amazon EMR-release-version>
--interactive-configuration '{"livyEndpointEnabled": true}'
```



2. Une fois que EMR Serverless a créé votre application, démarrez-la pour rendre le point de terminaison Apache Livy disponible.

```
aws emr-serverless start-application \  
--application-id application-id
```

Utilisez la commande suivante pour vérifier l'état de votre demande. Une fois le statut atteint `STARTED`, vous pouvez accéder au point de terminaison Apache Livy.

```
aws emr-serverless get-application \  
--region <AWS_REGION> --application-id >application_id<
```

3. Utilisez ce qui suit URL pour accéder au point de terminaison :

```
https://_<application-id>_.livy.emr-serverless-  
services._<AWS_REGION>_.amazonaws.com
```

Une fois que le point de terminaison est prêt, vous pouvez soumettre des charges de travail en fonction de votre cas d'utilisation. Vous devez signer chaque demande envoyée au point de terminaison avec [le SIGv4 protocole](#) et transmettre un en-tête d'autorisation. Vous pouvez utiliser les méthodes suivantes pour exécuter des charges de travail :

- HTTPclient : vous devez soumettre les API opérations de votre point de terminaison Apache Livy à un HTTP client personnalisé.
- Noyau Sparkmagic : vous devez exécuter localement le noyau Sparkmagic et soumettre des requêtes interactives avec les blocs-notes Jupyter.

## HTTPclients

Pour créer une session Apache Livy, vous devez la soumettre `emr-serverless.session.executionRoleArn` dans le `conf` paramètre du corps de votre requête. L'exemple suivant est un exemple de POST `/sessions` demande.

```
{  
  "kind": "pyspark",  
  "heartbeatTimeoutInSeconds": 60,  
  "conf": {  
    "emr-serverless.session.executionRoleArn": "<executionRoleArn>"  
  }  
}
```

```
}
}
```

Le tableau suivant décrit toutes les API opérations Apache Livy disponibles.

APIopération	Description
GET/sessions	Renvoie la liste de toutes les sessions interactives actives.
POST/sessions	Crée une nouvelle session interactive via Spark ou Pyspark.
GET/sessions/ <i>&lt;sessionId &gt;</i>	Renvoie les informations de session.
GET/sessions/ <i>&lt;sessionId &gt;</i> /État	Renvoie l'état de la session.
DELETE/sessions/ <i>&lt;sessionId &gt;</i>	Arrête et supprime la session.
GET/sessions/ <i>&lt;sessionId &gt;</i> /déclarations	Renvoie toutes les instructions d'une session.
POST/sessions/ <i>&lt;sessionId &gt;</i> /déclarations	Exécute une instruction au cours d'une session.
GET/sessions/ <i>&lt;sessionId &gt;</i> /déclarations/ <i>&lt;statementId &gt;</i>	Renvoie les détails de l'instruction spécifiée dans une session.
POST/sessions/ <i>&lt;sessionId &gt;</i> /déclarations/ <i>&lt;statementId &gt;</i> /annuler	Annule l'instruction spécifiée dans cette session.

### Envoi de requêtes au point de terminaison Apache Livy

Vous pouvez également envoyer des demandes directement au point de terminaison Apache Livy depuis un HTTP client. Cela vous permet d'exécuter du code à distance pour vos cas d'utilisation en dehors d'un bloc-notes.

Avant de commencer à envoyer des demandes au terminal, assurez-vous d'avoir installé les bibliothèques suivantes :

```
pip3 install botocore awscli requests
```

Voici un exemple de script Python permettant d'envoyer des HTTP demandes directement à un point de terminaison :

```
from botocore import crt
import requests
from botocore.awsrequest import AWSRequest
from botocore.credentials import Credentials
import botocore.session
import json, pprint, textwrap

endpoint = 'https://<application_id>.livy.emr-serverless-
services-<AWS_REGION>.amazonaws.com'
headers = {'Content-Type': 'application/json'}

session = botocore.session.Session()
signer = crt.auth.CrtS3SigV4Auth(session.get_credentials(), 'emr-serverless',
    '<AWS_REGION>')

### Create session request

data = {'kind': 'pyspark', 'heartbeatTimeoutInSeconds': 60, 'conf': { 'emr-
serverless.session.executionRoleArn': 'arn:aws:iam::123456789012:role/role1'}}

request = AWSRequest(method='POST', url=endpoint + "/sessions", data=json.dumps(data),
    headers=headers)

request.context["payload_signing_enabled"] = False

signer.add_auth(request)

prepped = request.prepare()

r = requests.post(prepped.url, headers=prepped.headers, data=json.dumps(data))

pprint.pprint(r.json())

### List Sessions Request

request = AWSRequest(method='GET', url=endpoint + "/sessions", headers=headers)

request.context["payload_signing_enabled"] = False
```

```
signer.add_auth(request)

prepped = request.prepare()

r2 = requests.get(prepped.url, headers=prepped.headers)
pprint.pprint(r2.json())

### Get session state

session_url = endpoint + r.headers['location']

request = AWSRequest(method='GET', url=session_url, headers=headers)

request.context["payload_signing_enabled"] = False

signer.add_auth(request)

prepped = request.prepare()

r3 = requests.get(prepped.url, headers=prepped.headers)

pprint.pprint(r3.json())

### Submit Statement

data = {
    'code': "1 + 1"
}

statements_url = endpoint + r.headers['location'] + "/statements"

request = AWSRequest(method='POST', url=statements_url, data=json.dumps(data),
    headers=headers)

request.context["payload_signing_enabled"] = False

signer.add_auth(request)

prepped = request.prepare()

r4 = requests.post(prepped.url, headers=prepped.headers, data=json.dumps(data))
```

```
pprint.pprint(r4.json())

### Check statements results

specific_statement_url = endpoint + r4.headers['location']

request = AWSRequest(method='GET', url=specific_statement_url, headers=headers)

request.context["payload_signing_enabled"] = False

signer.add_auth(request)

prepped = request.prepare()

r5 = requests.get(prepped.url, headers=prepped.headers)

pprint.pprint(r5.json())

### Delete session

session_url = endpoint + r.headers['location']

request = AWSRequest(method='DELETE', url=session_url, headers=headers)

request.context["payload_signing_enabled"] = False

signer.add_auth(request)

prepped = request.prepare()

r6 = requests.delete(prepped.url, headers=prepped.headers)

pprint.pprint(r6.json())
```

## Noyau Sparkmagic

Avant d'installer sparkmagic, assurez-vous d'avoir configuré AWS informations d'identification dans l'instance dans laquelle vous souhaitez installer sparkmagic

1. Installez sparkmagic en suivant les étapes d'[installation](#). Notez que vous n'avez qu'à effectuer les quatre premières étapes.
2. Le noyau sparkmagic prend en charge les authentificateurs personnalisés. Vous pouvez donc intégrer un authentificateur au noyau sparkmagic afin que chaque demande soit signée. SIGv4
3. Installez l'authentificateur personnalisé EMR sans serveur.

```
pip install emr-serverless-customauth
```

4. Indiquez maintenant le chemin d'accès à l'authentificateur personnalisé et au point de terminaison Apache Livy URL dans le fichier json de configuration de sparkmagic. Utilisez la commande suivante pour ouvrir le fichier de configuration.

```
vim ~/.sparkmagic/config.json
```

Voici un exemple de config.json fichier.

```
{
  "kernel_python_credentials" : {
    "username": "",
    "password": "",
    "url": "https://<application-id>.livy.emr-serverless-
services.<AWS_REGION>.amazonaws.com",
    "auth": "Custom_Auth"
  },

  "kernel_scala_credentials" : {
    "username": "",
    "password": "",
    "url": "https://<application-id>.livy.emr-serverless-
services.<AWS_REGION>.amazonaws.com",
    "auth": "Custom_Auth"
  },
  "authenticators": {
    "None": "sparkmagic.auth.customauth.Authenticator",
    "Basic_Access": "sparkmagic.auth.basic.Basic",
    "Custom_Auth":
"emr_serverless_customauth.customauthenticator.EMRServerlessCustomSigV4Signer"
  },
  "livy_session_startup_timeout_seconds": 600,
  "ignore_ssl_errors": false
}
```

```
}
```

5. Démarrez Jupyter Lab. Il doit utiliser l'authentification personnalisée que vous avez configurée lors de la dernière étape.
6. Vous pouvez ensuite exécuter les commandes de bloc-notes suivantes et votre code pour commencer.

```
%%info //Returns the information about the current sessions.
```

```
%%configure -f //Configure information specific to a session. We supply  
executionRoleArn in this example. Change it for your use case.
```

```
{  
  "driverMemory": "4g",  
  "conf": {  
    "emr-serverless.session.executionRoleArn":  
    "arn:aws:iam::123456789012:role/JobExecutionRole"  
  }  
}
```

```
<your code>//Run your code to start the session
```

En interne, chaque instruction appelle chacune des API opérations Apache Livy via le point de terminaison Apache Livy configuré. URL Vous pouvez ensuite rédiger vos instructions en fonction de votre cas d'utilisation.

## Considérations

Tenez compte des considérations suivantes lorsque vous exécutez des charges de travail interactives via les points de terminaison Apache Livy.

- EMRServerless maintient l'isolation au niveau de la session en utilisant le principal de l'appelant. Le principal appelant qui crée la session est le seul à pouvoir accéder à cette session. Pour une isolation plus précise, vous pouvez configurer une identité source lorsque vous utilisez des informations d'identification. Dans ce cas, EMR Serverless applique l'isolation au niveau de la session en fonction à la fois de l'identité principale de l'appelant et de l'identité de la source. Pour plus d'informations sur l'identité de la source, voir [Surveiller et contrôler les actions entreprises avec des rôles assumés](#).

- Les points de terminaison Apache Livy sont pris en charge avec les versions 6.14.0 et EMR supérieures sans serveur.
- Les points de terminaison Apache Livy ne sont pris en charge que pour le moteur Apache Spark.
- Les points de terminaison Apache Livy prennent en charge Scala Spark et PySpark
- Par défaut, autoStopConfig est activé dans vos applications. Cela signifie que les applications s'arrêtent après 15 minutes d'inactivité. Vous pouvez modifier cette configuration dans le cadre de votre update-application demande create-application ou de votre demande.
- Vous pouvez exécuter jusqu'à 25 sessions simultanées sur une seule application compatible avec le point de terminaison Apache Livy.
- Pour une expérience de démarrage optimale, nous vous recommandons de configurer la capacité pré-initialisée pour les pilotes et les exécuteurs.
- Vous devez démarrer manuellement votre application avant de vous connecter au point de terminaison Apache Livy.
- Vous devez disposer d'un quota CPU de service v suffisant dans votre Compte AWS pour exécuter des charges de travail interactives avec le point de terminaison Apache Livy. Nous recommandons au moins 24 CPU v.
- Le délai d'expiration de session Apache Livy par défaut est de 1 heure. Si vous n'exécutez pas d'instructions pendant une heure, Apache Livy supprime la session et libère le pilote et les exécuteurs. Vous ne pouvez pas modifier cette configuration.
- Seules les sessions actives peuvent interagir avec un point de terminaison Apache Livy. Une fois la session terminée, annulée ou terminée, vous ne pouvez pas y accéder via le point de terminaison Apache Livy.



# Journalisation et surveillance

La surveillance joue un rôle important dans le maintien de la fiabilité, de la disponibilité et des performances des applications et des tâches EMR sans serveur. Vous devez collecter des données de surveillance provenant de toutes les parties de vos solutions EMR Serverless afin de pouvoir corriger plus facilement une panne multipoint, le cas échéant.

## Rubriques

- [Stockage des journaux](#)
- [Bûches rotatives](#)
- [Chiffrement des journaux](#)
- [Configuration des propriétés Apache Log4j2 pour Amazon Serverless EMR](#)
- [Surveillance EMR sans serveur](#)
- [Automatiser le mode EMR Serverless avec Amazon EventBridge](#)

## Stockage des journaux

Pour suivre l'avancement de vos tâches sur EMR Serverless et résoudre les problèmes d'échec, vous pouvez choisir la manière dont EMR Serverless stocke et diffuse les journaux des applications. Lorsque vous soumettez une exécution de tâche, vous pouvez spécifier le stockage géré, Amazon S3 et Amazon CloudWatch comme options de journalisation.

Avec CloudWatch, vous pouvez spécifier les types de journaux et les emplacements des journaux que vous souhaitez utiliser, ou accepter les types et emplacements par défaut. Pour plus d'informations sur CloudWatch les journaux, consultez [the section called "Amazon CloudWatch"](#). En ce qui concerne le stockage géré et la journalisation S3, le tableau suivant indique les emplacements des journaux et la disponibilité de l'interface utilisateur auxquels vous pouvez vous attendre si vous choisissez le [stockage géré](#), les [compartiments Amazon S3](#) ou les deux.

Option	Journaux d'événements	Journaux de conteneurs	Interface utilisateur de l'application
Stockage géré	Stocké dans un espace de stockage géré	Stocké dans un espace de stockage géré	Pris en charge

Option	Journaux d'événements	Journaux de conteneurs	Interface utilisateur de l'application
Stockage géré et compartiment S3	Stocké aux deux endroits	Stocké dans un compartiment S3	Pris en charge
Compartiment Amazon S3	Stocké dans un compartiment S3	Stocké dans un compartiment S3	Non pris en charge <sup>1</sup>

<sup>1</sup> Nous vous recommandons de conserver l'option Stockage géré sélectionnée. Dans le cas contraire, vous ne pouvez pas utiliser l'application intégrée UIs.

## Journalisation EMR sans serveur avec stockage géré

Par défaut, EMR Serverless stocke les journaux des applications en toute sécurité dans le stockage EMR géré par Amazon pendant une durée maximale de 30 jours.

### Note

Si vous désactivez l'option par défaut, Amazon ne EMR pourra pas résoudre les problèmes liés à vos tâches en votre nom.

Pour désactiver cette option dans EMR Studio, désélectionnez l'option Autoriser AWS pour conserver les journaux pendant 30 jours, cochez la case Paramètres supplémentaires de la page Soumettre le travail.

Pour désactiver cette option depuis le AWS CLI, utilisez la `managedPersistenceMonitoringConfiguration` configuration lorsque vous soumettez une exécution de tâche.

```
{
  "monitoringConfiguration": {
    "managedPersistenceMonitoringConfiguration": {
      "enabled": false
    }
  }
}
```

## Journalisation EMR sans serveur avec des compartiments Amazon S3

Avant que vos tâches puissent envoyer des données de journal à Amazon S3, vous devez inclure les autorisations suivantes dans la politique d'autorisation pour le rôle d'exécution des tâches. *DOC-EXAMPLE-BUCKET-LOGGING* Remplacez-le par le nom de votre bucket de journalisation.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::DOC-EXAMPLE-BUCKET-LOGGING/*"
      ]
    }
  ]
}
```

Pour configurer un compartiment Amazon S3 afin de stocker les journaux provenant du AWS CLI, utilisez la `s3MonitoringConfiguration` configuration lorsque vous lancez une tâche. Pour ce faire, fournissez les éléments suivants `--configuration-overrides` dans la configuration.

```
{
  "monitoringConfiguration": {
    "s3MonitoringConfiguration": {
      "logUri": "s3://DOC-EXAMPLE-BUCKET-LOGGING/logs/"
    }
  }
}
```

Pour les tâches par lots pour lesquelles aucune nouvelle tentative n'est activée, EMR Serverless envoie les journaux au chemin suivant :

```
'/applications/<applicationId>/jobs/<jobId>'
```

EMR Les versions 7.1.0 et supérieures sans serveur prennent en charge les nouvelles tentatives pour les tâches de streaming et les tâches par lots. Si vous exécutez une tâche avec les nouvelles

tentatives activées, EMR Serverless ajoute automatiquement un numéro de tentative au préfixe du chemin du journal, afin que vous puissiez mieux distinguer et suivre les journaux.

```
'/applications/<applicationId>/jobs/<jobId>/attempts/<attemptNumber>/'
```

## Journalisation EMR sans serveur avec Amazon CloudWatch

Lorsque vous soumettez une tâche à une application EMR sans serveur, vous pouvez choisir Amazon CloudWatch comme option pour stocker les journaux de votre candidature. Cela vous permet d'utiliser les fonctionnalités d'analyse des journaux CloudWatch telles que Logs Insights et Live Tail. Vous pouvez également diffuser des journaux depuis d'autres systèmes, par exemple CloudWatch à des OpenSearch fins d'analyse plus approfondie.

EMRServerless fournit une journalisation en temps réel des journaux des conducteurs. Vous pouvez consulter les journaux en temps réel grâce à la fonctionnalité CloudWatch Live Tail ou via les commandes CloudWatch CLI Tail.

Par défaut, la CloudWatch journalisation est désactivée pour EMR Serverless. Pour l'activer, consultez la configuration dans [AWS CLI](#).

### Note

Amazon CloudWatch publie des journaux en temps réel, ce qui lui permet de mobiliser davantage de ressources de la part de ses employés. Si vous optez pour une faible capacité de travail, l'impact sur la durée d'exécution de votre travail peut augmenter. Si vous activez la CloudWatch journalisation, nous vous recommandons de choisir une capacité de travail supérieure. Il est également possible que la publication du journal soit ralentie si le taux de transactions par seconde (TPS) est trop faible pour PutLogEvents. La configuration CloudWatch de régulation est globale pour tous les services, y compris EMR Serverless. Pour plus d'informations, voir [Comment déterminer la régulation dans mes CloudWatch journaux](#) ? sur AWS re:post.

## Autorisations requises pour se connecter avec CloudWatch

Avant que vos tâches puissent envoyer des données de journal à Amazon CloudWatch, vous devez inclure les autorisations suivantes dans la politique d'autorisation relative au rôle d'exécution des tâches.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:DescribeLogGroups"
      ],
      "Resource": [
        "arn:aws:logs:Région AWS:111122223333:*"
      ]
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:PutLogEvents",
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:DescribeLogStreams"
      ],
      "Resource": [
        "arn:aws:logs:Région AWS:111122223333:log-group:my-log-group-name:*"
      ]
    }
  ]
}
```

## AWS CLI

Pour configurer Amazon CloudWatch afin qu'il stocke les journaux pour EMR Serverless à partir du AWS CLI, utilisez la `cloudWatchLoggingConfiguration` configuration lorsque vous lancez une tâche. Pour ce faire, fournissez les remplacements de configuration suivants. Facultativement, vous pouvez également fournir un nom de groupe de journaux, un nom de préfixe de flux de journaux, des types de journaux et une clé ARN de chiffrement.

Si vous ne spécifiez pas de valeurs facultatives, CloudWatch publie les journaux dans un groupe de journaux par défaut `/aws/emr-serverless`, avec le flux de journaux par défaut `/applications/applicationId/jobs/jobId/worker-type`.

EMR Les versions 7.1.0 et supérieures sans serveur prennent en charge les nouvelles tentatives pour les tâches de streaming et les tâches par lots. Si vous avez activé les nouvelles tentatives pour une

tâche, EMR Serverless ajoute automatiquement un numéro de tentative au préfixe du chemin du journal, afin que vous puissiez mieux distinguer et suivre les journaux.

```
'/applications/<applicationId>/jobs/<jobId>/attempts/<attemptNumber>/worker-type'
```

Voici la configuration minimale requise pour activer la CloudWatch journalisation Amazon avec les paramètres par défaut pour EMR Serverless :

```
{
  "monitoringConfiguration": {
    "cloudWatchLoggingConfiguration": {
      "enabled": true
    }
  }
}
```

L'exemple suivant montre toutes les configurations obligatoires et facultatives que vous pouvez spécifier lorsque vous activez la CloudWatch journalisation Amazon pour EMR Serverless. Les logTypes valeurs prises en charge sont également répertoriées sous cet exemple.

```
{
  "monitoringConfiguration": {
    "cloudWatchLoggingConfiguration": {
      "enabled": true, // Required
      "logGroupName": "Example_logGroup", // Optional
      "logStreamNamePrefix": "Example_logStream", // Optional
      "encryptionKeyArn": "key-arn", // Optional
      "logTypes": {
        "SPARK_DRIVER": ["stdout", "stderr"] //List of values
      }
    }
  }
}
```

Par défaut, EMR Serverless publie uniquement le pilote stdout et stderr dans lequel stderr se connecte. CloudWatch Si vous souhaitez d'autres journaux, vous pouvez spécifier un rôle de conteneur et les types de journaux correspondants à l'aide du logTypes champ.

La liste suivante indique les types de travailleurs pris en charge que vous pouvez spécifier pour la logTypes configuration :

## Spark

- SPARK\_DRIVER : ["STDERR", "STDOUT"]
- SPARK\_EXECUTOR : ["STDERR", "STDOUT"]

## Hive

- HIVE\_DRIVER : ["STDERR", "STDOUT", "HIVE\_LOG", "TEZ\_AM"]
- TEZ\_TASK : ["STDERR", "STDOUT", "SYSTEM\_LOGS"]

## Bûches rotatives

Amazon EMR Serverless peut alterner les journaux d'applications et les journaux d'événements Spark. La rotation des journaux permet de résoudre le problème des tâches de longue durée qui génèrent des fichiers journaux volumineux qui peuvent occuper tout l'espace disque. La rotation des journaux vous permet d'économiser de l'espace de stockage sur disque et de réduire le nombre d'échecs de tâches, car il ne vous reste plus d'espace sur votre disque.

La rotation des journaux est activée par défaut et n'est disponible que pour les tâches Spark.

### Journaux d'événements Spark

#### Note

La rotation du journal des événements Spark est disponible sur toutes les étiquettes EMR de version Amazon.

Au lieu de générer un seul fichier journal des événements, EMR Serverless fait pivoter le journal des événements à intervalles réguliers et supprime les anciens fichiers journaux d'événements. La rotation des journaux n'affecte pas les journaux chargés dans le compartiment S3.

### Journaux des applications Spark

#### Note

La rotation des journaux des applications Spark est disponible sur toutes les étiquettes EMR de version Amazon.

EMRServerless fait également pivoter les journaux des applications Spark pour les pilotes et les exécuteurs, tels que `stdout` les fichiers et `stderr`. Vous pouvez accéder aux derniers fichiers journaux en choisissant les liens des journaux dans Studio à l'aide des liens Spark History Server et Live UI. Les fichiers journaux sont les versions tronquées des derniers journaux. Pour consulter les anciens journaux soumis à une rotation, vous devez spécifier un emplacement Amazon S3 lors du stockage des journaux. Consultez la section [Journalisation EMR sans serveur avec des compartiments Amazon S3](#) pour plus d'informations.

Vous trouverez les derniers fichiers journaux à l'emplacement suivant. EMRServerless actualise les fichiers toutes les 15 secondes. Ces fichiers peuvent aller de 0 Mo à 128 Mo.

```
<example-S3-logUri>/applications/<application-id>/jobs/<job-id>/SPARK_DRIVER/stderr.gz
```

L'emplacement suivant contient les anciens fichiers ayant fait l'objet d'une rotation. Chaque fichier fait 128 Mo.

```
<example-S3-logUri>/applications/<application-id>/jobs/<job-id>/SPARK_DRIVER/archived/  
stderr_<index>.gz
```

Le même comportement s'applique également aux exécuteurs Spark. Cette modification ne s'applique qu'à la journalisation S3. La rotation des journaux n'apporte aucune modification aux flux de journaux chargés sur Amazon CloudWatch.

EMR Les versions 7.1.0 et supérieures sans serveur prennent en charge les nouvelles tentatives pour le streaming et les tâches par lots. Si vous avez activé les nouvelles tentatives pour votre tâche, EMR Serverless ajoute un préfixe au chemin du journal pour ces tâches afin que vous puissiez mieux suivre et distinguer les journaux les uns des autres. Ce chemin contient tous les journaux ayant fait l'objet d'une rotation.

```
 '/applications/<applicationId>/jobs/<jobId>/attempts/<attemptNumber>/' .
```

## Chiffrement des journaux

### Chiffrement des journaux EMR sans serveur avec un stockage géré

Pour chiffrer les journaux du stockage géré à l'aide de votre propre KMS clé, utilisez la `managedPersistenceMonitoringConfiguration` configuration lorsque vous soumettez une exécution de tâche.



```
{
  "monitoringConfiguration": {
    "managedPersistenceMonitoringConfiguration" : {
      "encryptionKeyArn": "key-arn"
    }
  }
}
```

## Chiffrement des journaux EMR sans serveur avec des compartiments Amazon S3

Pour chiffrer les journaux de votre compartiment Amazon S3 avec votre propre KMS clé, utilisez la `s3MonitoringConfiguration` configuration lorsque vous soumettez une exécution de tâche.

```
{
  "monitoringConfiguration": {
    "s3MonitoringConfiguration": {
      "logUri": "s3://DOC-EXAMPLE-BUCKET-LOGGING/logs/",
      "encryptionKeyArn": "key-arn"
    }
  }
}
```

## Chiffrer les journaux EMR sans serveur avec Amazon CloudWatch

Pour chiffrer les journaux sur Amazon CloudWatch avec votre propre KMS clé, utilisez la `cloudWatchLoggingConfiguration` configuration lorsque vous soumettez une exécution de tâche.

```
{
  "monitoringConfiguration": {
    "cloudWatchLoggingConfiguration": {
      "enabled": true,
      "encryptionKeyArn": "key-arn"
    }
  }
}
```

## Autorisations requises pour le chiffrement des journaux

Dans cette section

- [Autorisations utilisateur requises](#)
- [Autorisations relatives aux clés de chiffrement pour Amazon S3 et le stockage géré](#)
- [Autorisations relatives aux clés de chiffrement pour Amazon CloudWatch](#)

### Autorisations utilisateur requises

L'utilisateur qui soumet le travail ou consulte les journaux ou l'application UIs doit être autorisé à utiliser la clé. Vous pouvez spécifier les autorisations dans la politique KMS clé ou dans la IAM politique de l'utilisateur, du groupe ou du rôle. Si l'utilisateur qui soumet la tâche ne dispose pas des autorisations KMS clés, EMR Serverless rejette la soumission de l'exécution de la tâche.

Exemple de politique clé

La politique clé suivante fournit les autorisations nécessaires pour `kms:GenerateDataKey` et `kms:Decrypt` :

```
{
  "Effect": "Allow",
  "Principal": {
    "AWS": "arn:aws:iam::111122223333:user/user-name"
  },
  "Action": [
    "kms:GenerateDataKey",
    "kms:Decrypt"
  ],
  "Resource": "*"
}
```

Exemple IAM de politique

La IAM politique suivante fournit les autorisations nécessaires pour `kms:GenerateDataKey` et `kms:Decrypt` :

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
```

```

    "Action": [
      "kms:GenerateDataKey",
      "kms:Decrypt"
    ],
    "Resource": "key-arn"
  }
}

```

Pour lancer l'interface utilisateur Spark ou Tez, vous devez autoriser vos utilisateurs, groupes ou rôles à accéder aux `emr-serverless:GetDashboardForJobRun` API éléments suivants :

```

{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "emr-serverless:GetDashboardForJobRun"
    ]
  }
}

```

## Autorisations relatives aux clés de chiffrement pour Amazon S3 et le stockage géré

Lorsque vous chiffrez des journaux avec votre propre clé de chiffrement dans le stockage géré ou dans vos compartiments S3, vous devez configurer les autorisations relatives aux KMS clés comme suit.

Le `emr-serverless.amazonaws.com` principal doit disposer des autorisations suivantes dans la politique relative à la KMS clé :

```

{
  "Effect": "Allow",
  "Principal": {
    "Service": "emr-serverless.amazonaws.com"
  },
  "Action": [
    "kms:Decrypt",
    "kms:GenerateDataKey"
  ],
  "Resource": "*"
  "Condition": {
    "StringLike": {

```

```

    "aws:SourceArn": "arn:aws:emr-serverless:region:aws-account-id:/
applications/application-id"
  }
}

```

Pour des raisons de sécurité, nous vous recommandons d'ajouter une clé de `aws:SourceArn` condition à la politique de KMS clé. La clé de condition IAM globale `aws:SourceArn` permet de garantir que EMR Serverless utilise la KMS clé uniquement pour une applicationARN.

Le rôle d'exécution des tâches doit disposer des autorisations suivantes dans sa IAM politique :

```

{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "kms:GenerateDataKey",
      "kms:Decrypt"
    ],
    "Resource": "key-arn"
  }
}

```

## Autorisations relatives aux clés de chiffrement pour Amazon CloudWatch

Pour associer la KMS clé ARN à votre groupe de journaux, appliquez la IAM politique suivante pour le rôle d'exécution des tâches.

```

{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "logs:AssociateKmsKey"
    ],
    "Resource": [
      "arn:aws:logs:Région AWS:111122223333:log-group:my-log-group-name:*"
    ]
  }
}

```

Configurez la politique KMS clé pour accorder KMS des autorisations à Amazon CloudWatch :

```
{
  "Version": "2012-10-17",
  "Id": "key-default-1",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "logs.Région.amazonaws.com"
      },
      "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey",
      ],
      "Resource": "*",
      "Condition": {
        "ArnLike": {
          "kms:EncryptionContext:aws:logs:arn": "arn:aws:logs:Région:AWS:111122223333:*"
        }
      }
    }
  ]
}
```

## Configuration des propriétés Apache Log4j2 pour Amazon Serverless EMR

Cette page décrit comment configurer les propriétés personnalisées d'[Apache Log4j 2.x](#) pour les tâches EMR sans serveur sur. StartJobRun Si vous souhaitez configurer les classifications Log4j au niveau de l'application, consultez. [Configuration d'application par défaut pour EMR Serverless](#)

## Configuration des propriétés de Spark Log4j2 pour Amazon Serverless EMR

Avec les EMR versions 6.8.0 et supérieures d'Amazon, vous pouvez personnaliser les propriétés d'[Apache Log4j 2.x](#) pour spécifier des configurations de journal précises. Cela simplifie le dépannage de vos tâches Spark sur EMR Serverless. Pour configurer ces propriétés, utilisez les spark-executor-log4j2 classifications spark-driver-log4j2 et.

## Rubriques

- [Classifications Log4j2 pour Spark](#)
- [Exemple de configuration Log4j2 pour Spark](#)
- [Log4j2 dans les exemples de tâches Spark](#)
- [Considérations relatives à Log4j2 pour Spark](#)

## Classifications Log4j2 pour Spark

Pour personnaliser les configurations du journal Spark, utilisez les classifications suivantes avec [applicationConfiguration](#). Pour configurer les propriétés de Log4j 2.x, utilisez ce qui suit. [properties](#)

### **spark-driver-log4j2**

Cette classification définit les valeurs du `log4j2.properties` fichier pour le pilote.

### **spark-executor-log4j2**

Cette classification définit les valeurs du `log4j2.properties` fichier pour l'exécuteur.

## Exemple de configuration Log4j2 pour Spark

L'exemple suivant montre comment soumettre une tâche Spark pour personnaliser les `applicationConfiguration` configurations Log4j2 pour le pilote et l'exécuteur Spark.

Pour configurer les classifications Log4j au niveau de l'application plutôt que lorsque vous soumettez le travail, consultez. [Configuration d'application par défaut pour EMR Serverless](#)

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "/usr/lib/spark/examples/jars/spark-examples.jar",  
      "entryPointArguments": ["1"],  
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi --conf  
spark.executor.cores=4 --conf spark.executor.memory=20g --conf spark.driver.cores=4 --  
conf spark.driver.memory=8g --conf spark.executor.instances=1"  
    }  
  }'
```

```
--configuration-overrides '{
  "applicationConfiguration": [
    {
      "classification": "spark-driver-log4j2",
      "properties": {
        "rootLogger.level":"error", // will only display Spark error logs
        "logger.IdentifierForClass.name": "classpath for setting logger",
        "logger.IdentifierForClass.level": "info"
      }
    },
    {
      "classification": "spark-executor-log4j2",
      "properties": {
        "rootLogger.level":"error", // will only display Spark error logs
        "logger.IdentifierForClass.name": "classpath for setting logger",
        "logger.IdentifierForClass.level": "info"
      }
    }
  ]
}'
```

## Log4j2 dans les exemples de tâches Spark

Les exemples de code suivants montrent comment créer une application Spark pendant que vous initialisez une configuration Log4j2 personnalisée pour l'application.

### Python

#### Exemple - Utilisation de Log4j2 pour une tâche Spark avec Python

```
import os
import sys

from pyspark import SparkConf, SparkContext
from pyspark.sql import SparkSession

app_name = "PySparkApp"
if __name__ == "__main__":
    spark = SparkSession\
        .builder\
        .appName(app_name)\
        .getOrCreate()
```

```
spark.sparkContext._conf.getAll()
sc = spark.sparkContext
log4jLogger = sc._jvm.org.apache.log4j
LOGGER = log4jLogger.LogManager.getLogger(app_name)

LOGGER.info("pyspark script logger info")
LOGGER.warn("pyspark script logger warn")
LOGGER.error("pyspark script logger error")

// your code here

spark.stop()
```

Pour personnaliser Log4j2 pour le pilote lorsque vous exécutez une tâche Spark, vous pouvez utiliser la configuration suivante :

```
{
  "classification": "spark-driver-log4j2",
  "properties": {
    "rootLogger.level": "error", // only display Spark error logs
    "logger.PySparkApp.level": "info",
    "logger.PySparkApp.name": "PySparkApp"
  }
}
```

## Scala

Exemple - Utilisation de Log4j2 pour une tâche Spark avec Scala

```
import org.apache.log4j.Logger
import org.apache.spark.sql.SparkSession

object ExampleClass {
  def main(args: Array[String]): Unit = {
    val spark = SparkSession
      .builder
      .appName(this.getClass.getName)
      .getOrCreate()

    val logger = Logger.getLogger(this.getClass);
    logger.info("script logging info logs")
    logger.warn("script logging warn logs")
  }
}
```



```
logger.error("script logging error logs")

// your code here
spark.stop()
}
```

Pour personnaliser Log4j2 pour le pilote lorsque vous exécutez une tâche Spark, vous pouvez utiliser la configuration suivante :

```
{
  "classification": "spark-driver-log4j2",
  "properties": {
    "rootLogger.level": "error", // only display Spark error logs
    "logger.ExampleClass.level": "info",
    "logger.ExampleClass.name": "ExampleClass"
  }
}
```

## Considérations relatives à Log4j2 pour Spark

Les propriétés Log4j2.x suivantes ne sont pas configurables pour les processus Spark :

- `rootLogger.appenderRef.stdout.ref`
- `appender.console.type`
- `appender.console.name`
- `appender.console.target`
- `appender.console.layout.type`
- `appender.console.layout.pattern`

[Pour des informations détaillées sur les propriétés Log4j2.x que vous pouvez configurer, consultez le fichier sur `log4j2.properties.template` GitHub](#)

## Surveillance EMR sans serveur

Cette section explique comment vous pouvez surveiller vos applications et tâches Amazon EMR Serverless.

## Rubriques

- [Surveillance des applications et des tâches EMR sans serveur](#)
- [Surveillez les métriques de Spark avec Amazon Managed Service pour Prometheus](#)
- [EMRMesures d'utilisation sans serveur](#)

## Surveillance des applications et des tâches EMR sans serveur

Avec Amazon CloudWatch Metrics for EMR Serverless, vous pouvez recevoir des CloudWatch métriques en une minute et accéder à des CloudWatch tableaux de bord pour visualiser les near-real-time opérations et les performances de vos EMR applications Serverless.

EMRServerless envoie des métriques à CloudWatch chaque minute. EMRServerless émet ces métriques au niveau de l'application ainsi qu'au niveau de la tâche, du type de travailleur et des niveaux. `capacity-allocation-type`

Pour commencer, utilisez le modèle de tableau de CloudWatch bord EMR Serverless fourni dans le [GitHub référentiel EMR Serverless](#) et déployez-le.

### Note

EMR Les [charges de travail interactives sans serveur](#) sont uniquement activées pour la surveillance au niveau de l'application et ont une nouvelle dimension de type de travailleur. `Spark_Kernel` Pour surveiller et déboguer vos charges de travail interactives, vous pouvez consulter les journaux et l'interface utilisateur d'Apache Spark depuis [votre espace de travail EMR Studio](#).

Le tableau ci-dessous décrit les dimensions EMR Serverless disponibles dans l'espace de AWS/EMRServerless noms.

### Dimensions pour les EMR métriques sans serveur

Dimension	Description
<code>ApplicationId</code>	Filtres pour toutes les métriques d'une application EMR sans serveur.

Dimension	Description
JobId	Filtres pour toutes les métriques d'une tâche exécutée EMR sans serveur.
WorkerType	Filtres pour tous les indicateurs d'un type de travailleur donné. Par exemple, vous pouvez filtrer pour SPARK_DRIVER et SPARK_EXECUTORS pour les tâches Spark.
CapacityAllocationType	Filtres pour tous les indicateurs d'un type d'allocation de capacité donné. Par exemple, vous pouvez filtrer PreInitCapacity pour la capacité pré-initialisée et OnDemandCapacity pour tout le reste.

## Surveillance au niveau de l'application

Vous pouvez surveiller l'utilisation de la capacité au niveau de l'application EMR sans serveur grâce aux CloudWatch métriques Amazon. Vous pouvez également configurer une vue unique pour surveiller l'utilisation de la capacité des applications dans un CloudWatch tableau de bord.

### EMRMétriques relatives aux applications sans serveur

Métrique	Description	Dimension principale	Dimension secondaire
CPUAllocated	Le nombre total de personnes vCPUs allouées.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType

Métrique	Description	Dimension principale	Dimension secondaire
IdleWorkerCount	Nombre total de travailleurs inactifs.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType
MaxCPUAllowed	Le maximum CPU autorisé pour l'application.	ApplicationId	N/A
MaxMemoryAllowed	Mémoire maximale autorisée pour l'application, exprimée en Go.	ApplicationId	N/A
MaxStorageAllowed	Stockage maximal en Go autorisé pour l'application.	ApplicationId	N/A
MemoryAllocated	Mémoire totale allouée en Go.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType
PendingCreationWorkerCount	Nombre total de travailleurs en attente de création.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType
RunningWorkerCount	Nombre total de travailleurs utilisés par l'application.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType

Métrique	Description	Dimension principale	Dimension secondaire
StorageAlllocated	Stockage sur disque total en Go alloué.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType
TotalWorkerCount	Le nombre total de travailleurs disponibles.	ApplicationId	ApplicationId , WorkerType , CapacityAllocationType

## Surveillance au niveau des tâches

Amazon EMR Serverless envoie les métriques suivantes au niveau des tâches à Amazon CloudWatch toutes les minutes. Vous pouvez consulter les valeurs métriques pour les exécutions de tâches agrégées par état d'exécution des tâches. L'unité de chacune des métriques est le nombre.

### EMRMesures au niveau des tâches sans serveur

Métrique	Description	Dimension principale
SubmittedJobs	Le nombre de tâches dans un état Soumis.	ApplicationId
PendingJobs	Le nombre de tâches en attente.	ApplicationId
ScheduledJobs	Le nombre de tâches dans un état planifié.	ApplicationId
RunningJobs	Nombre de tâches en cours d'exécution.	ApplicationId
SuccessJobs	Le nombre d'emplois dont l'état est « Success ».	ApplicationId
FailedJobs	Le nombre de tâches en état d'échec.	ApplicationId

Métrie	Description	Dimension principale
CancelledJobs	Le nombre d'emplois dans un État annulable.	ApplicationId
CancelledJobs	Nombre de tâches annulées.	ApplicationId

Vous pouvez surveiller les métriques spécifiques au moteur pour les tâches EMR sans serveur en cours et terminées avec une application spécifique au moteur. UIs Lorsque vous consultez l'interface utilisateur d'une tâche en cours d'exécution, vous voyez l'interface utilisateur de l'application en direct avec des mises à jour en temps réel. Lorsque vous consultez l'interface utilisateur d'une tâche terminée, vous voyez l'interface utilisateur persistante de l'application.

### Exécution de tâches

Pour vos tâches EMR sans serveur en cours d'exécution, vous pouvez consulter une interface en temps réel qui fournit des métriques spécifiques au moteur. Vous pouvez utiliser l'interface utilisateur Apache Spark ou l'interface utilisateur Hive Tez pour surveiller et déboguer vos tâches. Pour y accéder UIs, utilisez la console EMR Studio ou demandez un point de URL terminaison sécurisé à l'aide du AWS Command Line Interface.

### Tâches terminées

Pour les tâches EMR sans serveur terminées, vous pouvez utiliser le serveur d'historique Spark ou l'interface utilisateur de Persistent Hive Tez pour afficher les détails des tâches, les étapes, les tâches et les statistiques relatives à l'exécution des tâches Spark ou Hive. Pour y accéder UIs, utilisez la console EMR Studio ou demandez un point de URL terminaison sécurisé avec AWS Command Line Interface.

### Surveillance au niveau du Job Worker

Amazon EMR Serverless envoie à Amazon les métriques suivantes au niveau du travailleur, disponibles dans l'espace de AWS/EMRServerless noms et le groupe de Job Worker Metrics métriques. CloudWatch EMRServerless collecte des points de données auprès de travailleurs individuels lors de l'exécution des tâches au niveau de la tâche, du type de travailleur et du niveau. capacity-allocation-type Vous pouvez l'utiliser ApplicationId comme dimension pour surveiller plusieurs tâches appartenant à la même application.

## EMR Mesures au niveau des travailleurs sans serveur

Métrique	Description	Unité	Dimension principale	Dimension secondaire
<code>WorkerCpuAllocated</code>	Nombre total de CPU cœurs v alloués aux travailleurs dans le cadre d'une exécution de tâche.	Aucun	JobId	ApplicationId , WorkerType et CapacityAllocationType
<code>WorkerCpuUsed</code>	Nombre total de CPU cœurs V utilisés par les travailleurs lors d'une exécution de tâche.	Aucun	JobId	ApplicationId , WorkerType et CapacityAllocationType
<code>WorkerMemoryAllocated</code>	Mémoire totale en Go allouée aux travailleurs dans le cadre d'une exécution de tâche.	Gigaoctets (Go)	JobId	ApplicationId , WorkerType et CapacityAllocationType
<code>WorkerMemoryUsed</code>	Mémoire totale en Go utilisée par les travailleurs lors de l'exécution d'une tâche.	Gigaoctets (Go)	JobId	ApplicationId , WorkerType et CapacityAllocationType
<code>WorkerEphemeralStorageAllocated</code>	Nombre d'octets de stockage éphémère alloués aux	Gigaoctets (Go)	JobId	ApplicationId , WorkerType et CapacityA

Métrique	Description	Unité	Dimension principale	Dimension secondaire
	travailleurs dans le cadre d'une exécution de tâche.			Allocation Type
WorkerEphemeralStorageUsed	Nombre d'octets de stockage éphémère utilisés par les travailleurs dans le cadre d'une exécution de tâche.	Gigaoctets (Go)	JobId	ApplicationId , WorkerType et CapacityAllocation Type
WorkerStorageReadBytes	Nombre d'octets lus depuis le stockage par les travailleurs lors d'une exécution de tâche.	Octets	JobId	ApplicationId , WorkerType et CapacityAllocation Type
WorkerStorageWriteBytes	Nombre d'octets écrits dans le stockage par les travailleurs lors d'une exécution de tâche.	Octets	JobId	ApplicationId , WorkerType et CapacityAllocation Type

Les étapes ci-dessous décrivent comment afficher les différents types de métriques.



## Console

Pour accéder à l'interface utilisateur de votre application à l'aide de la console

1. Accédez à votre application EMR Serverless sur le EMR Studio en suivant les instructions de la section [Mise en route depuis la console](#).
2. Pour consulter l'application UIs et les journaux spécifiques au moteur d'une tâche en cours d'exécution :
  - a. Choisissez un poste doté d'un RUNNING statut.
  - b. Sélectionnez le poste sur la page Détails de la candidature ou accédez à la page des détails du poste correspondant à votre poste.
  - c. Dans le menu déroulant Display UI, choisissez Spark UI ou Hive Tez UI pour accéder à l'interface utilisateur de l'application correspondant à votre type de tâche.
  - d. Pour consulter les journaux du moteur Spark, accédez à l'onglet Executors de l'interface utilisateur Spark, puis cliquez sur le lien Logs pour le pilote. Pour consulter les journaux du moteur Hive, cliquez sur le lien Logs correspondant au moteur approprié DAG dans l'interface utilisateur Hive Tez.
3. Pour consulter l'application UIs et les journaux spécifiques au moteur pour une tâche terminée :
  - a. Choisissez un poste doté d'un SUCCESS statut.
  - b. Sélectionnez le poste sur la page des détails de candidature de votre candidature ou accédez à la page des détails du poste.
  - c. Dans le menu déroulant de l'interface utilisateur d'affichage, choisissez Spark History Server ou Persistent Hive Tez UI pour accéder à l'interface utilisateur de l'application correspondant à votre type de tâche.
  - d. Pour consulter les journaux du moteur Spark, accédez à l'onglet Executors de l'interface utilisateur Spark, puis cliquez sur le lien Logs pour le pilote. Pour consulter les journaux du moteur Hive, cliquez sur le lien Logs correspondant au moteur approprié DAG dans l'interface utilisateur Hive Tez.

## AWS CLI

Pour accéder à l'interface utilisateur de votre application à l'aide du AWS CLI

- Pour générer un fichier URL que vous pouvez utiliser pour accéder à l'interface utilisateur de votre application pour les tâches en cours et terminées, appelez le `GetDashboardForJobRunAPI`.

```
aws emr-serverless get-dashboard-for-job-run /  
--application-id <application-id> /  
--job-run-id <job-id>
```

Le URL que vous générez est valide pendant une heure.

## Surveillez les métriques de Spark avec Amazon Managed Service pour Prometheus

Avec les EMR versions 7.1.0 et supérieures d'Amazon, vous pouvez intégrer EMR Serverless à Amazon Managed Service for Prometheus afin de collecter des métriques Apache Spark pour les tâches et applications sans serveur. EMR Cette intégration est disponible lorsque vous soumettez une offre d'emploi ou que vous créez une candidature à l'aide de AWS console, le EMR Serverless API ou AWS CLI.

### Prérequis

Avant de pouvoir transmettre vos métriques Spark à Amazon Managed Service for Prometheus, vous devez remplir les conditions préalables suivantes.

- [Créez un espace de travail Amazon Managed Service pour Prometheus](#). Cet espace de travail sert de point de terminaison pour l'ingestion. Prenez note de l'URL d'affichage pour Endpoint - écriture à distance URL. Vous devez spécifier le URL moment où vous créez votre application EMR Serverless.
- Pour autoriser l'accès à vos tâches à Amazon Managed Service for Prometheus à des fins de surveillance, ajoutez la politique suivante à votre rôle d'exécution des tâches.

```
{  
  "Sid": "AccessToPrometheus",  
  "Effect": "Allow",  
  "Action": ["aps:RemoteWrite"],
```

```
"Resource": "arn:aws:aps:<AWS_REGION>:<AWS_ACCOUNT_ID>:workspace/<WORKSPACE_ID>"
}
```

## Configuration

Pour utiliser le plugin AWS console pour créer une application intégrée à Amazon Managed Service pour Prometheus

1. Consultez [Getting started with Amazon EMR Serverless](#) pour créer une application.
2. Lorsque vous créez une application, choisissez Utiliser les paramètres personnalisés, puis configurez votre application en spécifiant les informations dans les champs que vous souhaitez configurer.
3. Sous Journaux et métriques des applications, choisissez Deliver les métriques du moteur à Amazon Managed Service for Prometheus, puis spécifiez votre écriture à distance. URL
4. Spécifiez les autres paramètres de configuration souhaités, puis choisissez Create and start application.

Utilisez le AWS CLI ou EMR sans serveur API

Vous pouvez également utiliser le AWS CLI ou EMR Serverless API pour intégrer votre application EMR Serverless à Amazon Managed Service for Prometheus lorsque vous exécutez les commandes ou les commandes. `create-application start-job-run`

`create-application`

```
aws emr-serverless create-application \  
--release-label emr-7.1.0 \  
--type "SPARK" \  
--monitoring-configuration '{  
    "prometheusMonitoringConfiguration": {  
        "remoteWriteUrl": "https://aps-workspaces.<AWS_REGION>.amazonaws.com/  
workspaces/<WORKSPACE_ID>/api/v1/remote_write"  
    }  
}'
```

`start-job-run`

```
aws emr-serverless start-job-run \  

```

```

--application-id <APPLICATION_ID> \
--execution-role-arn <JOB_EXECUTION_ROLE> \
--job-driver '{
  "sparkSubmit": {
    "entryPoint": "local:///usr/lib/spark/examples/src/main/python/pi.py",
    "entryPointArguments": ["10000"],
    "sparkSubmitParameters": "--conf spark.dynamicAllocation.maxExecutors=10"
  }
}' \
--configuration-overrides '{
  "monitoringConfiguration": {
    "prometheusMonitoringConfiguration": {
      "remoteWriteUrl": "https://aps-workspaces.<AWS_REGION>.amazonaws.com/
workspaces/<WORKSPACE_ID>/api/v1/remote_write"
    }
  }
}'

```

L'inclusion `prometheusMonitoringConfiguration` dans votre commande indique que EMR Serverless doit exécuter la tâche Spark avec un agent qui collecte les métriques Spark et les écrit sur votre `remoteWriteUrl` point de terminaison pour Amazon Managed Service for Prometheus. Vous pouvez ensuite utiliser les métriques Spark dans Amazon Managed Service for Prometheus pour la visualisation, les alertes et les analyses.

## Propriétés de configuration avancées

EMRServerless utilise un composant de Spark nommé `PrometheusServlet` pour collecter les métriques Spark et traduire les données de performance en données compatibles avec Amazon Managed Service for Prometheus. Par défaut, EMR Serverless définit les valeurs par défaut dans Spark et analyse les métriques du pilote et de l'exécuteur lorsque vous soumettez une tâche à l'aide de `PrometheusMonitoringConfiguration`.

Le tableau suivant décrit toutes les propriétés que vous pouvez configurer lorsque vous soumettez une tâche Spark qui envoie des métriques à Amazon Managed Service for Prometheus.

Propriété Spark	Valeur par défaut	Description
<code>spark.metrics.conf</code> <code>.*.sink.prometheus</code> <code>Servlet.class</code>	<code>org.apache.spark.metrics.sink.</code> <code>PrometheusServlet</code>	Classe utilisée par Spark pour envoyer des métriques à Amazon Managed Service

Propriété Spark	Valeur par défaut	Description
		for Prometheus. Pour modifier le comportement par défaut, spécifiez votre propre classe personnalisée.
<code>spark.metrics.conf.*.source.jvm.class</code>	<code>org.apache.spark.metrics.source.JvmSource</code>	La classe utilisée par Spark pour collecter et envoyer des métriques cruciales à partir de la machine virtuelle Java sous-jacente. Pour arrêter de collecter JVM des métriques, désactivez cette propriété en lui attribuant une chaîne vide, telle que "". Pour modifier le comportement par défaut, spécifiez votre propre classe personnalisée.
<code>spark.metrics.conf.driver.sink.prometheusServlet.path</code>	<code>/métriques/prométhée</code>	Distinction URL utilisée par Amazon Managed Service for Prometheus pour collecter des statistiques auprès du conducteur. Pour modifier le comportement par défaut, spécifiez votre propre chemin. Pour arrêter de collecter les métriques relatives aux conducteurs, désactivez cette propriété en lui attribuant une chaîne vide, telle que "".

Propriété Spark	Valeur par défaut	Description
<code>spark.metrics.conf.executor.sink.prometheusServlet.path</code>	<code>/metrics/executor/prometheus</code>	Distinction URL utilisée par Amazon Managed Service for Prometheus pour collecter des métriques auprès de l'exécuteur. Pour modifier le comportement par défaut, spécifiez votre propre chemin. Pour arrêter de collecter les métriques de l'exécuteur, désactivez cette propriété en lui attribuant une chaîne vide, telle que "".

Pour plus d'informations sur les métriques Spark, consultez [Métriques Apache Spark](#).

## Considérations et restrictions

Lorsque vous utilisez Amazon Managed Service for Prometheus pour collecter des métriques EMR depuis Serverless, tenez compte des considérations et limites suivantes.

- Support pour l'utilisation d'Amazon Managed Service for Prometheus EMR avec Serverless uniquement dans le [Régions AWS où Amazon Managed Service for Prometheus est généralement disponible](#).
- L'exécution de l'agent pour collecter les métriques Spark sur Amazon Managed Service for Prometheus nécessite davantage de ressources de la part des employés. Si vous choisissez une taille de travail plus petite, par exemple un CPU travailleur en V, la durée d'exécution de votre tâche peut augmenter.
- Support pour l'utilisation d'Amazon Managed Service for Prometheus EMR avec Serverless uniquement pour les versions 7.1.0 et supérieures d'EMRAmazon.

## EMR Mesures d'utilisation sans serveur

Vous pouvez utiliser les statistiques CloudWatch d'utilisation d'Amazon pour avoir une visibilité sur les ressources utilisées par votre compte. Utilisez ces indicateurs pour visualiser l'utilisation de vos services sur CloudWatch des graphiques et des tableaux de bord.

EMR Les métriques d'utilisation sans serveur correspondent aux Service Quotas. Vous pouvez configurer des alarmes qui vous alertent lorsque votre utilisation approche d'un quota de service. Pour plus d'informations, consultez les sections [Service Quotas et Amazon CloudWatch alarmes](#) dans le Guide de l'utilisateur de Service Quotas.

Pour plus d'informations sur les quotas EMR de service sans serveur, consultez [Points de terminaison et quotas pour EMR Serverless](#).

### Mesures d'utilisation des quotas de service pour EMR Serverless

EMR Serverless publie les mesures d'utilisation des quotas de service suivantes dans l'espace de AWS/Usage noms.

Métrique	Description
ResourceCount	Le nombre total de ressources spécifiées exécutées sur votre compte. La ressource est définie par les <a href="#">dimensions</a> associées à la métrique.

### Dimensions des métriques d'utilisation des quotas de service EMR sans serveur

Vous pouvez utiliser les dimensions suivantes pour affiner les métriques d'utilisation publiées par EMR Serverless.

Dimension	Valeur	Description
Service	EMRSans serveur	Le nom du Service AWS qui contient la ressource.
Type	Ressource	Type d'entité signalée par EMR Serverless.

Dimension	Valeur	Description
Resource	v CPU	Type de ressource que EMR Serverless suit.
Class	Aucun	Classe de ressource suivie par EMR Serverless.

## Automatiser le mode EMR Serverless avec Amazon EventBridge

Vous pouvez utiliser ... Amazon EventBridge pour automatiser votre Services AWS et répondez automatiquement aux événements du système, tels que les problèmes de disponibilité des applications ou les modifications des ressources. EventBridge fournit un flux d'événements système en temps quasi réel décrivant les modifications apportées à votre AWS ressources. Vous pouvez écrire des règles simples pour indiquer quels événements vous intéressent et les actions automatisées à effectuer quand un événement correspond à une règle. Avec EventBridge, vous pouvez automatiquement :

- Invoquez un AWS Lambda fonction
- Transmettre un événement à Amazon Kinesis Data Streams
- Activez un AWS Step Functions machine d'état
- Notifier un SNS sujet Amazon ou une SQS file d'attente Amazon

Par exemple, lorsque vous utilisez EventBridge EMR Serverless, vous pouvez activer un AWS Lambda fonctionne en cas de réussite ETL d'une tâche ou avertit un SNS sujet Amazon en cas d'échec ETL d'une tâche.

EMRServerless émet trois types d'événements :

- Événements de modification de l'état d'une application : événements qui déclenchent chaque changement d'état d'une application. Pour plus d'informations sur les états des applications, consultez [États de l'application](#).
- Événements de changement d'état d'exécution d'une tâche : événements qui émettent chaque changement d'état d'une exécution de tâche. Pour plus d'informations sur, voir [États d'exécution de la tâche](#).



- Événements de nouvelle tentative d'exécution de tâches : événements qui émettent chaque nouvelle tentative d'exécution d'une tâche à partir des versions 7.1.0 et supérieures d'Amazon EMR Serverless.

## Exemples d'EMR Événements sans serveur EventBridge

Les événements signalés par EMR Serverless ont la valeur `aws.emr-serverless` assignée à `source`, comme dans les exemples suivants.

### Événement de changement d'état de l'application

L'exemple d'événement suivant montre une application dans son `CREATING` état.

```
{
  "version": "0",
  "id": "9fd3cf79-1ff1-b633-4dd9-34508dc1e660",
  "detail-type": "EMR Serverless Application State Change",
  "source": "aws.emr-serverless",
  "account": "123456789012",
  "time": "2022-05-31T21:16:31Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
    "applicationId": "00f1cb5c6anuij25",
    "applicationName": "3965ad00-8fba-4932-a6c8-ded32786fd42",
    "arn": "arn:aws:emr-serverless:us-east-1:111122223333:/
applications/00f1cb5c6anuij25",
    "releaseLabel": "emr-6.6.0",
    "state": "CREATING",
    "type": "HIVE",
    "createdAt": "2022-05-31T21:16:31.547953Z",
    "updatedAt": "2022-05-31T21:16:31.547970Z",
    "autoStopConfig": {
      "enabled": true,
      "idleTimeout": 15
    },
    "autoStartConfig": {
      "enabled": true
    }
  }
}
```

## Événement de changement d'état de Job Run

L'exemple d'événement suivant montre une exécution de travail qui passe de l'`SCHEDULED` état à l'`RUNNING` état.

```
{
  "version": "0",
  "id": "00df3ec6-5da1-36e6-ab71-20f0de68f8a0",
  "detail-type": "EMR Serverless Job Run State Change",
  "source": "aws.emr-serverless",
  "account": "123456789012",
  "time": "2022-05-31T21:07:42Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
    "jobRunId": "00f1cbn5g4bb0c01",
    "applicationId": "00f1982r1uukb925",
    "arn": "arn:aws:emr-serverless:us-east-1:123456789012:/
applications/00f1982r1uukb925/jobruns/00f1cbn5g4bb0c01",
    "releaseLabel": "emr-6.6.0",
    "state": "RUNNING",
    "previousState": "SCHEDULED",
    "createdBy": "arn:aws:sts::123456789012:assumed-role/
TestRole-402dcef3ad14993c15d28263f64381e4cda34775/6622b6233b6d42f59c25dd2637346242",
    "updatedAt": "2022-05-31T21:07:42.299487Z",
    "createdAt": "2022-05-31T21:07:25.325900Z"
  }
}
```

## Événement Job Run Retry

Voici un exemple d'événement de nouvelle tentative d'exécution d'une tâche.

```
{
  "version": "0",
  "id": "00df3ec6-5da1-36e6-ab71-20f0de68f8a0",
  "detail-type": "EMR Serverless Job Run Retry",
  "source": "aws.emr-serverless",
  "account": "123456789012",
  "time": "2022-05-31T21:07:42Z",
  "region": "us-east-1",
  "resources": [],
  "detail": {
```

```
    "jobRunId": "00f1cbn5g4bb0c01",
    "applicationId": "00f1982r1uukb925",
    "arn": "arn:aws:emr-serverless:us-east-1:123456789012:/
applications/00f1982r1uukb925/jobruns/00f1cbn5g4bb0c01",
    "releaseLabel": "emr-6.6.0",
    "createdBy": "arn:aws:sts::123456789012:assumed-role/
TestRole-402dcef3ad14993c15d28263f64381e4cda34775/6622b6233b6d42f59c25dd2637346242",
    "updatedAt": "2022-05-31T21:07:42.299487Z",
    "createdAt": "2022-05-31T21:07:25.325900Z",
    //Attempt Details
    "previousAttempt": 1,
    "previousAttemptState": "FAILED",
    "previousAttemptCreatedAt": "2022-05-31T21:07:25.325900Z",
    "previousAttemptEndedAt": "2022-05-31T21:07:30.325900Z",
    "newAttempt": 2,
    "newAttemptCreatedAt": "2022-05-31T21:07:30.325900Z"
  }
}
```

# Balisage des ressources

Vous pouvez attribuer vos propres métadonnées à chaque ressource à l'aide de balises pour vous aider à gérer vos ressources EMR sans serveur. Cette section fournit un aperçu des fonctions des balises et explique comment créer des balises.

## Rubriques

- [Qu'est-ce qu'un tag ?](#)
- [Balisage de vos ressources](#)
- [Limites relatives au balisage](#)
- [Utilisation des balises à l'aide du AWS CLI et Amazon EMR Serverless API](#)

## Qu'est-ce qu'un tag ?

Un tag est un label que vous attribuez à un AWS ressource. Chaque étiquette est constituée d'une clé et d'une valeur, que vous définissez. Les tags vous permettent de classer vos AWS ressources par attributs tels que le but, le propriétaire et l'environnement. Lorsque vous avez de nombreuses ressources de même type, vous pouvez rapidement identifier une ressource spécifique en fonction des balises que vous lui avez attribuées. Par exemple, vous pouvez définir un ensemble de balises pour vos applications Amazon EMR Serverless afin de suivre le propriétaire et le niveau de pile de chaque application. Nous vous recommandons de concevoir un ensemble cohérent de clés de balise pour chaque type de ressource.

Les balises ne sont pas automatiquement affectées à vos ressources. Après avoir ajouté une balise à une ressource, vous pouvez modifier la valeur d'une balise ou supprimer la balise de la ressource à tout moment. Les balises n'ont aucune signification sémantique pour Amazon EMR Serverless et sont interprétées strictement comme des chaînes de caractères. Si vous ajoutez une balise ayant la même clé qu'une balise existante sur cette ressource, la nouvelle valeur remplace l'ancienne valeur.

Si vous utilisez IAM, vous pouvez contrôler les utilisateurs de votre AWS le compte est autorisé à gérer les tags. Pour des exemples de politique de contrôle d'accès basée sur les balises, consultez [Politiques de contrôle d'accès basées sur les balises](#).

## Balisage de vos ressources

Vous pouvez étiqueter des applications et des cycles de travail nouveaux ou existants. Si vous utilisez Amazon EMR ServerlessAPI, AWS CLI, ou un AWS SDK, vous pouvez appliquer des balises aux nouvelles ressources à l'aide du `tags` paramètre correspondant à l'API action correspondante. Vous pouvez appliquer des balises aux ressources existantes à l'aide de `TagResource` API cette action.

Vous pouvez utiliser certaines actions de création de ressources pour spécifier des balises pour une ressource lors de la création de cette dernière. Dans ce cas, si les balises ne peuvent pas être appliquées pendant la création de la ressource, cette dernière n'est pas créée. Ce mécanisme garantit que les ressources que vous vouliez étiqueter lors de la création sont créées avec des identifications spécifiées ou ne sont pas créées du tout. Si vous balisez des ressources au moment de leur création, il n'est pas nécessaire d'exécuter des scripts de balisage personnalisés après avoir créé une ressource.

Le tableau suivant décrit les ressources Amazon EMR Serverless qui peuvent être balisées.

Ressource	Prend en charge les étiquettes	Prend en charge la propagation des étiquettes	Supporte le balisage lors de la création (Amazon EMR ServerlessAPI, AWS CLI, et AWS SDK)	API pour la création (des tags peuvent être ajoutés lors de la création)
Application	Oui	Non Les balises associées à une application ne se propagent pas aux exécutions de tâches soumises à cette application.	Oui	CreateApplication
Exécution de tâche	Oui	Non	Oui	StartJobRun

## Limites relatives au balisage

Les restrictions de base suivantes s'appliquent aux balises :

- Chaque ressource peut avoir un maximum de 50 balises créées par l'utilisateur.
- Pour chaque ressource, chaque clé d'identification doit être unique, et chaque clé d'identification peut avoir une seule valeur.
- La longueur maximale de la clé est de 128 caractères Unicode en UTF -8.
- La longueur maximale de la valeur est de 256 caractères Unicode en UTF -8.
- Les caractères autorisés sont les lettres, les chiffres, les espaces représentables en UTF -8 et les caractères suivants : `_ . :/= + - @`.
- Une clé de balise ne peut pas être une chaîne vide. Une valeur de balise peut être une chaîne vide, mais pas null.
- Les clés et valeurs de balise sont sensibles à la casse.
- N'utilisez pas `AWS` : pas de combinaison majuscules ou minuscules, telle qu'un préfixe pour les clés ou les valeurs. Ils sont réservés uniquement aux AWS utiliser.

## Utilisation des balises à l'aide du AWS CLI et Amazon EMR Serverless API

Utilisez ce qui suit AWS CLI des commandes ou API des opérations Amazon EMR Serverless pour ajouter, mettre à jour, répertorier et supprimer les balises de vos ressources.

Ressource	Prend en charge les étiquettes	Prend en charge la propagation des étiquettes
Ajouter ou remplacer une ou plusieurs balises	<code>tag-resource</code>	<code>TagResource</code>
Répertorie les balises d'une ressource.	<code>list-tags-for-resource</code>	<code>ListTagsForResource</code>
Supprimer une ou plusieurs balises.	<code>untag-resource</code>	<code>UntagResource</code>

Les exemples suivants montrent comment baliser ou débaliser des ressources à l'aide du AWS CLI.

### Marquer une application existante

La commande suivante balise une application existante.

```
aws emr-serverless tag-resource --resource-arn resource_ARN --tags team=devs
```

### Annuler le balisage d'une application existante

La commande suivante supprime une balise d'une application existante.

```
aws emr-serverless untag-resource --resource-arn resource_ARN --tag-keys tag_key
```

### Répertorier les balises d'une ressource

La commande suivante permet de répertorier l'ensemble des étiquettes associées à une ressource existante.

```
aws emr-serverless list-tags-for-resource --resource-arn resource_ARN
```

# Tutoriels pour EMR Serverless

Cette section décrit les cas d'utilisation courants lorsque vous travaillez avec des applications EMR sans serveur.

## Rubriques

- [Utilisation de Java 17 avec Amazon EMR Serverless](#)
- [Utilisation d'Apache Hudi avec Serverless EMR](#)
- [Utilisation d'Apache Iceberg avec Serverless EMR](#)
- [Utilisation de bibliothèques Python avec EMR Serverless](#)
- [Utilisation de différentes versions de Python avec EMR Serverless](#)
- [Utilisation de Delta Lake OSS avec EMR Serverless](#)
- [Soumission de tâches EMR sans serveur depuis Airflow](#)
- [Utilisation des fonctions définies par l'utilisateur de Hive avec Serverless EMR](#)
- [Utilisation d'images personnalisées avec EMR Serverless](#)
- [Utilisation de l'intégration Amazon Redshift pour Apache Spark sur Amazon Serverless EMR](#)
- [Connexion à DynamoDB avec Amazon Serverless EMR](#)

## Utilisation de Java 17 avec Amazon EMR Serverless

Avec les EMR versions 6.11.0 et supérieures d'Amazon, vous pouvez configurer des tâches Spark EMR sans serveur pour utiliser le runtime Java 17 pour la machine virtuelle Java (). JVM Utilisez l'une des méthodes suivantes pour configurer Spark avec Java 17.

### **JAVA\_HOME**

Pour remplacer le JVM paramètre de EMR Serverless 6.11.0 et versions ultérieures, vous pouvez le fournir à ses `spark.emr-serverless.driverEnv` classifications et à celles de l'`JAVA_HOME` environnement. `spark.executorEnv`

x86\_64

Définissez les propriétés requises pour spécifier Java 17 comme `JAVA_HOME` configuration pour le pilote et les exécuteurs Spark :



```
--conf spark.emr-serverless.driverEnv.JAVA_HOME=/usr/lib/jvm/java-17-amazon-
corretto.x86_64/
--conf spark.executorEnv.JAVA_HOME=/usr/lib/jvm/java-17-amazon-corretto.x86_64/
```

## arm\_64

Définissez les propriétés requises pour spécifier Java 17 comme JAVA\_HOME configuration pour le pilote et les exécuteurs Spark :

```
--conf spark.emr-serverless.driverEnv.JAVA_HOME=/usr/lib/jvm/java-17-amazon-
corretto.aarch64/
--conf spark.executorEnv.JAVA_HOME=/usr/lib/jvm/java-17-amazon-corretto.aarch64/
```

## spark-defaults

Vous pouvez également spécifier Java 17 dans la spark-defaults classification pour remplacer le JVM paramètre de EMR Serverless 6.11.0 et versions ultérieures.

### x86\_64

Spécifiez Java 17 dans la spark-defaults classification :

```
{
  "applicationConfiguration": [
    {
      "classification": "spark-defaults",
      "properties": {
        "spark.emr-serverless.driverEnv.JAVA_HOME" : "/usr/lib/jvm/java-17-
amazon-corretto.x86_64/",
        "spark.executorEnv.JAVA_HOME": "/usr/lib/jvm/java-17-amazon-
corretto.x86_64/"
      }
    }
  ]
}
```

### arm\_64

Spécifiez Java 17 dans la spark-defaults classification :

```
{
```

```

"applicationConfiguration": [
  {
    "classification": "spark-defaults",
    "properties": {
      "spark.emr-serverless.driverEnv.JAVA_HOME" : "/usr/lib/jvm/java-17-
amazon-corretto.aarch64/",
      "spark.executorEnv.JAVA_HOME": "/usr/lib/jvm/java-17-amazon-
corretto.aarch64/"
    }
  }
]
}

```

## Utilisation d'Apache Hudi avec Serverless EMR

Pour utiliser Apache Hudi avec des applications EMR sans serveur

1. Définissez les propriétés Spark requises lors de l'exécution de la tâche Spark correspondante.

```

spark.jars=/usr/lib/hudi/hudi-spark-bundle.jar
spark.serializer=org.apache.spark.serializer.KryoSerializer

```

2. Pour synchroniser une table Hudi avec le catalogue configuré, désignez soit le AWS Glue Data Catalog comme métastore ou configurez un métastore externe. EMRLe mode de synchronisation sans serveur est pris hms en charge pour les tables Hive pour les charges de travail Hudi. EMRServerless active cette propriété par défaut. Pour en savoir plus sur la configuration de votre métastore, consultez. [Configuration du métastore](#)

### Important

EMRServerless ne prend pas en charge HIVEQL les tables Hive et ne les utilise pas en JDBC tant qu'options de mode de synchronisation pour gérer les charges de travail Hudi. Pour en savoir plus, consultez la section [Modes de synchronisation](#).

Lorsque vous utilisez le AWS Glue Data Catalog en tant que métastore, vous pouvez spécifier les propriétés de configuration suivantes pour votre tâche Hudi.

```

--conf spark.jars=/usr/lib/hudi/hudi-spark-bundle.jar,

```

```
--conf spark.serializer=org.apache.spark.serializer.KryoSerializer,
--conf
spark.hadoop.hive.metastore.client.factory.class=com.amazonaws.glue.catalog.metastore.AWSG
```

Pour en savoir plus sur les versions d'Apache Hudi d'AmazonEMR, consultez l'historique des [versions de Hudi](#).

## Utilisation d'Apache Iceberg avec Serverless EMR

Pour utiliser Apache Iceberg avec des applications EMR sans serveur

1. Définissez les propriétés Spark requises lors de l'exécution de la tâche Spark correspondante.

```
spark.jars=/usr/share/aws/iceberg/lib/iceberg-spark3-runtime.jar
```

2. Désignez soit le AWS Glue Data Catalog comme métastore ou configurez un métastore externe. Pour en savoir plus sur la configuration de votre métastore, consultez [Configuration du métastore](#)

Configurez les propriétés du métastore que vous souhaitez utiliser pour Iceberg. Par exemple, si vous souhaitez utiliser AWS Glue Data Catalog, définissez les propriétés suivantes dans la configuration de l'application.

```
spark.sql.catalog.dev.warehouse=s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/
spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
spark.sql.catalog.dev=org.apache.iceberg.spark.SparkCatalog
spark.sql.catalog.dev.catalog-impl=org.apache.iceberg.aws.glue.GlueCatalog
spark.hadoop.hive.metastore.client.factory.class=com.amazonaws.glue.catalog.metastore.AWSG
```

Lorsque vous utilisez le AWS Glue Data Catalog En tant que métastore, vous pouvez spécifier les propriétés de configuration suivantes pour votre tâche Iceberg.

```
--conf spark.jars=/usr/share/aws/iceberg/lib/iceberg-spark3-runtime.jar,
--conf
spark.sql.extensions=org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions,
--conf spark.sql.catalog.dev=org.apache.iceberg.spark.SparkCatalog,
--conf spark.sql.catalog.dev.catalog-impl=org.apache.iceberg.aws.glue.GlueCatalog,
--conf spark.sql.catalog.dev.warehouse=s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/
```

```
--conf spark.hadoop.hive.metastore.client.factory.class=com.amazonaws.glue.catalog.metastore.AWSG
```

Pour en savoir plus sur les versions d'Apache Iceberg d'AmazonEMR, consultez l'historique des [versions d'Iceberg](#).

## Utilisation de bibliothèques Python avec EMR Serverless

Lorsque vous exécutez PySpark des tâches sur des applications Amazon EMR Serverless, vous pouvez empaqueter différentes bibliothèques Python sous forme de dépendances. Pour ce faire, vous pouvez utiliser les fonctionnalités natives de Python, créer un environnement virtuel ou configurer directement vos PySpark tâches pour utiliser les bibliothèques Python. Cette page couvre chaque approche.

### Utilisation des fonctionnalités natives de Python

Lorsque vous définissez la configuration suivante, vous pouvez l'utiliser PySpark pour télécharger des fichiers Python (.py), des packages Python compressés (.zip) et des fichiers Egg (.egg) vers les exécuteurs Spark.

```
--conf spark.submit.pyFiles=s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/<.py|.egg|.zip file>
```

Pour plus de détails sur l'utilisation des environnements virtuels Python pour les PySpark tâches, consultez la section [Utilisation des fonctionnalités PySpark natives](#).

### Création d'un environnement virtuel Python

Pour empaqueter plusieurs bibliothèques Python pour une PySpark tâche, vous pouvez créer des environnements virtuels Python isolés.

1. Pour créer l'environnement virtuel Python, utilisez les commandes suivantes. L'exemple illustré installe les packages `scipy` `matplotlib` dans un environnement virtuel et copie l'archive vers un emplacement Amazon S3.

#### Important

Vous devez exécuter les commandes suivantes dans un environnement Amazon Linux 2 similaire avec la même version de Python que celle que vous utilisez dans EMR

Serverless, c'est-à-dire Python 3.7.10 pour Amazon EMR version 6.6.0. Vous pouvez trouver un exemple de Dockerfile dans le référentiel [EMRServerless Samples](#). GitHub

```
# initialize a python virtual environment
python3 -m venv pyspark_venvsource
source pyspark_venvsource/bin/activate

# optionally, ensure pip is up-to-date
pip3 install --upgrade pip

# install the python packages
pip3 install scipy
pip3 install matplotlib

# package the virtual environment into an archive
pip3 install venv-pack
venv-pack -f -o pyspark_venv.tar.gz

# copy the archive to an S3 location
aws s3 cp pyspark_venv.tar.gz s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/

# optionally, remove the virtual environment directory
rm -fr pyspark_venvsource
```

2. Soumettez la tâche Spark avec vos propriétés définies pour utiliser l'environnement virtuel Python.

```
--conf spark.archives=s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/
pyspark_venv.tar.gz#environment
--conf spark.emr-serverless.driverEnv.PYSPARK_DRIVER_PYTHON=./environment/bin/
python
--conf spark.emr-serverless.driverEnv.PYSPARK_PYTHON=./environment/bin/python
--conf spark.executorEnv.PYSPARK_PYTHON=./environment/bin/python
```

Notez que si vous ne remplacez pas le binaire Python d'origine, la deuxième configuration de la séquence de paramètres précédente sera `--conf spark.executorEnv.PYSPARK_PYTHON=python` la suivante.

Pour en savoir plus sur l'utilisation des environnements virtuels Python pour les PySpark tâches, consultez la section [Utilisation de Virtualenv](#). Pour plus d'exemples sur la façon de soumettre des tâches Spark, consultez [Offres d'emploi Spark](#).

## Configuration des PySpark tâches pour utiliser les bibliothèques Python

Avec les EMR versions 6.12.0 et supérieures d'Amazon, vous pouvez configurer directement des PySpark tâches EMR sans serveur pour utiliser les bibliothèques Python de science des données les plus populaires, telles [que Pandas, et ce NumPy, PyArrow](#) sans aucune configuration supplémentaire.

Les exemples suivants montrent comment emballer chaque bibliothèque Python pour une PySpark tâche.

### NumPy

NumPy est une bibliothèque Python pour le calcul scientifique qui propose des tableaux multidimensionnels et des opérations pour les mathématiques, le tri, la simulation aléatoire et les statistiques de base. Pour l'utiliser NumPy, exécutez la commande suivante :

```
import numpy
```

### pandas

pandas est une bibliothèque Python construite sur NumPy. La bibliothèque Pandas fournit aux scientifiques des structures de [DataFrame](#) données et des outils d'analyse de données. Pour utiliser les pandas, exécutez la commande suivante :

```
import pandas
```

### PyArrow

PyArrow est une bibliothèque Python qui gère les données colonnaires en mémoire pour améliorer les performances au travail. PyArrow est basé sur la spécification de développement multilingue Apache Arrow, qui est un moyen standard de représenter et d'échanger des données dans un format en colonnes. Pour l'utiliser PyArrow, exécutez la commande suivante :

```
import pyarrow
```

# Utilisation de différentes versions de Python avec EMR Serverless

Outre le cas d'utilisation [Utilisation de bibliothèques Python avec EMR Serverless](#), vous pouvez également utiliser des environnements virtuels Python pour travailler avec des versions de Python différentes de celles incluses dans la EMR version Amazon pour votre application Amazon EMR Serverless. Pour ce faire, vous devez créer un environnement virtuel Python avec la version de Python que vous souhaitez utiliser.

Pour soumettre une tâche depuis un environnement virtuel Python

1. Créez votre environnement virtuel à l'aide des commandes de l'exemple suivant. Cet exemple installe Python 3.9.9 dans un package d'environnement virtuel et copie l'archive vers un emplacement Amazon S3.

## Important

Si vous utilisez les EMR versions 7.0.0 et supérieures d'Amazon, vous devez exécuter vos commandes dans un environnement Amazon Linux 2023 similaire à celui que vous utilisez pour vos applications EMR sans serveur.

Si vous utilisez la version 6.15.0 ou inférieure, vous devez exécuter les commandes suivantes dans un environnement Amazon Linux 2 similaire.

```
# install Python 3.9.9 and activate the venv
yum install -y gcc openssl-devel bzip2-devel libffi-devel tar gzip wget make
wget https://www.python.org/ftp/python/3.9.9/Python-3.9.9.tgz && \
tar xzf Python-3.9.9.tgz && cd Python-3.9.9 && \
./configure --enable-optimizations && \
make altinstall

# create python venv with Python 3.9.9
python3.9 -m venv pyspark_venv_python_3.9.9 --copies
source pyspark_venv_python_3.9.9/bin/activate

# copy system python3 libraries to venv
cp -r /usr/local/lib/python3.9/* ./pyspark_venv_python_3.9.9/lib/python3.9/

# package venv to archive.
# Note that you have to supply --python-prefix option
# to make sure python starts with the path where your
```

```
# copied libraries are present.
# Copying the python binary to the "environment" directory.
pip3 install venv-pack
venv-pack -f -o pyspark_venv_python_3.9.9.tar.gz --python-prefix /home/hadoop/
environment

# stage the archive in S3
aws s3 cp pyspark_venv_python_3.9.9.tar.gz s3://<path>

# optionally, remove the virtual environment directory
rm -fr pyspark_venv_python_3.9.9
```

## 2. Définissez vos propriétés pour utiliser l'environnement virtuel Python et soumettez le job Spark.

```
# note that the archive suffix "environment" is the same as the directory where you
copied the Python binary.
--conf spark.archives=s3://DOC-EXAMPLE-BUCKET/EXAMPLE-PREFIX/
pyspark_venv_python_3.9.9.tar.gz#environment
--conf spark.emr-serverless.driverEnv.PYSPARK_DRIVER_PYTHON=./environment/bin/
python
--conf spark.emr-serverless.driverEnv.PYSPARK_PYTHON=./environment/bin/python
--conf spark.executorEnv.PYSPARK_PYTHON=./environment/bin/python
```

Pour en savoir plus sur l'utilisation des environnements virtuels Python pour les PySpark tâches, consultez la section [Utilisation de Virtualenv](#). Pour plus d'exemples sur la façon de soumettre des tâches Spark, consultez [Offres d'emploi Spark](#).

## Utilisation de Delta Lake OSS avec EMR Serverless

### Amazon EMR versions 6.9.0 et supérieures

#### Note

Amazon EMR 7.0.0 et versions ultérieures utilisent Delta Lake 3.0.0, qui renomme le `delta-core.jar` fichier en `delta-spark.jar`. Si vous utilisez Amazon EMR 7.0.0 ou une version ultérieure, assurez-vous de le spécifier `delta-spark.jar` dans vos configurations.

Amazon EMR 6.9.0 et versions ultérieures incluent Delta Lake. Vous n'avez donc plus à emballer Delta Lake vous-même ni à fournir le `--packages` drapeau avec vos tâches EMR sans serveur.



1. Lorsque vous soumettez des tâches EMR sans serveur, assurez-vous que vous disposez des propriétés de configuration suivantes et incluez les paramètres suivants dans le `sparkSubmitParameters` champ.

```
--conf spark.jars=/usr/share/aws/delta/lib/delta-core.jar,/usr/share/aws/delta/lib/delta-storage.jar
--conf spark.sql.extensions=io.delta.sql.DeltaSparkSessionExtension
--conf
spark.sql.catalog.spark_catalog=org.apache.spark.sql.delta.catalog.DeltaCatalog
```

2. Créez un local `delta_sample.py` pour tester la création et la lecture d'une table Delta.

```
# delta_sample.py
from pyspark.sql import SparkSession

import uuid

url = "s3://DOC-EXAMPLE-BUCKET/delta-lake/output/%s/" % str(uuid.uuid4())
spark = SparkSession.builder.appName("DeltaSample").getOrCreate()

## creates a Delta table and outputs to target S3 bucket
spark.range(5).write.format("delta").save(url)

## reads a Delta table and outputs to target S3 bucket
spark.read.format("delta").load(url).show
```

3. Utilisation de AWS CLI, chargez le `delta_sample.py` fichier dans votre compartiment Amazon S3. Utilisez ensuite la `start-job-run` commande pour soumettre une tâche à une application EMR sans serveur existante.

```
aws s3 cp delta_sample.py s3://DOC-EXAMPLE-BUCKET/code/

aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --name emr-delta \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/code/delta_sample.py",
      "sparkSubmitParameters": "--conf spark.jars=/usr/share/
aws/delta/lib/delta-core.jar,/usr/share/aws/delta/lib/delta-storage.jar --
```

```
conf spark.sql.extensions=io.delta.sql.DeltaSparkSessionExtension --conf
  spark.sql.catalog.spark_catalog=org.apache.spark.sql.delta.catalog.DeltaCatalog"
  }
}'
```

Pour utiliser les bibliothèques Python avec Delta Lake, vous pouvez ajouter la `delta-core` bibliothèque en [l'empaquetant sous forme de dépendance](#) ou [en l'utilisant comme image personnalisée](#).

Vous pouvez également utiliser le `SparkContext.addPyFile` pour ajouter les bibliothèques Python à partir du `delta-core` JAR fichier :

```
import glob
from pyspark.sql import SparkSession

spark = SparkSession.builder.getOrCreate()
spark.sparkContext.addPyFile(glob.glob("/usr/share/aws/delta/lib/delta-core_*.jar")[0])
```

## Amazon EMR versions 6.8.0 et antérieures

Si vous utilisez Amazon EMR 6.8.0 ou une version antérieure, suivez ces étapes pour utiliser Delta Lake OSS avec vos applications EMR sans serveur.

1. Pour créer une version open source de [Delta Lake](#) compatible avec la version de Spark sur votre application Amazon EMR Serverless, accédez au [Delta GitHub](#) et suivez les instructions.
2. Téléchargez les bibliothèques Delta Lake dans un compartiment Amazon S3 de votre Compte AWS.
3. Lorsque vous soumettez des tâches EMR sans serveur dans la configuration de l'application, incluez les JAR fichiers Delta Lake qui se trouvent désormais dans votre compartiment.

```
--conf spark.jars=s3://DOC-EXAMPLE-BUCKET/jars/delta-core_2.12-1.1.0.jar
```

4. Pour vous assurer que vous pouvez lire et écrire à partir d'une table Delta, exécutez un exemple de PySpark test.

```
from pyspark import SparkConf, SparkContext
from pyspark.sql import HiveContext, SparkSession

import uuid
```

```
conf = SparkConf()
sc = SparkContext(conf=conf)
sqlContext = HiveContext(sc)

url = "s3://DOC-EXAMPLE-BUCKET/delta-lake/output/1.0.1/%s/" % str(uuid.uuid4())

## creates a Delta table and outputs to target S3 bucket
session.range(5).write.format("delta").save(url)

## reads a Delta table and outputs to target S3 bucket
session.read.format("delta").load(url).show
```

## Soumission de tâches EMR sans serveur depuis Airflow

Le fournisseur Amazon d'Apache Airflow fournit des opérateurs EMR sans serveur. Pour plus d'informations sur les opérateurs, consultez [Amazon EMR Serverless Operators](#) dans la documentation d'Apache Airflow.

Vous pouvez l'utiliser `EmrServerlessCreateApplicationOperator` pour créer une application Spark ou Hive. Vous pouvez également l'utiliser `EmrServerlessStartJobOperator` pour démarrer une ou plusieurs tâches avec votre nouvelle application.

Pour utiliser l'opérateur avec Amazon Managed Workflows for Apache Airflow (MWAA) avec Airflow 2.2.2, ajoutez la ligne suivante à votre `requirements.txt` fichier et mettez à jour votre MWAA environnement pour utiliser le nouveau fichier.

```
apache-airflow-providers-amazon==6.0.0
boto3>=1.23.9
```

Notez que le support EMR sans serveur a été ajouté à la version 5.0.0 du fournisseur Amazon. La version 6.0.0 est la dernière version compatible avec Airflow 2.2.2. Vous pouvez utiliser les versions ultérieures avec Airflow 2.4.3 activé. MWAA

L'exemple abrégé suivant montre comment créer une application, exécuter plusieurs tâches Spark, puis arrêter l'application. Un exemple complet est disponible dans le GitHub référentiel [EMRServerless Samples](#). Pour plus de détails sur `sparkSubmit` la configuration, consultez [Offres d'emploi Spark](#).

```
from datetime import datetime
```

```

from airflow import DAG
from airflow.providers.amazon.aws.operators.emr import (
    EmrServerlessCreateApplicationOperator,
    EmrServerlessStartJobOperator,
    EmrServerlessDeleteApplicationOperator,
)

# Replace these with your correct values
JOB_ROLE_ARN = "arn:aws:iam::account-id:role/emr_serverless_default_role"
S3_LOGS_BUCKET = "DOC-EXAMPLE-BUCKET"

DEFAULT_MONITORING_CONFIG = {
    "monitoringConfiguration": {
        "s3MonitoringConfiguration": {"logUri": f"s3://DOC-EXAMPLE-BUCKET/logs/"}
    },
}

with DAG(
    dag_id="example_endtoend_emr_serverless_job",
    schedule_interval=None,
    start_date=datetime(2021, 1, 1),
    tags=["example"],
    catchup=False,
) as dag:
    create_app = EmrServerlessCreateApplicationOperator(
        task_id="create_spark_app",
        job_type="SPARK",
        release_label="emr-6.7.0",
        config={"name": "airflow-test"},
    )

    application_id = create_app.output

    job1 = EmrServerlessStartJobOperator(
        task_id="start_job_1",
        application_id=application_id,
        execution_role_arn=JOB_ROLE_ARN,
        job_driver={
            "sparkSubmit": {
                "entryPoint": "local:///usr/lib/spark/examples/src/main/python/
pi_fail.py",
            }
        },
    ),

```

```
        configuration_overrides=DEFAULT_MONITORING_CONFIG,
    )

    job2 = EmrServerlessStartJobOperator(
        task_id="start_job_2",
        application_id=application_id,
        execution_role_arn=JOB_ROLE_ARN,
        job_driver={
            "sparkSubmit": {
                "entryPoint": "local:///usr/lib/spark/examples/src/main/python/pi.py",
                "entryPointArguments": ["1000"]
            }
        },
        configuration_overrides=DEFAULT_MONITORING_CONFIG,
    )

    delete_app = EmrServerlessDeleteApplicationOperator(
        task_id="delete_app",
        application_id=application_id,
        trigger_rule="all_done",
    )

    (create_app >> [job1, job2] >> delete_app)
```

## Utilisation des fonctions définies par l'utilisateur de Hive avec Serverless EMR

Les fonctions définies par l'utilisateur Hive (UDFs) vous permettent de créer des fonctions personnalisées pour traiter des enregistrements ou des groupes d'enregistrements. Dans ce didacticiel, vous allez utiliser un exemple UDF d'application Amazon EMR Serverless préexistante pour exécuter une tâche qui génère un résultat de requête. Pour savoir comment configurer une application, consultez [Commencer à utiliser Amazon EMR Serverless](#).

Pour utiliser un UDF avec EMR Serverless

1. Accédez au [GitHub](#) pour obtenir un exemple UDF. Clonez le dépôt et passez à la branche git que vous souhaitez utiliser. Mettez à jour le `maven-compiler-plugin` dans le `pom.xml` fichier du référentiel pour avoir une source. Mettez également à jour la configuration de la version Java cible vers 1.8. Exécutez `mvn package -DskipTests` pour créer le JAR fichier contenant votre exempleUDFs.

- Après avoir créé le JAR fichier, chargez-le dans votre compartiment S3 à l'aide de la commande suivante.

```
aws s3 cp brickhouse-0.8.2-JS.jar s3://DOC-EXAMPLE-BUCKET/jars/
```

- Créez un fichier d'exemple pour utiliser l'une des UDF fonctions d'exemple. Enregistrez cette requête sous `udf_example.q` et chargez-la dans votre compartiment S3.

```
add jar s3://DOC-EXAMPLE-BUCKET/jars/brickhouse-0.8.2-JS.jar;
CREATE TEMPORARY FUNCTION from_json AS 'brickhouse.udf.json.FromJsonUDF';
select from_json('{"key1":[0,1,2], "key2":[3,4,5,6], "key3":[7,8,9]}', map("",
  array(cast(0 as int))));
select from_json('{"key1":[0,1,2], "key2":[3,4,5,6], "key3":[7,8,9]}', map("",
  array(cast(0 as int))))["key1"][2];
```

- Soumettez le job Hive suivant.

```
aws emr-serverless start-job-run \
  --application-id application-id \
  --execution-role-arn job-role-arn \
  --job-driver '{
    "hive": {
      "query": "s3://DOC-EXAMPLE-BUCKET/queries/udf_example.q",
      "parameters": "--hiveconf hive.exec.scratchdir=s3://DOC-EXAMPLE-BUCKET/emr-
serverless-hive/scratch --hiveconf hive.metastore.warehouse.dir=s3://'$BUCKET'/emr-
serverless-hive/warehouse"
    }
  }' --configuration-overrides '{
  "applicationConfiguration": [{
    "classification": "hive-site",
    "properties": {
      "hive.driver.cores": "2",
      "hive.driver.memory": "6G"
    }
  }],
  "monitoringConfiguration": {
    "s3MonitoringConfiguration": {
      "logUri": "s3://DOC-EXAMPLE-BUCKET/logs/"
    }
  }
}'
```

5. Utilisez la `get-job-run` commande pour vérifier l'état de votre tâche. Attendez que l'état passe à `SUCCESS`.

```
aws emr-serverless get-job-run --application-id application-id --job-run-id job-id
```

6. Téléchargez les fichiers de sortie à l'aide de la commande suivante.

```
aws s3 cp --recursive s3://DOC-EXAMPLE-BUCKET/logs/applications/application-id/jobs/job-id/HIVE_DRIVER/ .
```

Le `stdout.gz` fichier ressemble à ce qui suit.

```
{"key1": [0, 1, 2], "key2": [3, 4, 5, 6], "key3": [7, 8, 9]}
2
```

## Utilisation d'images personnalisées avec EMR Serverless

### Rubriques

- [Utiliser une version personnalisée de Python](#)
- [Utiliser une version personnalisée de Java](#)
- [Créez une image de science des données](#)
- [Traitement des données géospatiales avec Apache Sedona](#)

### Utiliser une version personnalisée de Python

Vous pouvez créer une image personnalisée pour utiliser une version différente de Python. Pour utiliser la version 3.10 de Python pour les tâches Spark, par exemple, exécutez la commande suivante :

```
FROM public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest

USER root

# install python 3
RUN yum install -y gcc openssl-devel bzip2-devel libffi-devel tar gzip wget make
RUN wget https://www.python.org/ftp/python/3.10.0/Python-3.10.0.tgz && \
tar xzf Python-3.10.0.tgz && cd Python-3.10.0 && \
```

```
./configure --enable-optimizations && \  
make altinstall  
  
# EMRS will run the image as hadoop  
USER hadoop:hadoop
```

Avant de soumettre le job Spark, définissez vos propriétés pour utiliser l'environnement virtuel Python, comme suit.

```
--conf spark.emr-serverless.driverEnv.PYSPARK_DRIVER_PYTHON=/usr/local/bin/python3.10  
--conf spark.emr-serverless.driverEnv.PYSPARK_PYTHON=/usr/local/bin/python3.10  
--conf spark.executorEnv.PYSPARK_PYTHON=/usr/local/bin/python3.10
```

## Utiliser une version personnalisée de Java

L'exemple suivant montre comment créer une image personnalisée pour utiliser Java 11 pour vos tâches Spark.

```
FROM public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest  
  
USER root  
  
# install JDK 11  
RUN sudo amazon-linux-extras install java-openjdk11  
  
# EMRS will run the image as hadoop  
USER hadoop:hadoop
```

Avant de soumettre la tâche Spark, définissez les propriétés de Spark pour utiliser Java 11, comme suit.

```
--conf spark.executorEnv.JAVA_HOME=/usr/lib/jvm/java-11-  
openjdk-11.0.16.0.8-1.amzn2.0.1.x86_64  
--conf spark.emr-serverless.driverEnv.JAVA_HOME=/usr/lib/jvm/java-11-  
openjdk-11.0.16.0.8-
```

## Créer une image de science des données

L'exemple suivant montre comment inclure des packages Python courants pour la science des données, tels que Pandas et NumPy.



```
FROM public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest

USER root

# python packages
RUN pip3 install boto3 pandas numpy
RUN pip3 install -U scikit-learn==0.23.2 scipy
RUN pip3 install sk-dist
RUN pip3 install xgboost

# EMR Serverless will run the image as hadoop
USER hadoop:hadoop
```

## Traitement des données géospatiales avec Apache Sedona

L'exemple suivant montre comment créer une image pour inclure Apache Sedona pour le traitement géospatial.

```
FROM public.ecr.aws/emr-serverless/spark/emr-6.9.0:latest

USER root

RUN yum install -y wget
RUN wget https://repo1.maven.org/maven2/org/apache/sedona/sedona-core-3.0_2.12/1.3.0-incubating/sedona-core-3.0_2.12-1.3.0-incubating.jar -P /usr/lib/spark/jars/
RUN pip3 install apache-sedona

# EMRS will run the image as hadoop
USER hadoop:hadoop
```

## Utilisation de l'intégration Amazon Redshift pour Apache Spark sur Amazon Serverless EMR

Dans les EMR versions 6.9.0 et ultérieures d'Amazon, chaque image de version inclut un connecteur entre [Apache Spark](#) et Amazon Redshift. Avec ce connecteur, vous pouvez utiliser Spark sur Amazon EMR Serverless pour traiter les données stockées dans Amazon Redshift. L'intégration est basée sur le [connecteur open-source spark-redshift](#). Pour Amazon EMR Serverless, [l'intégration Amazon Redshift pour Apache Spark](#) est incluse en tant qu'intégration native.

### Rubriques

- [Lancement d'une application Spark avec l'intégration Amazon Redshift pour Apache Spark](#)
- [Authentification avec l'intégration Amazon Redshift pour Apache Spark](#)
- [Lecture et écriture à partir de et vers Amazon Redshift](#)
- [Considérations et limites relatives à l'utilisation du connecteur Spark](#)

## Lancement d'une application Spark avec l'intégration Amazon Redshift pour Apache Spark

Pour utiliser l'intégration avec EMR Serverless 6.9.0, vous devez transmettre les dépendances Spark-Redshift requises à votre tâche Spark. `--jars` À utiliser pour inclure les bibliothèques associées au connecteur Redshift. Pour connaître les autres emplacements de fichiers pris en charge par l'option `--jars`, consultez la rubrique [Gestion avancée des dépendances](#) de la documentation Apache Spark.

- `spark-redshift.jar`
- `spark-avro.jar`
- `RedshiftJDBC.jar`
- `minimal-json.jar`

EMR Les versions 6.10.0 et ultérieures d'Amazon ne nécessitent pas cette `minimal-json.jar` dépendance et installent automatiquement les autres dépendances sur chaque cluster par défaut. Les exemples suivants montrent comment lancer une application Spark avec l'intégration Amazon Redshift pour Apache Spark.

### Amazon EMR 6.10.0 +

Lancez une tâche Spark sur Amazon EMR Serverless avec l'intégration Amazon Redshift pour Apache Spark EMR on Serverless version 6.10.0 ou ultérieure.

```
spark-submit my_script.py
```

### Amazon EMR 6.9.0

Pour lancer une tâche Spark sur Amazon EMR Serverless avec l'intégration Amazon Redshift pour Apache Spark EMR on Serverless version 6.9.0, utilisez `--jars` l'option illustrée dans

l'exemple suivant. Notez que les chemins répertoriés avec l'`--jars` option sont les chemins par défaut pour les JAR fichiers.

```
--jars
  /usr/share/aws/redshift/jdbc/RedshiftJDBC.jar,
  /usr/share/aws/redshift/spark-redshift/lib/spark-redshift.jar,
  /usr/share/aws/redshift/spark-redshift/lib/spark-avro.jar,
  /usr/share/aws/redshift/spark-redshift/lib/minimal-json.jar
```

```
spark-submit \
  --jars /usr/share/aws/redshift/jdbc/RedshiftJDBC.jar,/usr/share/aws/redshift/
  spark-redshift/lib/spark-redshift.jar,/usr/share/aws/redshift/spark-redshift/lib/
  spark-avro.jar,/usr/share/aws/redshift/spark-redshift/lib/minimal-json.jar \
  my_script.py
```

## Authentification avec l'intégration Amazon Redshift pour Apache Spark

### Utiliser AWS Secrets Manager pour récupérer les informations d'identification et se connecter à Amazon Redshift

Vous pouvez vous authentifier auprès d'Amazon Redshift en toute sécurité en stockant les informations d'identification dans Secrets Manager et en demandant à la tâche Spark d'appeler `GetSecretValue` API le pour les récupérer :

```
from pyspark.sql import SQLContextimport boto3

sc = # existing SparkContext
sql_context = SQLContext(sc)

secretsmanager_client = boto3.client('secretsmanager',
  region_name=os.getenv('AWS_REGION'))
secret_manager_response = secretsmanager_client.get_secret_value(
  SecretId='string',
  VersionId='string',
  VersionStage='string'
)
username = # get username from secret_manager_response
password = # get password from secret_manager_response
```

```
url = "jdbc:redshift://redshifthost:5439/database?user=" + username + "&password="
      + password

# Access to Redshift cluster using Spark
```

## Authentifiez-vous auprès d'Amazon Redshift avec un chauffeur JDBC

Définissez le nom d'utilisateur et le mot de passe dans JDBC URL

Vous pouvez authentifier une tâche Spark auprès d'un cluster Amazon Redshift en spécifiant le nom et le mot de passe de la base de données Amazon Redshift dans le JDBC URL

### Note

Si vous transmettez les informations d'identification de la base de données dans le URL, toute personne ayant accès au URL peut également accéder aux informations d'identification. Cette méthode n'est généralement pas recommandée, car elle n'est pas une option sécurisée.

Si la sécurité n'est pas un problème pour votre application, vous pouvez utiliser le format suivant pour définir le nom d'utilisateur et le mot de passe dans JDBC URL :

```
jdbc:redshift://redshifthost:5439/database?user=username&password=password
```

## Utiliser l'authentification IAM basée sur le rôle d'exécution des tâches Amazon EMR Serverless

À partir de la version 6.9.0 d'Amazon EMR Serverless, le pilote Amazon JDBC Redshift 2.1 ou supérieur est intégré à l'environnement. Avec JDBC le pilote 2.1 ou supérieur, vous pouvez spécifier le nom d'utilisateur JDBC URL et le mot de passe bruts et ne pas inclure le nom d'utilisateur et le mot de passe bruts.

Au lieu de cela, vous pouvez indiquer un schéma `jdbc:redshift:iam://`. Cela commande au JDBC pilote d'utiliser votre rôle d'exécution de tâches EMR sans serveur pour récupérer automatiquement les informations d'identification. Consultez [Configurer une ODBC connexion JDBC ou pour utiliser les IAM informations d'identification](#) dans le guide de gestion Amazon Redshift pour plus d'informations. Voici un exemple de URL ceci :

```
jdbc:redshift:iam://examplecluster.abc123xyz789.us-west-2.redshift.amazonaws.com:5439/
dev
```

Les autorisations suivantes sont requises pour votre rôle d'exécution de tâches lorsque les conditions fournies sont remplies :

Autorisation	Conditions requises pour le rôle d'exécution des tâches
<code>redshift:GetClusterCredentials</code>	Obligatoire pour que JDBC le chauffeur récupère les informations d'identification auprès d'Amazon Redshift
<code>redshift:DescribeCluster</code>	Obligatoire si vous spécifiez le cluster Amazon Redshift et Région AWS au JDBC URL lieu du point de terminaison
<code>redshift-serverless:GetCredentials</code>	Obligatoire pour que JDBC le conducteur récupère les informations d'identification depuis Amazon Redshift Serverless
<code>redshift-serverless:GetWorkgroup</code>	Obligatoire si vous utilisez Amazon Redshift Serverless et que vous spécifiez le nom du groupe URL de travail et la région

## Connexion à Amazon Redshift dans un autre VPC

Lorsque vous configurez un cluster Amazon Redshift provisionné ou un groupe de travail Amazon Redshift Serverless dans le cadre d'un VPC, vous devez configurer la VPC connectivité pour que votre application EMR Amazon Serverless puisse accéder aux ressources. Pour plus d'informations sur la configuration de VPC la connectivité sur une application EMR sans serveur, consultez [Configuration de VPC l'accès](#).

- Si votre cluster Amazon Redshift ou votre groupe de travail Amazon Redshift Serverless provisionné est accessible au public, vous pouvez spécifier un ou plusieurs sous-réseaux privés auxquels une passerelle est attachée lorsque vous NAT créez des applications sans serveur. EMR
- Si votre cluster Amazon Redshift ou votre groupe de travail Amazon Redshift Serverless provisionné n'est pas accessible au public, vous devez créer un point de VPC terminaison géré par Amazon Redshift pour votre cluster Amazon Redshift, comme décrit dans [Configuration de VPC l'accès](#) Vous pouvez également créer votre groupe de travail Amazon Redshift Serverless comme décrit dans la section Connexion à [Amazon Redshift Serverless du guide de gestion Amazon](#)

[Redshift](#). Vous devez associer votre cluster ou votre sous-groupe aux sous-réseaux privés que vous spécifiez lorsque vous créez votre application EMR Serverless.

#### Note

Si vous utilisez l'authentification IAM basée et qu'aucune NAT passerelle n'est attachée à vos sous-réseaux privés pour l'application EMR Serverless, vous devez également créer un VPC point de terminaison sur ces sous-réseaux pour Amazon Redshift ou Amazon Redshift Serverless. De cette façon, le JDBC pilote peut récupérer les informations d'identification.

## Lecture et écriture à partir de et vers Amazon Redshift

Les exemples de code suivants permettent de PySpark lire et d'écrire des exemples de données depuis et vers une base de données Amazon Redshift avec une source de données API et avec Spark. SQL

### Data source API

PySpark À utiliser pour lire et écrire des exemples de données depuis et vers une base de données Amazon Redshift avec source de données. API

```
import boto3
from pyspark.sql import SQLContext

sc = # existing SparkContext
sql_context = SQLContext(sc)

url = "jdbc:redshift:iam://redshifthost:5439/database"
aws_iam_role_arn = "arn:aws:iam::account-id:role/role-name"

df = sql_context.read \
    .format("io.github.spark_redshift_community.spark.redshift") \
    .option("url", url) \
    .option("dbtable", "table-name") \
    .option("tempdir", "s3://path/for/temp/data") \
    .option("aws_iam_role", "aws-iam-role-arn") \
    .load()

df.write \
```

```

.format("io.github.spark_redshift_community.spark.redshift") \
.option("url", url) \
.option("dbtable", "table-name-copy") \
.option("tempdir", "s3://path/for/temp/data") \
.option("aws_iam_role", "aws-iam-role-arn") \
.mode("error") \
.save()

```

## SparkSQL

PySpark À utiliser pour lire et écrire des exemples de données depuis et vers une base de données Amazon Redshift avec Spark. SQL

```

import boto3
import json
import sys
import os
from pyspark.sql import SparkSession

spark = SparkSession \
    .builder \
    .enableHiveSupport() \
    .getOrCreate()

url = "jdbc:redshift:iam://redshifthost:5439/database"
aws_iam_role_arn = "arn:aws:iam::account-id:role/role-name"

bucket = "s3://path/for/temp/data"
tableName = "table-name" # Redshift table name

s = f"""CREATE TABLE IF NOT EXISTS {table-name} (country string, data string)
    USING io.github.spark_redshift_community.spark.redshift
    OPTIONS (dbtable '{table-name}', tempdir '{bucket}', url '{url}', aws_iam_role
    '{aws-iam-role-arn}' ); """

spark.sql(s)

columns = ["country" ,"data"]
data = [("test-country", "test-data")]
df = spark.sparkContext.parallelize(data).toDF(columns)

# Insert data into table
df.write.insertInto(table-name, overwrite=False)

```

```
df = spark.sql(f"SELECT * FROM {table-name}")
df.show()
```

## Considérations et limites relatives à l'utilisation du connecteur Spark

- Nous vous recommandons d'activer SSL la JDBC connexion entre Spark on Amazon EMR et Amazon Redshift.
- Nous vous recommandons de gérer les informations d'identification du cluster Amazon Redshift dans AWS Secrets Manager en tant que meilleure pratique. Voir [Utilisation AWS Secrets Manager pour récupérer les informations d'identification permettant de se connecter à Amazon Redshift](#), par exemple.
- Nous vous recommandons de transmettre un IAM rôle avec le paramètre `aws_iam_role` d'authentification Amazon Redshift.
- Le paramètre `tempformat` ne prend actuellement pas en charge le format Parquet.
- Il `tempdir` URI pointe vers un emplacement Amazon S3. Ce répertoire temporaire n'est pas nettoyé automatiquement et peut donc entraîner des coûts supplémentaires.
- Tenez compte des recommandations suivantes pour Amazon Redshift :
  - Nous vous recommandons de bloquer l'accès public au cluster Amazon Redshift.
  - Nous vous recommandons d'activer la [journalisation des audits d'Amazon Redshift](#).
  - Nous vous recommandons d'activer le [chiffrement au repos d'Amazon Redshift](#).
- Tenez compte des recommandations suivantes pour Amazon S3 :
  - Nous vous recommandons de [bloquer l'accès public aux compartiments Amazon S3](#).
  - Nous vous recommandons d'utiliser le [chiffrement côté serveur Amazon S3](#) pour chiffrer les compartiments Amazon S3 utilisés.
  - Nous vous recommandons d'utiliser les [politiques de cycle de vie d'Amazon S3](#) pour définir les règles de conservation du compartiment Amazon S3.
  - Amazon vérifie EMR toujours le code importé depuis l'open source dans l'image. Pour des raisons de sécurité, nous ne prenons pas en charge les méthodes d'authentification suivantes de Spark vers Amazon S3 :
    - Paramètre AWS clés d'accès dans la classification `hadoop-env` de configuration
    - Encodage AWS clés d'accès dans le `tempdir` URI



Pour plus d'informations sur l'utilisation du connecteur et les paramètres qu'il prend en charge, consultez les ressources suivantes :

- [Intégration d'Amazon Redshift pour Apache Spark](#) dans le Guide de gestion Amazon Redshift
- Le [référentiel communautaire spark-redshift](#) sur Github

## Connexion à DynamoDB avec Amazon Serverless EMR

Dans ce didacticiel, vous chargez un sous-ensemble de données du [United States Board on Geographic Names](#) dans un compartiment Amazon S3, puis vous utilisez Hive ou Spark sur Amazon EMR Serverless pour copier les données dans une table Amazon DynamoDB que vous pouvez interroger.

### Étape 1 : télécharger des données dans un compartiment Amazon S3

Pour créer un compartiment Amazon S3, suivez les instructions de la section [Création d'un compartiment](#) dans le guide de l'utilisateur de la console Amazon Simple Storage Service.

Remplacez les références *DOC-EXAMPLE-BUCKET* à par le nom du bucket que vous venez de créer. Votre application EMR Serverless est maintenant prête à exécuter des tâches.

1. Téléchargez l'exemple d'archive de données `features.zip` à l'aide de la commande suivante.

```
wget https://docs.aws.amazon.com/amazondynamodb/latest/developerguide/samples/features.zip
```

2. Extrayez le `features.txt` fichier de l'archive et visualisez les premières lignes du fichier :

```
unzip features.zip
head features.txt
```

Le résultat devrait ressembler à ce qui suit.

```
1535908|Big Run|Stream|WV|38.6370428|-80.8595469|794
875609|Constable Hook|Cape|NJ|40.657881|-74.0990309|7
1217998|Gooseberry Island|Island|RI|41.4534361|-71.3253284|10
26603|Boone Moore Spring|Spring|AZ|34.0895692|-111.410065|3681
1506738|Missouri Flat|Flat|WA|46.7634987|-117.0346113|2605
1181348|Minnow Run|Stream|PA|40.0820178|-79.3800349|1558
1288759|Hunting Creek|Stream|TN|36.343969|-83.8029682|1024
```

```
533060|Big Charles Bayou|Bay|LA|29.6046517|-91.9828654|0
829689|Greenwood Creek|Stream|NE|41.596086|-103.0499296|3671
541692|Button Willow Island|Island|LA|31.9579389|-93.0648847|98
```

Les champs de chaque ligne indiquent un identifiant unique, un nom, un type d'élément naturel, un état, une latitude en degrés, une longitude en degrés et une hauteur en pieds.

### 3. Chargez vos données sur Amazon S3

```
aws s3 cp features.txt s3://DOC-EXAMPLE-BUCKET/features/
```

## Étape 2 : Création d'une table Hive

Utilisez Apache Spark ou Hive pour créer une nouvelle table Hive contenant les données téléchargées dans Amazon S3.

### Spark

Pour créer une table Hive avec Spark, exécutez la commande suivante.

```
import org.apache.spark.sql.SparkSession

val sparkSession = SparkSession.builder().enableHiveSupport().getOrCreate()

sparkSession.sql("CREATE TABLE hive_features \
  (feature_id BIGINT, \
  feature_name STRING, \
  feature_class STRING, \
  state_alpha STRING, \
  prim_lat_dec DOUBLE, \
  prim_long_dec DOUBLE, \
  elev_in_ft BIGINT) \
  ROW FORMAT DELIMITED \
  FIELDS TERMINATED BY '|' \
  LINES TERMINATED BY '\n' \
  LOCATION 's3://DOC-EXAMPLE-BUCKET/features';")
```

Vous disposez désormais d'une table Hive remplie avec les données du `features.txt` fichier. Pour vérifier que vos données figurent dans la table, exécutez une SQL requête Spark comme indiqué dans l'exemple suivant.

```
sparkSession.sql(
    "SELECT state_alpha, COUNT(*) FROM hive_features GROUP BY state_alpha;")
```

## Hive

Pour créer une table Hive avec Hive, exécutez la commande suivante.

```
CREATE TABLE hive_features
  (feature_id          BIGINT,
   feature_name        STRING ,
   feature_class       STRING ,
   state_alpha         STRING,
   prim_lat_dec        DOUBLE ,
   prim_long_dec       DOUBLE ,
   elev_in_ft          BIGINT)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '|'
LINES TERMINATED BY '\n'
LOCATION 's3://DOC-EXAMPLE-BUCKET/features';
```

Vous disposez désormais d'une table Hive qui contient les données du `features.txt` fichier. Pour vérifier que vos données figurent dans la table, exécutez une requête HiveQL, comme indiqué dans l'exemple suivant.

```
SELECT state_alpha, COUNT(*) FROM hive_features GROUP BY state_alpha;
```

## Étape 3 : Copier les données dans DynamoDB

Utilisez Spark ou Hive pour copier des données dans une nouvelle table DynamoDB.

### Spark

Pour copier les données de la table Hive que vous avez créée à l'étape précédente dans DynamoDB, suivez les étapes 1 à 3 de la section [Copier](#) les données dans DynamoDB. Cela crée une nouvelle table DynamoDB appelée `Features`. Vous pouvez ensuite lire les données directement depuis le fichier texte et les copier dans votre table DynamoDB, comme le montre l'exemple suivant.

```
import com.amazonaws.services.dynamodbv2.model.AttributeValue
import org.apache.hadoop.dynamodb.DynamoDBItemWritable
```

```
import org.apache.hadoop.dynamodb.read.DynamoDBInputFormat
import org.apache.hadoop.io.Text
import org.apache.hadoop.mapred.JobConf
import org.apache.spark.SparkContext

import scala.collection.JavaConverters._

object EmrServerlessDynamoDbTest {

  def main(args: Array[String]): Unit = {

    jobConf.set("dynamodb.input.tableName", "Features")
    jobConf.set("dynamodb.output.tableName", "Features")
    jobConf.set("dynamodb.region", "region")

    jobConf.set("mapred.output.format.class",
"org.apache.hadoop.dynamodb.write.DynamoDBOutputFormat")
    jobConf.set("mapred.input.format.class",
"org.apache.hadoop.dynamodb.read.DynamoDBInputFormat")

    val rdd = sc.textFile("s3://DOC-EXAMPLE-BUCKET/ddb-connector/")
      .map(row => {
        val line = row.split("\\|")
        val item = new DynamoDBItemWritable()

        val elevInFt = if (line.length > 6) {
          new AttributeValue().withN(line(6))
        } else {
          new AttributeValue().withNULL(true)
        }

        item.setItem(Map(
          "feature_id" -> new AttributeValue().withN(line(0)),
          "feature_name" -> new AttributeValue(line(1)),
          "feature_class" -> new AttributeValue(line(2)),
          "state_alpha" -> new AttributeValue(line(3)),
          "prim_lat_dec" -> new AttributeValue().withN(line(4)),
          "prim_long_dec" -> new AttributeValue().withN(line(5)),
          "elev_in_ft" -> elevInFt)
          .asJava)
          (new Text(""), item)
        })
    rdd.saveAsHadoopDataset(jobConf)
  }
}
```

```
}
```

## Hive

Pour copier les données de la table Hive que vous avez créée à l'étape précédente dans DynamoDB, suivez les instructions de la section [Copier les données dans DynamoDB](#).

## Étape 4 : interroger les données depuis DynamoDB

Utilisez Spark ou Hive pour interroger votre table DynamoDB.

### Spark

Pour interroger les données de la table DynamoDB que vous avez créée à l'étape précédente, vous pouvez utiliser SQL Spark ou Spark. MapReduce API

Exemple — Interrogez votre table DynamoDB avec Spark SQL

La SQL requête Spark suivante renvoie une liste de tous les types de fonctionnalités par ordre alphabétique.

```
val dataframe = sparkSession.sql("SELECT DISTINCT feature_class \  
  FROM ddb_features \  
  ORDER BY feature_class;")
```

La SQL requête Spark suivante renvoie une liste de tous les lacs commençant par la lettre M.

```
val dataframe = sparkSession.sql("SELECT feature_name, state_alpha \  
  FROM ddb_features \  
  WHERE feature_class = 'Lake' \  
  AND feature_name LIKE 'M%' \  
  ORDER BY feature_name;")
```

La SQL requête Spark suivante renvoie une liste de tous les états comportant au moins trois entités situées à plus d'un kilomètre.

```
val dataframe = sparkSession.dql("SELECT state_alpha, feature_class, COUNT(*) \  
  FROM ddb_features \  
  WHERE elev_in_ft > 5280 \  
  GROUP BY state_alpha, feature_class;")
```

```
GROUP BY state_alpha, feature_class \
HAVING COUNT(*) >= 3 \
ORDER BY state_alpha, feature_class;")
```

Exemple — Interrogez votre table DynamoDB avec le Spark MapReduce API

La MapReduce requête suivante renvoie une liste de tous les types de fonctionnalités par ordre alphabétique.

```
val df = sc.hadoopRDD(jobConf, classOf[DynamoDBInputFormat], classOf[Text],
  classOf[DynamoDBItemWritable])
  .map(pair => (pair._1, pair._2.getItem))
  .map(pair => pair._2.get("feature_class").getS)
  .distinct()
  .sortBy(value => value)
  .toDF("feature_class")
```

La MapReduce requête suivante renvoie une liste de tous les lacs commençant par la lettre M.

```
val df = sc.hadoopRDD(jobConf, classOf[DynamoDBInputFormat], classOf[Text],
  classOf[DynamoDBItemWritable])
  .map(pair => (pair._1, pair._2.getItem))
  .filter(pair => "Lake".equals(pair._2.get("feature_class").getS))
  .filter(pair => pair._2.get("feature_name").getS.startsWith("M"))
  .map(pair => (pair._2.get("feature_name").getS,
    pair._2.get("state_alpha").getS))
  .sortBy(_._1)
  .toDF("feature_name", "state_alpha")
```

La MapReduce requête suivante renvoie une liste de tous les états comportant au moins trois entités situées à plus d'un kilomètre.

```
val df = sc.hadoopRDD(jobConf, classOf[DynamoDBInputFormat], classOf[Text],
  classOf[DynamoDBItemWritable])
  .map(pair => pair._2.getItem)
  .filter(pair => pair.get("elev_in_ft").getN != null)
  .filter(pair => Integer.parseInt(pair.get("elev_in_ft").getN) > 5280)
  .groupBy(pair => (pair.get("state_alpha").getS, pair.get("feature_class").getS))
  .filter(pair => pair._2.size >= 3)
  .map(pair => (pair._1._1, pair._1._2, pair._2.size))
  .sortBy(pair => (pair._1, pair._2))
```

```
.toDF("state_alpha", "feature_class", "count")
```

## Hive

Pour interroger les données de la table DynamoDB que vous avez créée à l'étape précédente, suivez les instructions de la section [Interroger les données de la](#) table DynamoDB.

## Configurer l'accès intercompte

Pour configurer l'accès entre comptes pour EMR Serverless, procédez comme suit. Dans l'exemple, AccountA il s'agit du compte sur lequel vous avez créé votre application Amazon EMR Serverless et AccountB du compte sur lequel se trouve votre Amazon DynamoDB.

1. Créez une table DynamoDB dans. AccountB Pour plus d'informations, voir [Étape 1 : Création d'une table](#).
2. Créez un Cross-Account-Role-B IAM rôle permettant d'accéder à la table DynamoDB. AccountB
  - a. Connectez-vous au AWS Management Console et ouvrez la IAM console à l'adresse <https://console.aws.amazon.com/iam/>.
  - b. Choisissez Rôles, puis créez un nouveau rôle appelé Cross-Account-Role-B. Pour plus d'informations sur la création de IAM rôles, consultez la section [Création de IAM rôles](#) dans le guide de l'utilisateur.
  - c. Créez une IAM politique qui accorde les autorisations d'accès à la table DynamoDB entre comptes. Attachez ensuite la IAM politique à Cross-Account-Role-B.

Voici une politique qui autorise l'accès à une table DynamoDB CrossAccountTable.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "dynamodb:*",
      "Resource": "arn:aws:dynamodb:region:AccountB:table/
CrossAccountTable"
    }
  ]
}
```

- d. Modifiez la relation de confiance du rôle Cross-Account-Role-B.

Pour configurer la relation de confiance pour le rôle, choisissez l'onglet Relations de confiance dans la IAM console pour le rôle que vous avez créé à l'étape 2 : Cross-Account-Role-B.

Sélectionnez Modifier la relation de confiance, puis ajoutez le document de politique suivant. Ce document permet AccountA à Job-Execution-Role-A in d'assumer ce Cross-Account-Role-B rôle.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "AWS": "arn:aws:iam::AccountA:role/Job-Execution-Role-A"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
```

- e. Accordez Job-Execution-Role-A AccountA avec - STS Assume role les autorisations d'assumerCross-Account-Role-B.

Dans la IAM console pour Compte AWS AccountA, sélectionnezJob-Execution-Role-A. Ajoutez la déclaration de politique générale suivante au rôle Job-Execution-Role-A pour autoriser l'action AssumeRole sur le rôle Cross-Account-Role-B.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "sts:AssumeRole",
      "Resource": "arn:aws:iam::AccountB:role/Cross-Account-Role-B"
    }
  ]
}
```

- f. Définissez la dynamodb.customAWSCredentialsProvider propriété avec une valeur comme com.amazonaws.emr.AssumeRoleAWSCredentialsProvider dans la classification des sites principaux. Définissez la variable d'environnement ASSUME\_ROLE\_CREDENTIALS\_ROLE\_ARN avec la ARN valeur deCross-Account-Role-B.

3. Exécutez le job Spark ou Hive en utilisantJob-Execution-Role-A.



## Considérations

### Considérations relatives à l'utilisation du connecteur DynamoDB avec Apache Spark

- Spark SQL ne prend pas en charge la création d'une table Hive avec l'option `storage-handler`. Pour plus d'informations, consultez la section [Spécification du format de stockage pour les tables Hive](#) dans la documentation d'Apache Spark.
- Spark SQL ne prend pas en charge l'`STORED BY` opération avec le gestionnaire de stockage. Si vous souhaitez interagir avec une table DynamoDB via une table Hive externe, utilisez d'abord Hive pour créer la table.
- Pour convertir une requête en requête DynamoDB, le connecteur DynamoDB utilise le prédicat `pushdown`. Le prédicat `pushdown` filtre les données en fonction d'une colonne mappée à la clé de partition d'une table DynamoDB. Le `pushdown` des prédicats ne fonctionne que lorsque vous utilisez le connecteur avec SparkSQL, et non avec le `MapReduce API`.

### Considérations relatives à l'utilisation du connecteur DynamoDB avec Apache Hive

#### Réglage du nombre maximum de mappers

- Si vous utilisez la `SELECT` requête pour lire les données d'une table Hive externe mappée à DynamoDB, le nombre de tâches cartographiques EMR sur Serverless est calculé comme le débit de lecture total configuré pour la table DynamoDB, divisé par le débit par tâche cartographique. Le débit par défaut par tâche cartographique est de 100.
- La tâche Hive peut utiliser le nombre de tâches cartographiques au-delà du nombre maximum de conteneurs configurés par application EMR Serverless, en fonction du débit de lecture configuré pour DynamoDB. En outre, une requête Hive de longue durée peut consommer toute la capacité de lecture allouée à la table DynamoDB. Cela a un impact négatif sur les autres utilisateurs.
- Vous pouvez utiliser cette `dynamodb.max.map.tasks` propriété pour définir une limite supérieure pour les tâches cartographiques. Vous pouvez également utiliser cette propriété pour ajuster la quantité de données lues par chaque tâche cartographique en fonction de la taille du conteneur de tâches.
- Vous pouvez définir la `dynamodb.max.map.tasks` propriété au niveau de la requête Hive ou dans la `hive-site` classification de la `start-job-run` commande. Cette valeur doit être supérieure ou égale à 1. Lorsque Hive traite votre requête, la tâche Hive qui en résulte n'utilise que les valeurs indiquées `dynamodb.max.map.tasks` lors de la lecture dans la table DynamoDB.

## Réglage du débit d'écriture par tâche

- Le débit d'écriture par tâche sur EMR Serverless est calculé comme le débit d'écriture total configuré pour une table DynamoDB, divisé par la valeur de la propriété `mapreduce.job.maps`. Pour Hive, la valeur par défaut de cette propriété est 2. Ainsi, les deux premières tâches de la phase finale d'une tâche Hive peuvent consommer tout le débit d'écriture. Cela entraîne une limitation des écritures d'autres tâches dans le même travail ou dans d'autres tâches.
- Pour éviter la limitation de l'écriture, vous pouvez définir la valeur de la `mapreduce.job.maps` propriété en fonction du nombre de tâches de l'étape finale ou du débit d'écriture que vous souhaitez allouer par tâche. Définissez cette propriété dans la `mapred-site` classification de la `start-job-run` commande sur EMR Serverless.

# Sécurité

Sécurité du cloud chez AWS est la plus haute priorité. En tant que AWS client, vous bénéficiez d'un centre de données et d'une architecture réseau conçus pour répondre aux exigences des entreprises les plus sensibles en matière de sécurité.

La sécurité est une responsabilité partagée entre AWS et toi. Le [modèle de responsabilité partagée](#) décrit cette notion par les termes sécurité du cloud et sécurité dans le cloud :

- Sécurité du cloud — AWS est chargé de protéger l'infrastructure qui fonctionne AWS services dans le AWS Nuage. AWS vous fournit également des services que vous pouvez utiliser en toute sécurité. Des auditeurs tiers testent et vérifient régulièrement l'efficacité de notre sécurité dans le cadre du [AWS programmes de conformité](#). Pour en savoir plus sur les programmes de conformité qui s'appliquent à Amazon EMR Serverless, consultez [AWS services visés par le programme de conformité](#).
- Sécurité dans le cloud — Votre responsabilité est déterminée par le AWS service que vous utilisez. Vous êtes également responsable d'autres facteurs, y compris la sensibilité de vos données, les exigences de votre entreprise, ainsi que la législation et la réglementation applicables.

Cette documentation vous aide à comprendre comment appliquer le modèle de responsabilité partagée lors de l'utilisation d'Amazon EMR Serverless. Les rubriques de ce chapitre vous montrent comment configurer Amazon EMR Serverless et utiliser d'autres AWS des services pour répondre à vos objectifs de sécurité et de conformité.

## Rubriques

- [Bonnes pratiques de sécurité pour Amazon EMR Serverless](#)
- [Protection des données](#)
- [Identity and Access Management \(IAM\) dans Amazon EMR Serverless](#)
- [Utilisation du mode EMR Serverless avec AWS Lake Formation pour un contrôle d'accès précis](#)
- [Chiffrement inter-travailleurs](#)
- [Secrets Manager pour la protection des données avec EMR Serverless](#)
- [Utilisation des autorisations d'accès Amazon S3 avec EMR Serverless](#)
- [Enregistrement des API appels Amazon EMR Serverless à l'aide de AWS CloudTrail](#)
- [Validation de conformité pour Amazon EMR Serverless](#)

- [Résilience dans Amazon EMR Serverless](#)
- [Sécurité de l'infrastructure dans Amazon EMR Serverless](#)
- [Analyse de configuration et de vulnérabilité dans Amazon EMR Serverless](#)

## Bonnes pratiques de sécurité pour Amazon EMR Serverless

Amazon EMR Serverless fournit un certain nombre de fonctionnalités de sécurité à prendre en compte lors de l'élaboration et de la mise en œuvre de vos propres politiques de sécurité. Les bonnes pratiques suivantes doivent être considérées comme des instructions générales et ne représentent pas une solution de sécurité complète. Étant donné que ces bonnes pratiques peuvent ne pas être appropriées ou suffisantes pour votre environnement, considérez-les comme des remarques utiles plutôt que comme des recommandations.

### Application du principe du moindre privilège

EMRServerless fournit une politique d'accès granulaire pour les applications utilisant des IAM rôles, tels que des rôles d'exécution. Nous recommandons de n'accorder aux rôles d'exécution que l'ensemble minimal de privilèges requis par la tâche, tels que la couverture de votre application et l'accès à la destination du journal. Nous recommandons également de vérifier régulièrement les autorisations des tâches et lors de toute modification du code d'application.

### Isolation du code d'application non fiable

EMRServerless crée une isolation complète du réseau entre les tâches appartenant à différentes applications EMR sans serveur. Dans les cas où l'isolation au niveau des tâches est souhaitée, envisagez d'isoler les tâches dans différentes EMR applications sans serveur.

### Autorisations de contrôle d'accès basées sur les rôles (RBAC)

Les administrateurs doivent contrôler strictement les autorisations de contrôle d'accès basé sur les rôles (RBAC) pour les applications EMR sans serveur.

### Protection des données

Le AWS [Le modèle de responsabilité partagée](#) s'applique à la protection des données dans Amazon EMR Serverless. Comme décrit dans ce modèle, AWS est chargé de protéger l'infrastructure

mondiale qui gère tous les AWS Nuage. La gestion du contrôle de votre contenu hébergé sur cette infrastructure relève de votre responsabilité. Ce contenu inclut les tâches de configuration et de gestion de la sécurité pour AWS les services que vous utilisez. Pour plus d'informations sur la confidentialité des données, consultez la section [Confidentialité des données FAQ](#). Pour plus d'informations sur la protection des données en Europe, consultez [le AWS Modèle de responsabilité partagée et article de GDPR](#) blog sur le AWS Blog sur la sécurité.

Pour des raisons de protection des données, nous vous recommandons de protéger AWS informations d'identification du compte et configuration de comptes individuels avec AWS Identity and Access Management (IAM). Ainsi, chaque utilisateur se voit attribuer uniquement les autorisations nécessaires pour exécuter ses tâches. Nous vous recommandons également de sécuriser vos données comme indiqué ci-dessous :

- Utilisez l'authentification multifactorielle (MFA) pour chaque compte.
- Utilisez SSL/TLS pour communiquer avec AWS ressources. Nous recommandons la version TLS 1.2 ou une version ultérieure.
- Configuration API et enregistrement de l'activité des utilisateurs avec AWS CloudTrail.
- Utiliser AWS solutions de chiffrement, ainsi que tous les contrôles de sécurité par défaut intégrés AWS services.
- Utilisez des services de sécurité gérés avancés tels qu'Amazon Macie, qui contribuent à la découverte et à la sécurisation des données personnelles stockées dans Amazon S3.
- Utilisez les options de chiffrement Amazon EMR Serverless pour chiffrer les données au repos et en transit.
- Si vous avez besoin de FIPS 140 à 2 modules cryptographiques validés pour accéder AWS via une interface de ligne de commande ou un API, utilisez un FIPS point de terminaison. Pour plus d'informations sur les FIPS points de terminaison disponibles, voir [Federal Information Processing Standard \(FIPS\) 140-2](#).

Nous vous recommandons vivement de ne jamais placer d'informations identifiables sensibles, telles que les numéros de compte de vos clients, dans des champs de formulaire comme Nom. Cela inclut lorsque vous travaillez avec Amazon EMR Serverless ou un autre AWS les services utilisant la console API, AWS CLI, ou AWS SDKs. Toutes les données que vous entrez dans Amazon EMR Serverless ou dans d'autres services peuvent être récupérées pour être incluses dans les journaux de diagnostic. Lorsque vous fournissez un URL à un serveur externe, n'incluez pas d'informations d'identification dans le URL pour valider votre demande auprès de ce serveur.

## Chiffrement au repos

Le chiffrement des données vous permet d'empêcher les utilisateurs non autorisés de lire les données d'un cluster et celles des systèmes de stockage de données associés. Cela inclut les données enregistrées sur les supports persistants (données au repos) et les données qui peuvent être interceptées alors qu'elles circulent sur le réseau (données en transit).

Le chiffrement des données nécessite des clés et des certificats. Vous pouvez choisir parmi plusieurs options, notamment les clés gérées par AWS Key Management Service, les clés gérées par Amazon S3 et les clés et certificats des fournisseurs personnalisés que vous fournissez. Lors de l'utilisation AWS KMS en tant que fournisseur de clés, des frais s'appliquent pour le stockage et l'utilisation des clés de chiffrement. Pour plus d'informations, consultez [.AWS KMS tarification](#).

Avant d'indiquer les options de chiffrement, choisissez les systèmes de gestion des clés et des certificats que vous souhaitez utiliser. Créez ensuite les clés et les certificats pour les fournisseurs personnalisés que vous indiquez dans le cadre des paramètres de chiffrement.

### Chiffrement au repos pour EMRFS les données dans Amazon S3

Chaque application EMR sans serveur utilise une version de version spécifique, qui inclut EMRFS (système de EMR fichiers). Le chiffrement Amazon S3 fonctionne avec les objets EMR File System (EMRFS) lus et écrits sur Amazon S3. Vous pouvez spécifier le chiffrement côté serveur (SSE) ou le chiffrement côté client ( ) Amazon S3 comme mode de chiffrement par défaut lorsque vous activez le chiffrement au repos. CSE Le cas échéant, vous pouvez spécifier différentes méthodes de chiffrement pour les compartiments individuels à l'aide de remplacements de chiffrement par compartiment. Que le chiffrement Amazon S3 soit activé ou non, Transport Layer Security (TLS) chiffre les EMRFS objets en transit entre les nœuds EMR du cluster et Amazon S3. Si vous utilisez Amazon S3 CSE avec des clés gérées par le client, votre rôle d'exécution utilisé pour exécuter des tâches dans une application EMR sans serveur doit avoir accès à la clé. Pour obtenir des informations détaillées sur le chiffrement Amazon S3, consultez la section [Protection des données à l'aide du chiffrement](#) dans le manuel Amazon Simple Storage Service Developer Guide.

#### Note

Lorsque vous utilisez AWS KMS, des frais s'appliquent pour le stockage et l'utilisation des clés de chiffrement. Pour plus d'informations, consultez [.AWS KMS tarification](#).

## Chiffrement côté serveur sur Amazon S3

Lorsque vous configurez le chiffrement côté serveur sur Amazon S3, Amazon S3 chiffre les données au niveau de l'objet au moment où elles sont écrites sur le disque et déchiffre les données lorsqu'elles sont accédées. Pour plus d'informations SSE, consultez la section [Protection des données à l'aide du chiffrement côté serveur dans le manuel Amazon Simple Storage Service Developer Guide](#).

Vous pouvez choisir entre deux systèmes de gestion de clés différents lorsque vous le spécifiez SSE dans Amazon EMR Serverless :

- SSE-S3 - Amazon S3 gère les clés pour vous. Aucune configuration supplémentaire n'est requise sur EMR Serverless.
- SSE-KMS - Vous utilisez un AWS KMS key à configurer avec des politiques adaptées à EMR Serverless. Aucune configuration supplémentaire n'est requise sur EMR Serverless.

Pour utiliser AWS KMS pour chiffrer les données que vous écrivez sur Amazon S3, deux options s'offrent à vous lorsque vous utilisez le `StartJobRunAPI`. Vous pouvez soit activer le chiffrement pour tout ce que vous écrivez sur Amazon S3, soit activer le chiffrement pour les données que vous écrivez dans un compartiment spécifique. Pour plus d'informations sur le `StartJobRunAPI`, consultez le manuel [EMRServerless API Reference](#).

Pour activer AWS KMS pour chiffrer toutes les données que vous écrivez sur Amazon S3, utilisez les commandes suivantes lorsque vous appelez le `StartJobRunAPI`.

```
--conf spark.hadoop.fs.s3.enableServerSideEncryption=true
--conf spark.hadoop.fs.s3.serverSideEncryption.kms.keyId=<kms_id>
```

Pour activer AWS KMS pour chiffrer les données que vous écrivez dans un compartiment spécifique, utilisez les commandes suivantes lorsque vous appelez le `StartJobRunAPI`.

```
--conf spark.hadoop.fs.s3.bucket.<DOC-EXAMPLE-BUCKET>.enableServerSideEncryption=true
--conf spark.hadoop.fs.s3.bucket.<DOC-EXAMPLE-BUCKET>.serverSideEncryption.kms.keyId=<kms-id>
```

SSE avec des clés fournies par le client (SSE-C) n'est pas disponible pour une utilisation avec Serverless. EMR

## Chiffrement côté client sur Amazon S3

Avec le chiffrement côté client d'Amazon S3, le chiffrement et le déchiffrement d'Amazon S3 ont lieu dans le EMRFS client disponible sur chaque version d'Amazon. EMR Les objets sont chiffrés avant d'être chargés sur Amazon S3 et déchiffrés après leur chargement. Le fournisseur que vous indiquez fournit la clé de chiffrement utilisée par le client. Le client peut utiliser les clés fournies par AWS KMS (CSE-KMS) ou une classe Java personnalisée qui fournit la clé racine côté client (CSE-C). Les spécificités du chiffrement sont légèrement différentes entre CSE - KMS et CSE -C, selon le fournisseur spécifié et les métadonnées de l'objet déchiffré ou chiffré. Si vous utilisez Amazon S3 CSE avec des clés gérées par le client, votre rôle d'exécution utilisé pour exécuter des tâches dans une application EMR sans serveur doit avoir accès à la clé. Des KMS frais supplémentaires peuvent s'appliquer. Pour plus d'informations sur ces différences, consultez la section [Protection des données à l'aide du chiffrement côté client dans le](#) manuel Amazon Simple Storage Service Developer Guide.

## Chiffrement de disque local

Les données stockées dans un stockage éphémère sont cryptées à l'aide de clés appartenant au service à l'aide de l'algorithme cryptographique standard AES -256.

## Gestion des clés

Vous pouvez configurer KMS pour faire pivoter automatiquement vos KMS touches. Ce système permet d'effectuer une rotation de vos clés une fois par an tout en conservant indéfiniment les anciennes clés, afin que vos données puissent toujours être déchiffrées. Pour plus d'informations, voir [Rotation des clés principales du client](#).

## Chiffrement en transit

Les fonctionnalités de chiffrement spécifiques aux applications suivantes sont disponibles avec Amazon EMR Serverless :

- Spark
  - Par défaut, la communication entre les pilotes Spark et les exécuteurs est authentifiée et interne. RPCla communication entre les pilotes et les exécuteurs est cryptée.
- Hive
  - Communication entre AWS Les applications Glue Metastore et EMR Serverless se font via. TLS



Vous devez autoriser uniquement les connexions chiffrées via HTTPS (TLS) en utilisant [la SecureTransport condition aws](#) : des IAM politiques relatives aux compartiments Amazon S3.

## Identity and Access Management (IAM) dans Amazon EMR Serverless

AWS Identity and Access Management (IAM) est un Service AWS qui permet à un administrateur de contrôler en toute sécurité l'accès à AWS ressources. IAMles administrateurs contrôlent qui peut être authentifié (connecté) et autorisé (autorisé) à utiliser les ressources Amazon EMR Serverless. IAMest un Service AWS que vous pouvez utiliser sans frais supplémentaires.

### Rubriques

- [Public ciblé](#)
- [Authentification par des identités](#)
- [Gestion des accès à l'aide de politiques](#)
- [Comment fonctionne EMR Serverless avec IAM](#)
- [Utilisation de rôles liés à un service pour Serverless EMR](#)
- [Rôles d'exécution des tâches pour Amazon EMR Serverless](#)
- [Exemples de politiques d'accès utilisateur pour EMR Serverless](#)
- [Politiques de contrôle d'accès basées sur les balises](#)
- [Exemples de politiques basées sur l'identité pour Serverless EMR](#)
- [Mises à jour Amazon EMR Serverless vers AWS stratégies gérées](#)
- [Résolution des problèmes d'identité et d'EMRaccès Amazon Serverless](#)

### Public ciblé

Comment utilisez-vous AWS Identity and Access Management (IAM) diffère en fonction du travail que vous effectuez dans Amazon EMR Serverless.

Utilisateur du service : si vous utilisez le service Amazon EMR Serverless pour effectuer votre travail, votre administrateur vous fournit les informations d'identification et les autorisations dont vous avez besoin. Au fur et à mesure que vous utilisez de plus en plus de fonctionnalités Amazon EMR Serverless pour effectuer votre travail, vous aurez peut-être besoin d'autorisations supplémentaires. En comprenant bien la gestion des accès, vous saurez demander les autorisations appropriées

à votre administrateur. Si vous ne pouvez pas accéder à une fonctionnalité dans Amazon EMR Serverless, consultez [Résolution des problèmes d'identité et d'EMR Accès Amazon Serverless](#).

**Administrateur du service** — Si vous êtes responsable des ressources Amazon EMR Serverless au sein de votre entreprise, vous avez probablement un accès complet à Amazon EMR Serverless. C'est à vous de déterminer les fonctionnalités et ressources Amazon EMR Serverless auxquelles les utilisateurs de votre service doivent accéder. Vous devez ensuite envoyer des demandes à votre IAM administrateur pour modifier les autorisations des utilisateurs de votre service. Consultez les informations de cette page pour comprendre les concepts de base de IAM. Pour en savoir plus sur la manière dont votre entreprise peut utiliser IAM Amazon EMR Serverless, consultez [Identity and Access Management \(IAM\) dans Amazon EMR Serverless](#).

**IAM administrateur** — Si vous êtes IAM administrateur, vous souhaitez peut-être en savoir plus sur la manière dont vous pouvez rédiger des politiques pour gérer l'accès à Amazon EMR Serverless. Pour consulter des exemples de politiques basées sur l'identité Amazon EMR Serverless que vous pouvez utiliser, consultez IAM [Exemples de politiques basées sur l'identité pour Serverless EMR](#)

## Authentification par des identités

L'authentification est la façon dont vous vous connectez à AWS en utilisant vos informations d'identification. Vous devez être authentifié (connecté) à AWS) en tant que Utilisateur racine d'un compte AWS, en tant qu'IAM utilisateur ou en assumant un IAM rôle.

Vous pouvez vous connecter à AWS en tant qu'identité fédérée en utilisant les informations d'identification fournies par le biais d'une source d'identité. AWS IAM Identity Center Les utilisateurs (IAM Identity Center), l'authentification unique de votre entreprise et vos informations d'identification Google ou Facebook sont des exemples d'identités fédérées. Lorsque vous vous connectez en tant qu'identité fédérée, votre administrateur a préalablement configuré la fédération d'identité à l'aide de IAM rôles. Lorsque vous accédez AWS en utilisant la fédération, vous assumez indirectement un rôle.

Selon le type d'utilisateur que vous êtes, vous pouvez vous connecter au AWS Management Console ou le AWS portail d'accès. Pour plus d'informations sur la connexion à AWS, voir [Comment se connecter à votre Compte AWS](#) dans le .Connexion à AWS Guide de l'utilisateur.

Si vous accédez AWS programmatically, AWS fournit un kit de développement logiciel (SDK) et une interface de ligne de commande (CLI) pour signer cryptographiquement vos demandes à l'aide de vos informations d'identification. Si vous n'utilisez pas AWS outils, vous devez signer vous-même les demandes. Pour plus d'informations sur l'utilisation de la méthode recommandée pour signer vous-même les demandes, voir [Signature AWS API demandes](#) dans le guide de IAM l'utilisateur.

Quelle que soit la méthode d'authentification que vous utilisez, vous devrez peut-être fournir des informations de sécurité supplémentaires. Par exemple, AWS vous recommande d'utiliser l'authentification multifactorielle (MFA) pour renforcer la sécurité de votre compte. Pour en savoir plus, consultez la section [Authentification multifactorielle](#) dans le AWS IAM Identity Center Guide de l'utilisateur et [utilisation de l'authentification multifactorielle \(MFA\) dans AWS](#) dans le guide de l'utilisateur IAM.

## Compte AWS utilisateur root

Lorsque vous créez un Compte AWS, vous commencez avec une seule identité de connexion qui donne un accès complet à tous Services AWS et les ressources du compte. Cette identité s'appelle Compte AWS utilisateur root et est accessible en vous connectant avec l'adresse e-mail et le mot de passe que vous avez utilisés pour créer le compte. Il est vivement recommandé de ne pas utiliser l'utilisateur racine pour vos tâches quotidiennes. Protégez vos informations d'identification d'utilisateur racine et utilisez-les pour effectuer les tâches que seul l'utilisateur racine peut effectuer. Pour obtenir la liste complète des tâches qui nécessitent que vous vous connectiez en tant qu'utilisateur root, consultez la section [Tâches nécessitant des informations d'identification utilisateur root](#) dans le Guide de IAM l'utilisateur.

## Identité fédérée

La meilleure pratique consiste à obliger les utilisateurs humains, y compris ceux qui ont besoin d'un accès administrateur, à utiliser la fédération avec un fournisseur d'identité pour accéder Services AWS en utilisant des informations d'identification temporaires.

Une identité fédérée est un utilisateur de l'annuaire des utilisateurs de votre entreprise, un fournisseur d'identité Web, le AWS Directory Service, le répertoire Identity Center ou tout utilisateur accédant Services AWS en utilisant les informations d'identification fournies par le biais d'une source d'identité. Lorsque les identités fédérées accèdent Comptes AWS, ils assument des rôles, et les rôles fournissent des informations d'identification temporaires.

Pour une gestion centralisée des accès, nous vous recommandons d'utiliser AWS IAM Identity Center. Vous pouvez créer des utilisateurs et des groupes dans IAM Identity Center, ou vous pouvez vous connecter et synchroniser avec un ensemble d'utilisateurs et de groupes dans votre propre source d'identité afin de les utiliser dans tous vos Comptes AWS et applications. Pour plus d'informations sur IAM Identity Center, consultez [Qu'est-ce qu'IAM Identity Center ?](#) dans le AWS IAM Identity Center Guide de l'utilisateur.

## Utilisateurs et groupes IAM

Un [IAMutilisateur](#) est une identité au sein de votre Compte AWS qui dispose d'autorisations spécifiques pour une seule personne ou une seule application. Dans la mesure du possible, nous vous recommandons de vous appuyer sur des informations d'identification temporaires plutôt que de créer des IAM utilisateurs dotés d'informations d'identification à long terme, telles que des mots de passe et des clés d'accès. Toutefois, si vous avez des cas d'utilisation spécifiques qui nécessitent des informations d'identification à long terme auprès des IAM utilisateurs, nous vous recommandons de faire pivoter les clés d'accès. Pour plus d'informations, voir [Rotation régulière des clés d'accès pour les cas d'utilisation nécessitant des informations d'identification à long terme](#) dans le Guide de IAM l'utilisateur.

Un [IAMgroupe](#) est une identité qui définit un ensemble d'IAMutilisateurs. Vous ne pouvez pas vous connecter en tant que groupe. Vous pouvez utiliser les groupes pour spécifier des autorisations pour plusieurs utilisateurs à la fois. Les groupes permettent de gérer plus facilement les autorisations pour de grands ensembles d'utilisateurs. Par exemple, vous pouvez nommer un groupe IAMAdminset lui donner les autorisations nécessaires pour administrer IAM des ressources.

Les utilisateurs sont différents des rôles. Un utilisateur est associé de manière unique à une personne ou une application, alors qu'un rôle est conçu pour être endossé par tout utilisateur qui en a besoin. Les utilisateurs disposent d'informations d'identification permanentes, mais les rôles fournissent des informations d'identification temporaires. Pour en savoir plus, voir [Quand créer un IAM utilisateur \(au lieu d'un rôle\)](#) dans le Guide de IAM l'utilisateur.

## IAMrôles

Un [IAMrôle](#) est une identité au sein de votre Compte AWS qui dispose d'autorisations spécifiques. Il est similaire à un IAM utilisateur, mais n'est pas associé à une personne en particulier. Vous pouvez assumer temporairement un IAM rôle dans AWS Management Console en [changeant de rôle](#). Vous pouvez assumer un rôle en appelant un AWS CLI or AWS APIopération ou en utilisant une option personnaliséeURL. Pour plus d'informations sur les méthodes d'utilisation des rôles, consultez la section [Utilisation IAM des rôles](#) dans le Guide de IAM l'utilisateur.

IAMles rôles dotés d'informations d'identification temporaires sont utiles dans les situations suivantes :

- **Accès utilisateur fédéré** : pour attribuer des autorisations à une identité fédérée, vous créez un rôle et définissez des autorisations pour le rôle. Quand une identité externe s'authentifie, l'identité est associée au rôle et reçoit les autorisations qui sont définies par celui-ci. Pour plus

d'informations sur les rôles pour la fédération, voir [Création d'un rôle pour un fournisseur d'identité tiers](#) dans le guide de IAM l'utilisateur. Si vous utilisez IAM Identity Center, vous configurez un ensemble d'autorisations. Pour contrôler les accès auxquels vos identités peuvent accéder après leur authentification, IAM Identity Center met en corrélation l'ensemble d'autorisations avec un rôle dans. IAM Pour plus d'informations sur les ensembles d'autorisations, voir [Ensembles d'autorisations](#) dans le AWS IAM Identity Center Guide de l'utilisateur.

- Autorisations IAM utilisateur temporaires : un IAM utilisateur ou un rôle peut assumer un IAM rôle afin d'obtenir temporairement différentes autorisations pour une tâche spécifique.
- Accès entre comptes : vous pouvez utiliser un IAM rôle pour autoriser une personne (un mandant fiable) d'un autre compte à accéder aux ressources de votre compte. Les rôles constituent le principal moyen d'accorder l'accès intercompte. Cependant, avec certains Services AWS, vous pouvez associer une politique directement à une ressource (au lieu d'utiliser un rôle comme proxy). Pour connaître la différence entre les rôles et les politiques basées sur les ressources pour l'accès entre comptes, voir Accès aux [ressources entre comptes IAM dans le guide](#) de l'IAM utilisateur.
- Accès multiservices — Certains Services AWS utilisent des fonctionnalités dans d'autres Services AWS. Par exemple, lorsque vous effectuez un appel dans un service, il est courant que ce service exécute des applications dans Amazon EC2 ou stocke des objets dans Amazon S3. Un service peut le faire en utilisant les autorisations d'appel du principal, un rôle de service ou un rôle lié au service.
- Sessions d'accès transmises (FAS) : lorsque vous utilisez un IAM utilisateur ou un rôle pour effectuer des actions dans AWS, vous êtes considéré comme un directeur. Lorsque vous utilisez certains services, vous pouvez effectuer une action qui initie une autre action dans un autre service. FAS utilise les autorisations du principal appelant un Service AWS, combiné à la demande Service AWS pour adresser des demandes aux services en aval. FAS les demandes ne sont effectuées que lorsqu'un service reçoit une demande nécessitant des interactions avec d'autres Services AWS ou des ressources à compléter. Dans ce cas, vous devez disposer d'autorisations nécessaires pour effectuer les deux actions. Pour plus de détails sur les politiques relatives FAS aux demandes, consultez la section [Transférer les sessions d'accès](#).
- Rôle de service — Un rôle de service est un [IAM rôle](#) qu'un service assume pour effectuer des actions en votre nom. Un IAM administrateur peut créer, modifier et supprimer un rôle de service de l'intérieur IAM. Pour plus d'informations, voir [Création d'un rôle pour déléguer des autorisations à un Service AWS](#) dans le guide de l'utilisateur IAM.
- Rôle lié à un service — Un rôle lié à un service est un type de rôle lié à un service Service AWS. Le service peut assumer le rôle d'effectuer une action en votre nom. Les rôles liés à un service

apparaissent dans votre Compte AWS et appartiennent au service. Un IAM administrateur peut consulter, mais pas modifier les autorisations pour les rôles liés à un service.

- Applications exécutées sur Amazon EC2 : vous pouvez utiliser un IAM rôle pour gérer les informations d'identification temporaires pour les applications qui s'exécutent sur une EC2 instance et qui créent AWS CLI or AWS API demandes. Cela est préférable au stockage des clés d'accès dans l'EC2 instance. Pour attribuer un AWS pour attribuer un rôle à une EC2 instance et le mettre à la disposition de toutes ses applications, vous créez un profil d'instance attaché à l'instance. Un profil d'instance contient le rôle et permet aux programmes exécutés sur l'EC2 instance d'obtenir des informations d'identification temporaires. Pour plus d'informations, consultez la section [Utilisation d'un IAM rôle pour accorder des autorisations aux applications exécutées sur des EC2 instances Amazon](#) dans le Guide de IAM l'utilisateur.

Pour savoir s'il faut utiliser IAM des rôles ou des IAM utilisateurs, voir [Quand créer un IAM rôle \(au lieu d'un utilisateur\)](#) dans le guide de IAM l'utilisateur.

## Gestion des accès à l'aide de politiques

Vous contrôlez l'accès dans AWS en créant des politiques et en les associant à AWS identités ou ressources. Une politique est un objet dans AWS qui, lorsqu'elle est associée à une identité ou à une ressource, définit leurs autorisations. AWS évalue ces politiques lorsqu'un principal (utilisateur, utilisateur root ou session de rôle) fait une demande. Les autorisations dans les politiques déterminent si la demande est autorisée ou refusée. La plupart des politiques sont stockées dans AWS sous forme de JSON documents. Pour plus d'informations sur la structure et le contenu des documents de JSON politique, voir [Présentation des JSON politiques](#) dans le guide de IAM l'utilisateur.

Les administrateurs peuvent utiliser AWS JSON politiques pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

Par défaut, les utilisateurs et les rôles ne disposent d'aucune autorisation. Pour autoriser les utilisateurs à effectuer des actions sur les ressources dont ils ont besoin, un IAM administrateur peut créer des IAM politiques. L'administrateur peut ensuite ajouter les IAM politiques aux rôles, et les utilisateurs peuvent assumer les rôles.

IAM les politiques définissent les autorisations pour une action, quelle que soit la méthode que vous utilisez pour effectuer l'opération. Par exemple, supposons que vous disposiez d'une politique qui autorise l'action `iam:GetRole`. Un utilisateur appliquant cette politique peut obtenir des informations sur le rôle auprès du AWS Management Console, le AWS CLI, ou le AWS API.

## Politiques basées sur l'identité

Les politiques basées sur l'identité sont JSON des documents de politique d'autorisation que vous pouvez joindre à une identité, telle qu'un IAM utilisateur, un groupe d'utilisateurs ou un rôle. Ces politiques contrôlent quel type d'actions des utilisateurs et des rôles peuvent exécuter, sur quelles ressources et dans quelles conditions. Pour savoir comment créer une politique basée sur l'identité, consultez la section [Création de IAM politiques](#) dans le Guide de l'IAMutilisateur.

Les politiques basées sur l'identité peuvent être classées comme des politiques en ligne ou des politiques gérées. Les politiques en ligne sont intégrées directement à un utilisateur, groupe ou rôle. Les politiques gérées sont des politiques autonomes que vous pouvez associer à plusieurs utilisateurs, groupes et rôles dans votre Compte AWS. Les politiques gérées incluent AWS politiques gérées et politiques gérées par le client. Pour savoir comment choisir entre une politique gérée ou une politique intégrée, voir [Choisir entre des politiques gérées et des politiques intégrées dans le Guide](#) de l'IAMutilisateur.

## Politiques basées sur les ressources

Les politiques basées sur les ressources sont des documents JSON de stratégie que vous attachez à une ressource. Les politiques de confiance dans les IAM rôles et les politiques relatives aux compartiments Amazon S3 sont des exemples de politiques basées sur les ressources. Dans les services qui sont compatibles avec les politiques basées sur les ressources, les administrateurs de service peuvent les utiliser pour contrôler l'accès à une ressource spécifique. Pour la ressource dans laquelle se trouve la politique, cette dernière définit quel type d'actions un principal spécifié peut effectuer sur cette ressource et dans quelles conditions. Vous devez [spécifier un principal](#) dans une politique basée sur les ressources. Les principaux peuvent inclure des comptes, des utilisateurs, des rôles, des utilisateurs fédérés ou Services AWS.

Les politiques basées sur les ressources sont des politiques en ligne situées dans ce service. Vous ne pouvez pas utiliser AWS politiques gérées à partir IAM d'une stratégie basée sur les ressources.

## Listes de contrôle d'accès (ACLs)

Les listes de contrôle d'accès (ACLs) contrôlent les principaux (membres du compte, utilisateurs ou rôles) autorisés à accéder à une ressource. ACLs sont similaires aux politiques basées sur les ressources, bien qu'elles n'utilisent pas le format du document JSON de stratégie.

Amazon S3 AWS WAF, et Amazon VPC sont des exemples de services qui prennent en charge ACLs. Pour en savoir plus ACLs, consultez la [présentation de la liste de contrôle d'accès \(ACL\)](#) dans le guide du développeur Amazon Simple Storage Service.



## Autres types de politique

AWS prend en charge d'autres types de politiques moins courants. Ces types de politiques peuvent définir le nombre maximum d'autorisations qui vous sont accordées par des types de politiques plus courants.

- **Limites d'autorisations** — Une limite d'autorisations est une fonctionnalité avancée dans laquelle vous définissez le maximum d'autorisations qu'une politique basée sur l'identité peut accorder à une IAM entité (IAMutilisateur ou rôle). Vous pouvez définir une limite d'autorisations pour une entité. Les autorisations en résultant représentent la combinaison des politiques basées sur l'identité d'une entité et de ses limites d'autorisation. Les politiques basées sur les ressources qui spécifient l'utilisateur ou le rôle dans le champ `Principal` ne sont pas limitées par les limites d'autorisations. Un refus explicite dans l'une de ces politiques annule l'autorisation. Pour plus d'informations sur les limites d'autorisations, voir [Limites d'autorisations pour les IAM entités](#) dans le Guide de IAM l'utilisateur.
- **Politiques de contrôle des services (SCPs)** : SCPs JSON politiques qui spécifient les autorisations maximales pour une organisation ou une unité organisationnelle (UO) dans AWS Organizations. AWS Organizations est un service de regroupement et de gestion centralisée de plusieurs Comptes AWS que votre entreprise possède. Si vous activez toutes les fonctionnalités d'une organisation, vous pouvez appliquer des politiques de contrôle des services (SCPs) à l'un ou à l'ensemble de vos comptes. Les SCP limites d'autorisations pour les entités figurant dans les comptes des membres, y compris chaque Utilisateur racine d'un compte AWS. Pour plus d'informations sur les Organizations et SCPs consultez les [politiques de contrôle des services](#) dans le AWS Organizations Guide de l'utilisateur.
- **Politiques de séance** : les politiques de séance sont des politiques avancées que vous utilisez en tant que paramètre lorsque vous créez par programmation une séance temporaire pour un rôle ou un utilisateur fédéré. Les autorisations de séance en résultant sont une combinaison des politiques basées sur l'identité de l'utilisateur ou du rôle et des politiques de séance. Les autorisations peuvent également provenir d'une politique basée sur les ressources. Un refus explicite dans l'une de ces politiques annule l'autorisation. Pour plus d'informations, consultez la section [Politiques de session](#) dans le guide de IAM l'utilisateur.

## Plusieurs types de politique

Lorsque plusieurs types de politiques s'appliquent à la requête, les autorisations en résultant sont plus compliquées à comprendre. Pour savoir comment AWS détermine s'il faut autoriser une



demande lorsque plusieurs types de politiques sont impliqués, voir la [logique d'évaluation des politiques](#) dans le guide de IAM l'utilisateur.

## Comment fonctionne EMR Serverless avec IAM

Avant de commencer IAM à gérer l'accès à Amazon EMR Serverless, découvrez quelles IAM fonctionnalités peuvent être utilisées avec Amazon EMR Serverless.

IAM fonctionnalités que vous pouvez utiliser avec EMR Serverless

IAM fonctionnalité	Support Amazon EMR Serverless
<a href="#">Politiques basées sur l'identité</a>	Oui
<a href="#">Politiques basées sur les ressources</a>	Non
<a href="#">Actions de politique</a>	Oui
<a href="#">Ressources de politique</a>	Oui
<a href="#">Clés de condition d'une politique</a>	Non
<a href="#">ACLs</a>	Non
<a href="#">ABAC(balises dans les politiques)</a>	Oui
<a href="#">Informations d'identification temporaires</a>	Oui
<a href="#">Autorisations de principal</a>	Oui
<a href="#">Fonctions du service</a>	Non
<a href="#">Rôles liés à un service</a>	Oui

Pour obtenir une vue d'ensemble de la façon dont EMR Serverless et autres AWS les services fonctionnent avec la plupart IAM des fonctionnalités, voir [AWS services compatibles avec IAM](#) le Guide de l'IAM utilisateur.

## Politiques basées sur l'identité pour Serverless EMR

Prend en charge les politiques basées sur l'identité : oui

Les politiques basées sur l'identité sont JSON des documents de politique d'autorisation que vous pouvez joindre à une identité, telle qu'un IAM utilisateur, un groupe d'utilisateurs ou un rôle. Ces politiques contrôlent quel type d'actions des utilisateurs et des rôles peuvent exécuter, sur quelles ressources et dans quelles conditions. Pour savoir comment créer une politique basée sur l'identité, consultez la section [Création de IAM politiques](#) dans le Guide de l'IAMutilisateur.

Avec les politiques IAM basées sur l'identité, vous pouvez spécifier les actions et les ressources autorisées ou refusées ainsi que les conditions dans lesquelles les actions sont autorisées ou refusées. Vous ne pouvez pas spécifier le principal dans une politique basée sur une identité, car celle-ci s'applique à l'utilisateur ou au rôle auquel elle est attachée. Pour en savoir plus sur tous les éléments que vous pouvez utiliser dans une JSON politique, consultez la [référence aux éléments de IAM JSON politique](#) dans le Guide de IAM l'utilisateur.

Exemples de politiques basées sur l'identité pour Serverless EMR

Pour consulter des exemples de politiques basées sur l'identité Amazon EMR Serverless, consultez. [Exemples de politiques basées sur l'identité pour Serverless EMR](#)

## Politiques basées sur les ressources dans Serverless EMR

Prend en charge les politiques basées sur les ressources : non

Les politiques basées sur les ressources sont des documents JSON de stratégie que vous attachez à une ressource. Les politiques de confiance dans les IAM rôles et les politiques relatives aux compartiments Amazon S3 sont des exemples de politiques basées sur les ressources. Dans les services qui sont compatibles avec les politiques basées sur les ressources, les administrateurs de service peuvent les utiliser pour contrôler l'accès à une ressource spécifique. Pour la ressource dans laquelle se trouve la politique, cette dernière définit quel type d'actions un principal spécifié peut effectuer sur cette ressource et dans quelles conditions. Vous devez [spécifier un principal](#) dans une politique basée sur les ressources. Les principaux peuvent inclure des comptes, des utilisateurs, des rôles, des utilisateurs fédérés ou Services AWS.

Pour activer l'accès entre comptes, vous pouvez spécifier un compte entier ou IAM des entités d'un autre compte comme principal dans une politique basée sur les ressources. L'ajout d'un principal entre comptes à une politique basée sur les ressources ne représente qu'une partie de l'instauration de la relation d'approbation. Lorsque le principal et la ressource sont différents Comptes AWS, un IAM administrateur du compte sécurisé doit également accorder à l'entité principale (utilisateur ou rôle) l'autorisation d'accéder à la ressource. Pour ce faire, il attache une politique basée sur une identité à l'entité. Toutefois, si une politique basée sur des ressources accorde l'accès à un

principal dans le même compte, aucune autre politique basée sur l'identité n'est requise. Pour plus d'informations, voir [Accès aux ressources entre comptes IAM dans](#) le Guide de IAM l'utilisateur.

## Actions stratégiques pour le mode EMR Serverless

Prend en charge les actions de politique : oui

Les administrateurs peuvent utiliser AWS JSONpolitiques pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'Actionélément d'une JSON politique décrit les actions que vous pouvez utiliser pour autoriser ou refuser l'accès dans une politique. Les actions politiques portent généralement le même nom que les actions associées AWS APIopération. Il existe certaines exceptions, telles que les actions avec autorisation uniquement qui n'ont pas d'opération correspondante. API Certaines opérations nécessitent également plusieurs actions dans une politique. Ces actions supplémentaires sont nommées actions dépendantes.

Intégration d'actions dans une politique afin d'accorder l'autorisation d'exécuter les opérations associées.

Pour consulter la liste des actions EMR sans serveur, consultez la section [Actions, ressources et clés de condition pour Amazon EMR Serverless](#) dans le Service Authorization Reference.

Les actions de stratégie dans EMR Serverless utilisent le préfixe suivant avant l'action.

```
emr-serverless
```

Pour indiquer plusieurs actions dans une seule déclaration, séparez-les par des virgules.

```
"Action": [  
  "emr-serverless:action1",  
  "emr-serverless:action2"  
]
```

Pour consulter des exemples de politiques basées sur l'identité Amazon EMR Serverless, consultez. [Exemples de politiques basées sur l'identité pour Serverless EMR](#)

## Ressources relatives aux politiques pour le mode EMR Serverless

Prend en charge les ressources de politique : oui

Les administrateurs peuvent utiliser AWS JSONpolitiques pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'élément `Resource` JSON de stratégie indique le ou les objets auxquels s'applique l'action. Les instructions doivent inclure un élément `Resource` ou `NotResource`. Il est recommandé de spécifier une ressource en utilisant son [Amazon Resource Name \(ARN\)](#). Vous pouvez le faire pour des actions qui prennent en charge un type de ressource spécifique, connu sous la dénomination autorisations de niveau ressource.

Pour les actions qui ne sont pas compatibles avec les autorisations de niveau ressource, telles que les opérations de liste, utilisez un caractère générique (\*) afin d'indiquer que l'instruction s'applique à toutes les ressources.

```
"Resource": "*" 
```

Pour consulter la liste des types de ressources Amazon EMR Serverless et leurs caractéristiquesARNs, consultez la section [Ressources définies par Amazon EMR Serverless](#) dans le Service Authorization Reference. Pour savoir quelles actions vous pouvez spécifier pour chaque ressource, consultez [Actions, ressources et clés de condition pour Amazon EMR Serverless](#). ARN

Pour consulter des exemples de politiques basées sur l'identité Amazon EMR Serverless, consultez. [Exemples de politiques basées sur l'identité pour Serverless EMR](#)

## Clés de conditions de politique pour EMR Serverless

Prend en charge les clés de condition de politique spécifiques au service	Non
---	-----

Les administrateurs peuvent utiliser AWS JSONpolitiques pour spécifier qui a accès à quoi. C'est-à-dire, quel principal peut effectuer des actions sur quelles ressources et dans quelles conditions.

L'élément `Condition` (ou le bloc `Condition`) vous permet de spécifier des conditions lorsqu'une instruction est appliquée. L'élément `Condition` est facultatif. Vous pouvez créer des expressions conditionnelles qui utilisent des [opérateurs de condition](#), tels que les signes égal ou inférieur à, pour faire correspondre la condition de la politique aux valeurs de la demande.

Si vous spécifiez plusieurs Condition éléments dans une instruction ou plusieurs clés dans un seul Condition élément, AWS les évalue à l'aide d'une AND opération logique. Si vous spécifiez plusieurs valeurs pour une seule clé de condition, AWS évalue la condition à l'aide d'une OR opération logique. Toutes les conditions doivent être remplies avant que les autorisations associées à l'instruction ne soient accordées.

Vous pouvez aussi utiliser des variables d'espace réservé quand vous spécifiez des conditions. Par exemple, vous pouvez autoriser un IAM utilisateur à accéder à une ressource uniquement si celle-ci est étiquetée avec son nom IAM d'utilisateur. Pour plus d'informations, consultez [IAM la section Éléments de politique : variables et balises](#) dans le Guide de IAM l'utilisateur.

AWS prend en charge les clés de condition globales et les clés de condition spécifiques au service. Pour tout voir AWS clés de condition globales, voir [AWS clés contextuelles des conditions globales](#) dans le guide de IAM l'utilisateur.

Pour consulter la liste des clés de condition Amazon EMR Serverless et pour savoir quelles actions et ressources vous pouvez utiliser une clé de condition, consultez la section [Actions, ressources et clés de condition pour Amazon EMR Serverless](#) dans le Service Authorization Reference.

Toutes les EC2 actions Amazon prennent en charge les clés de `ec2:Region` condition `aws:RequestedRegion` et. Pour plus d'informations, voir [Exemple : restriction de l'accès à une région spécifique](#).

## Listes de contrôle d'accès (ACLs) dans EMR Serverless

Supports ACLs : Non

Les listes de contrôle d'accès (ACLs) contrôlent les principaux (membres du compte, utilisateurs ou rôles) autorisés à accéder à une ressource. ACLs sont similaires aux politiques basées sur les ressources, bien qu'elles n'utilisent pas le format du document JSON de stratégie.

## Contrôle d'accès basé sur les attributs (ABAC) avec Serverless EMR

Supports ABAC (balises dans les politiques)	Oui
---	-----

Le contrôle d'accès basé sur les attributs (ABAC) est une stratégie d'autorisation qui définit les autorisations en fonction des attributs. Entrée AWS, ces attributs sont appelés balises. Vous pouvez associer des tags à IAM des entités (utilisateurs ou rôles) et à de nombreuses AWS ressources. Le

balisage des entités et des ressources est la première étape de ABAC. Vous concevez ensuite des ABAC politiques pour autoriser les opérations lorsque le tag du principal correspond à celui de la ressource à laquelle il essaie d'accéder.

ABAC est utile dans les environnements qui se développent rapidement et aide dans les situations où la gestion des politiques devient fastidieuse.

Pour contrôler l'accès basé sur des étiquettes, vous devez fournir les informations d'étiquette dans l'[élément de condition](#) d'une politique utilisant les clés de condition `aws:ResourceTag/key-name`, `aws:RequestTag/key-name` ou `aws:TagKeys`.

Si un service prend en charge les trois clés de condition pour tous les types de ressources, alors la valeur pour ce service est Oui. Si un service prend en charge les trois clés de condition pour certains types de ressources uniquement, la valeur est Partielle.

Pour plus d'informations ABAC, voir [Qu'est-ce que c'est ABAC ?](#) dans le guide de IAM l'utilisateur. Pour consulter un didacticiel présentant les étapes de configuration ABAC, voir [Utiliser le contrôle d'accès basé sur les attributs \(ABAC\)](#) dans le guide de l'IAM utilisateur.

## Utilisation d'informations d'identification temporaires avec EMR Serverless

Prend en charge les informations d'identification temporaires : oui

Momentanée Services AWS ne fonctionnent pas lorsque vous vous connectez à l'aide d'informations d'identification temporaires. Pour plus d'informations, y compris lesquelles Services AWS utilisent des informations d'identification temporaires, voir [Services AWS qui fonctionnent avec IAM](#) le Guide de l'IAM utilisateur.

Vous utilisez des informations d'identification temporaires si vous vous connectez au AWS Management Console en utilisant n'importe quelle méthode, à l'exception du nom d'utilisateur et du mot de passe. Par exemple, lorsque vous accédez AWS à l'aide du lien d'authentification unique (SSO) de votre entreprise, ce processus crée automatiquement des informations d'identification temporaires. Vous créez également automatiquement des informations d'identification temporaires lorsque vous vous connectez à la console en tant qu'utilisateur, puis changez de rôle. Pour plus d'informations sur le changement de rôle, consultez la section [Passage à un rôle \(console\)](#) dans le guide de IAM l'utilisateur.

Vous pouvez créer manuellement des informations d'identification temporaires à l'aide du AWS CLI or AWS API. Vous pouvez ensuite utiliser ces informations d'identification temporaires pour

accéder AWS. AWS recommande de générer dynamiquement des informations d'identification temporaires au lieu d'utiliser des clés d'accès à long terme. Pour plus d'informations, consultez la section Informations [d'identification de sécurité temporaires dans IAM](#).

## Autorisations principales interservices pour Serverless EMR

Prend en charge les sessions d'accès transféré (FAS) : Oui

Lorsque vous utilisez un IAM utilisateur ou un rôle pour effectuer des actions dans AWS, vous êtes considéré comme un directeur. Lorsque vous utilisez certains services, vous pouvez effectuer une action qui initie une autre action dans un autre service. FAS utilise les autorisations du principal appelant un Service AWS, combiné à la demande Service AWS pour adresser des demandes aux services en aval. FAS les demandes ne sont effectuées que lorsqu'un service reçoit une demande nécessitant des interactions avec d'autres Services AWS ou des ressources à compléter. Dans ce cas, vous devez disposer d'autorisations nécessaires pour effectuer les deux actions. Pour plus de détails sur les politiques relatives FAS aux demandes, consultez la section [Transférer les sessions d'accès](#).

## Rôles de service pour EMR Serverless

Prend en charge les fonctions de service Non

## Rôles liés à un service pour Serverless EMR

Prend en charge les rôles liés à un service. Oui

Pour plus de détails sur la création ou la gestion des rôles liés à un service, voir [AWS services qui fonctionnent avec IAM](#). Recherchez un service dans le tableau qui inclut un Yes dans la colonne Rôle lié à un service. Choisissez le lien Oui pour consulter la documentation du rôle lié à ce service.

## Utilisation de rôles liés à un service pour Serverless EMR

Amazon EMR Serverless utilise AWS Identity and Access Management (IAM) rôles [liés aux services](#). Un rôle lié à un service est un type unique de IAM rôle directement lié à Serverless. EMR Les rôles liés au service sont prédéfinis par EMR Serverless et incluent toutes les autorisations dont le service a besoin pour appeler d'autres AWS services en votre nom.

Un rôle lié à un service facilite la configuration de EMR Serverless, car vous n'avez pas à ajouter manuellement les autorisations nécessaires. EMRServerless définit les autorisations associées à ses rôles liés aux services et, sauf indication contraire, seul EMR Serverless peut assumer ses rôles. Les autorisations définies incluent la politique de confiance et la politique d'autorisations, et cette politique d'autorisations ne peut être attachée à aucune autre IAM entité.

Vous pouvez supprimer un rôle lié à un service uniquement après la suppression préalable de ses ressources connexes. Cela protège vos ressources EMR sans serveur, car vous ne pouvez pas supprimer par inadvertance l'autorisation d'accès aux ressources.

Pour plus d'informations sur les autres services qui prennent en charge les rôles liés à un service, voir [AWS Services qui fonctionnent avec IAM](#) et recherchez les services dont la valeur Oui est indiquée dans la colonne Rôles liés aux services. Choisissez un Oui ayant un lien permettant de consulter les détails du rôle pour ce service.

## Autorisations de rôle liées au service pour Serverless EMR

EMRServerless utilise le rôle lié au service nommé `AWSServiceRoleForAmazonEMRServerless` pour lui permettre d'appeler AWS APIs en votre nom.

Le rôle `AWSServiceRoleForAmazonEMRServerless` lié à un service fait confiance aux services suivants pour assumer le rôle :

- `ops.emr-serverless.amazonaws.com`

La politique d'autorisation de rôle nommée `AmazonEMRServerlessServiceRolePolicy` permet à EMR Serverless d'effectuer les actions suivantes sur les ressources spécifiées.

### Note

Le contenu de la politique gérée étant modifié, la politique présentée ici est peut-être obsolète. Afficher la plus grande partie up-to-date de la politique [AmazonEMRServerless ServiceRolePolicy](#) dans le AWS Management Console.

- Action : `ec2:CreateNetworkInterface`
- Action : `ec2:DeleteNetworkInterface`
- Action : `ec2:DescribeNetworkInterfaces`
- Action : `ec2:DescribeSecurityGroups`



- Action : ec2:DescribeSubnets
- Action : ec2:DescribeVpcs
- Action : ec2:DescribeDhcpOptions
- Action : ec2:DescribeRouteTables
- Action : cloudwatch:PutMetricData

Voici la AmazonEMRServerlessServiceRolePolicy politique complète.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EC2PolicyStatement",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2>DeleteNetworkInterface",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeSubnets",
        "ec2:DescribeVpcs",
        "ec2:DescribeDhcpOptions",
        "ec2:DescribeRouteTables"
      ],
      "Resource": "*"
    },
    {
      "Sid": "CloudWatchPolicyStatement",
      "Effect": "Allow",
      "Action": [
        "cloudwatch:PutMetricData"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
          "cloudwatch:namespace": [
            "AWS/EMRServerless",
            "AWS/Usage"
          ]
        }
      }
    }
  ]
}
```

```

    }
  }
]
}

```

La politique de confiance suivante est attachée à ce rôle pour permettre au principal EMR Serverless d'assumer ce rôle.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": [
          "ops.emr-serverless.amazonaws.com"
        ]
      },
      "Action": "sts:AssumeRole"
    }
  ]
}

```

Vous devez configurer les autorisations pour autoriser une IAM entité (telle qu'un utilisateur, un groupe ou un rôle) à créer, modifier ou supprimer un rôle lié à un service. Pour plus d'informations, consultez la section [Autorisations relatives aux rôles liés à un service](#) dans le Guide de l'IAMutilisateur.

## Création d'un rôle lié à un service pour Serverless EMR

Vous n'avez pas besoin de créer manuellement un rôle lié à un service. Lorsque vous créez une nouvelle application EMR sans serveur dans le AWS Management Console (à l'aide de EMR Studio), le AWS CLI, ou le AWS API, EMR Serverless crée pour vous le rôle lié au service. Vous devez configurer les autorisations pour autoriser une IAM entité (telle qu'un utilisateur, un groupe ou un rôle) à créer, modifier ou supprimer un rôle lié à un service.

Pour créer le rôle `AWSServiceRoleForAmazonEMRServerless` lié à un service à l'aide de IAM

Ajoutez l'instruction suivante à la politique d'autorisation pour l'IAMentité qui doit créer le rôle lié à un service.

```
{
  "Effect": "Allow",
  "Action": [
    "iam:CreateServiceLinkedRole"
  ],
  "Resource": "arn:aws:iam::*:role/aws-service-role/ops.emr-serverless.amazonaws.com/AWSServiceRoleForAmazonEMRServerless*",
  "Condition": {"StringLike": {"iam:AWSServiceName": "ops.emr-serverless.amazonaws.com"}}
}
```

Si vous supprimez ce rôle lié à un service et que vous avez ensuite besoin de le recréer, vous pouvez utiliser la même procédure pour recréer le rôle dans votre compte. Lorsque vous créez une nouvelle application EMR Serverless, EMR Serverless crée à nouveau le rôle lié au service pour vous.

Vous pouvez également utiliser la IAM console pour créer un rôle lié à un service avec le cas d'utilisation EMRsans serveur. Dans le volet AWS CLI ou le AWS API, créez un rôle lié à un service avec le nom du `ops.emr-serverless.amazonaws.com` service. Pour plus d'informations, consultez la section [Création d'un rôle lié à un service](#) dans le Guide de l'IAUtilisateur. Si vous supprimez ce rôle lié à un service, vous pouvez utiliser ce même processus pour créer le rôle à nouveau.

## Modification d'un rôle lié à un service pour Serverless EMR

EMRServerless ne vous permet pas de modifier le rôle `AWSServiceRoleForAmazonEMRServerless` lié au service car diverses entités peuvent y faire référence. Vous ne pouvez pas modifier le AWS IAM-politique propre que le rôle lié au service EMR Serverless utilise, car elle contient toutes les autorisations nécessaires dont Serverless a besoin. EMR Vous pouvez toutefois modifier la description du rôle à l'aide deIAM.

Pour modifier la description du rôle `AWSServiceRoleForAmazonEMRServerless` lié à un service à l'aide de IAM

Ajoutez la déclaration suivante à la politique d'autorisation pour l'IAEntité qui doit modifier la description d'un rôle lié à un service.

```
{
  "Effect": "Allow",
  "Action": [
    "iam: UpdateRoleDescription"
  ]
}
```

```

    ],
    "Resource": "arn:aws:iam::*:role/aws-service-role/ops.emr-serverless.amazonaws.com/AWSServiceRoleForAmazonEMRServerless*",
    "Condition": {"StringLike": {"iam:AWSServiceName": "ops.emr-serverless.amazonaws.com"}}
  }

```

Pour plus d'informations, consultez la section [Modification d'un rôle lié à un service](#) dans le Guide de l'IAMutilisateur.

## Supprimer un rôle lié à un service pour Serverless EMR

Si vous n'avez plus besoin d'utiliser une fonctionnalité ou un service qui nécessite un rôle lié à un service, nous vous recommandons de supprimer ce rôle. Cela vous évite d'avoir une entité inutilisée qui n'est pas activement surveillée ou maintenue. Toutefois, vous devez supprimer toutes les applications EMR sans serveur dans toutes les régions avant de pouvoir supprimer le rôle lié à un service.

### Note

Si le service EMR Serverless utilise le rôle lorsque vous essayez de supprimer les ressources associées au rôle, la suppression risque d'échouer. Si cela se produit, patientez quelques minutes et réessayez.

Pour supprimer le rôle `AWSServiceRoleForAmazonEMRServerless` lié à un service à l'aide de IAM

Ajoutez l'instruction suivante à la politique d'autorisation pour l'IAMentité qui doit supprimer un rôle lié à un service.

```

{
  "Effect": "Allow",
  "Action": [
    "iam:DeleteServiceLinkedRole",
    "iam:GetServiceLinkedRoleDeletionStatus"
  ],
  "Resource": "arn:aws:iam::*:role/aws-service-role/ops.emr-serverless.amazonaws.com/AWSServiceRoleForAmazonEMRServerless*",
  "Condition": {"StringLike": {"iam:AWSServiceName": "ops.emr-serverless.amazonaws.com"}}
}

```

## Pour supprimer manuellement le rôle lié à un service à l'aide de IAM

Utilisez la IAM console, le AWS CLI, ou le AWS API pour supprimer le rôle `AWSServiceRoleForAmazonEMRServerless` lié au service. Pour plus d'informations, voir [Supprimer un rôle lié à un service](#) dans le Guide de l'IAM utilisateur.

## Régions prises en charge pour les rôles EMR liés à un service sans serveur

EMR Serverless prend en charge l'utilisation de rôles liés au service dans toutes les régions où le service est disponible. Pour plus d'informations, consultez [AWS Régions et points de terminaison](#).

## Rôles d'exécution des tâches pour Amazon EMR Serverless

Vous pouvez spécifier les autorisations de IAM rôle que l'exécution d'une tâche EMR sans serveur peut assumer lorsque vous appelez d'autres services en votre nom. Cela inclut l'accès à Amazon S3 pour toutes les sources de données, cibles, ainsi que pour d'autres AWS des ressources telles que les clusters Amazon Redshift et les tables DynamoDB. Pour en savoir plus sur la création d'un rôle, consultez [Création d'un rôle d'exécution de tâches](#).

### Exemples de politiques d'exécution

Vous pouvez associer une politique d'exécution, telle que la suivante, à un rôle d'exécution de tâche. La politique d'exécution des tâches suivante permet :

- Accès en lecture aux compartiments Amazon S3 avec des EMR exemples.
- Accès complet aux compartiments S3.
- Créez et lisez l'accès à AWS Catalogue de données Glue.

Pour ajouter un accès à d'autres AWS pour les ressources telles que DynamoDB, vous devrez inclure les autorisations correspondantes dans la politique lors de la création du rôle d'exécution.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ReadAccessForEMRSamples",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ]
    }
  ],
}
```

```

    "Resource": [
      "arn:aws:s3:::*elasticmapreduce",
      "arn:aws:s3:::*elasticmapreduce/*"
    ]
  },
  {
    "Sid": "FullAccessToS3Bucket",
    "Effect": "Allow",
    "Action": [
      "s3:PutObject",
      "s3:GetObject",
      "s3:ListBucket",
      "s3:DeleteObject"
    ],
    "Resource": [
      "arn:aws:s3:::DOC-EXAMPLE-BUCKET",
      "arn:aws:s3:::DOC-EXAMPLE-BUCKET/*"
    ]
  },
  {
    "Sid": "GlueCreateAndReadDataCatalog",
    "Effect": "Allow",
    "Action": [
      "glue:GetDatabase",
      "glue:CreateDatabase",
      "glue:GetDataBases",
      "glue:CreateTable",
      "glue:GetTable",
      "glue:UpdateTable",
      "glue>DeleteTable",
      "glue:GetTables",
      "glue:GetPartition",
      "glue:GetPartitions",
      "glue:CreatePartition",
      "glue:BatchCreatePartition",
      "glue:GetUserDefinedFunctions"
    ],
    "Resource": ["*"]
  }
]
}

```

## Transmettez les privilèges liés aux rôles

Vous pouvez associer IAM des politiques d'autorisation au rôle d'un utilisateur pour lui permettre de transmettre uniquement les rôles approuvés. Cela permet aux administrateurs de contrôler quels utilisateurs peuvent transmettre des rôles d'exécution de tâches spécifiques à des tâches EMR sans serveur. Pour en savoir plus sur la définition des autorisations, voir [Accorder à un utilisateur l'autorisation de transmettre un rôle à un AWS service](#).

Voici un exemple de politique qui permet de transmettre un rôle d'exécution de tâche au principal du service EMR Serverless.

```
{
  "Effect": "Allow",
  "Action": "iam:PassRole",
  "Resource": "arn:aws:iam::1234567890:role/JobRuntimeRoleForEMRServerless",
  "Condition": {
    "StringLike": {
      "iam:PassedToService": "emr-serverless.amazonaws.com"
    }
  }
}
```

## Exemples de politiques d'accès utilisateur pour EMR Serverless

Vous pouvez définir des politiques précises pour vos utilisateurs en fonction des actions que vous souhaitez que chaque utilisateur effectue lorsqu'il interagit avec des applications EMR sans serveur. Les politiques suivantes sont des exemples qui peuvent vous aider à configurer les autorisations appropriées pour vos utilisateurs. Cette section se concentre uniquement sur les politiques EMR sans serveur. Pour des exemples de politiques utilisateur de EMR Studio, voir [Configurer les autorisations utilisateur de EMR Studio](#). Pour plus d'informations sur la façon d'associer des politiques aux IAM utilisateurs (principaux), consultez la section [Gestion des IAM politiques](#) dans le Guide de l'IAMutilisateur.

### Politique relative aux utilisateurs expérimentés

Pour accorder toutes les actions requises pour EMR Serverless, créez et associez une `AmazonEMRServerlessFullAccess` politique à l'IAMutilisateur, au rôle ou au groupe requis.

Voici un exemple de politique qui permet aux utilisateurs expérimentés de créer et de modifier des applications EMR sans serveur, ainsi que d'effectuer d'autres actions telles que la soumission et le débogage de tâches. Il révèle toutes les actions requises par EMR Serverless pour les autres services.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EMRServerlessActions",
      "Effect": "Allow",
      "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"
      ],
      "Resource": "*"
    }
  ]
}
```

Lorsque vous activez la connectivité réseau à votre VPC, les applications EMR sans serveur créent des interfaces réseau EC2 élastiques Amazon (ENIs) pour communiquer avec les VPC ressources. La politique suivante garantit que les nouvelles applications ne EC2 ENIs sont créées que dans le contexte des applications EMR sans serveur.

#### Note

Nous recommandons vivement de définir cette politique afin de garantir que les utilisateurs ne puissent pas créer EC2ENIs, sauf dans le cadre du lancement d'applications EMR sans serveur.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowEC2ENICreationWithEMRTags",
```



```

    "Effect": "Allow",
    "Action": [
      "ec2:CreateNetworkInterface"
    ],
    "Resource": [
      "arn:aws:ec2:*:*:network-interface/*"
    ],
    "Condition": {
      "StringEquals": {
        "aws:CalledViaLast": "ops.emr-serverless.amazonaws.com"
      }
    }
  }
}

```

Si vous souhaitez restreindre l'accès EMR sans serveur à certains sous-réseaux, vous pouvez étiqueter chaque sous-réseau avec une condition de balise. Cette IAM politique garantit que les applications EMR sans serveur ne peuvent créer que EC2 ENIs dans les sous-réseaux autorisés.

```

{
  "Sid": "AllowEC2ENICreationInSubnetAndSecurityGroupWithEMRTags",
  "Effect": "Allow",
  "Action": [
    "ec2:CreateNetworkInterface"
  ],
  "Resource": [
    "arn:aws:ec2:*:*:subnet/*",
    "arn:aws:ec2:*:*:security-group/*"
  ],
  "Condition": {
    "StringEquals": {
      "aws:ResourceTag/KEY": "VALUE"
    }
  }
}

```

### Important

Si vous êtes un administrateur ou un utilisateur expérimenté qui crée votre première application, vous devez configurer vos politiques d'autorisation pour vous permettre de créer

un rôle lié à un service EMR sans serveur. Pour en savoir plus, consultez [Utilisation de rôles liés à un service pour Serverless EMR](#).

La IAM politique suivante vous permet de créer un rôle lié à un service EMR sans serveur pour votre compte.

```
{
  "Sid": "AllowEMRServerlessServiceLinkedRoleCreation",
  "Effect": "Allow",
  "Action": "iam:CreateServiceLinkedRole",
  "Resource": "arn:aws:iam::account-id:role/aws-service-role/ops.emr-serverless.amazonaws.com/AWSServiceRoleForAmazonEMRServerless"
}
```

## Politique relative aux ingénieurs de données

Voici un exemple de politique qui accorde aux utilisateurs des autorisations en lecture seule sur les applications EMR sans serveur, ainsi que la possibilité de soumettre et de déboguer des tâches. Gardez à l'esprit que, si cette stratégie n'empêche pas explicitement certaines actions, une autre déclaration de stratégie peut toutefois être utilisée pour accorder l'accès aux actions spécifiées.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EMRServerlessActions",
      "Effect": "Allow",
      "Action": [
        "emr-serverless:ListApplications",
        "emr-serverless:GetApplication",
        "emr-serverless:StartApplication",
        "emr-serverless:StartJobRun",
        "emr-serverless:CancelJobRun",
        "emr-serverless:ListJobRuns",
        "emr-serverless:GetJobRun"
      ],
      "Resource": "*"
    }
  ]
}
```

## Utilisation de balises pour le contrôle d'accès

Vous pouvez utiliser les conditions des balises pour un contrôle d'accès précis. Par exemple, vous pouvez restreindre les utilisateurs d'une équipe afin qu'ils ne puissent soumettre des tâches qu'aux applications EMR sans serveur étiquetées avec le nom de leur équipe.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "EMRServerlessActions",
      "Effect": "Allow",
      "Action": [
        "emr-serverless:ListApplications",
        "emr-serverless:GetApplication",
        "emr-serverless:StartApplication",
        "emr-serverless:StartJobRun",
        "emr-serverless:CancelJobRun",
        "emr-serverless:ListJobRuns",
        "emr-serverless:GetJobRun"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "aws:ResourceTag/Team": "team-name"
        }
      }
    }
  ]
}
```

## Politiques de contrôle d'accès basées sur les balises

Vous pouvez utiliser des conditions dans votre politique basée sur l'identité pour contrôler l'accès aux applications et aux exécutions de tâches en fonction des balises.

Les exemples suivants illustrent différents scénarios et méthodes d'utilisation des opérateurs de condition avec des clés de condition EMR sans serveur. Ces déclarations IAM de politique sont destinées à des fins de démonstration uniquement et ne doivent pas être utilisées dans des environnements de production. Il existe plusieurs façons de combiner des instructions de stratégie

pour accorder et refuser des autorisations selon vos besoins. Pour plus d'informations sur les IAM politiques de planification et de test, consultez le [guide de IAM l'utilisateur](#).

### ⚠ Important

Le refus explicite d'autoriser l'attribution de balises doit être pris en considération. Cela empêche les utilisateurs de baliser une ressource et de s'accorder ainsi des autorisations que vous n'aviez pas l'intention d'accorder. Si les actions de balisage d'une ressource ne sont pas refusées, un utilisateur peut modifier les balises et contourner l'intention des politiques basées sur les balises. Pour un exemple de politique qui refuse les actions de balisage, consultez [Refuser l'accès pour ajouter et supprimer des balises](#).

Les exemples ci-dessous illustrent les politiques d'autorisation basées sur l'identité qui sont utilisées pour contrôler les actions autorisées avec les applications EMR sans serveur.

## Autorisation d'actions uniquement sur les ressources ayant des valeurs de balises spécifiques

Dans l'exemple de politique suivant, l'opérateur de `StringEquals` condition essaie de faire `dev` correspondre la valeur du département des balises. Si le département des balises n'a pas été ajouté à l'application ou ne contient pas la valeur `dev`, la politique ne s'applique pas et les actions ne sont pas autorisées par cette politique. Si aucune autre déclaration de politique n'autorise les actions, l'utilisateur ne peut travailler qu'avec les applications dotées de cette balise avec cette valeur.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-serverless:GetApplication"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "emr-serverless:ResourceTag/department": "dev"
        }
      }
    }
  ]
}
```

```
]
}
```

Vous pouvez également spécifier plusieurs valeurs de balise à l'aide d'un opérateur de condition. Par exemple, pour autoriser des actions sur des applications où la `department` balise contient la valeur `devtest`, vous pouvez remplacer le bloc de condition dans l'exemple précédent par le suivant.

```
"Condition": {
  "StringEquals": {
    "emr-serverless:ResourceTag/department": ["dev", "test"]
  }
}
```

## Exiger le balisage lors de la création d'une ressource

Dans l'exemple ci-dessous, la balise doit être appliquée lors de la création de l'application.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-serverless:CreateApplication"
      ],
      "Resource": "*",
      "Condition": {
        "StringEquals": {
          "emr-serverless:RequestTag/department": "dev"
        }
      }
    }
  ]
}
```

La déclaration de politique suivante permet à un utilisateur de créer une application uniquement si celle-ci possède une `department` balise, qui peut contenir n'importe quelle valeur.

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

```

    "Effect": "Allow",
    "Action": [
      "emr-serverless:CreateApplication"
    ],
    "Resource": "*",
    "Condition": {
      "Null": {
        "emr-serverless:RequestTag/department": "false"
      }
    }
  }
]
}

```

## Refuser l'accès pour ajouter et supprimer des balises

Cette politique empêche un utilisateur d'ajouter ou de supprimer des balises dans les applications EMR sans serveur dont la valeur n'est pas dev la même. department

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Deny",
      "Action": [
        "emr-serverless:TagResource",
        "emr-serverless:UntagResource"
      ],
      "Resource": "*",
      "Condition": {
        "StringNotEquals": {
          "emr-serverless:ResourceTag/department": "dev"
        }
      }
    }
  ]
}

```

## Exemples de politiques basées sur l'identité pour Serverless EMR

Par défaut, les utilisateurs et les rôles ne sont pas autorisés à créer ou à modifier des ressources Amazon EMR Serverless. Ils ne peuvent pas non plus effectuer de tâches à l'aide du AWS

Management Console, AWS Command Line Interface (AWS CLI), ou AWS API. Pour autoriser les utilisateurs à effectuer des actions sur les ressources dont ils ont besoin, un IAM administrateur peut créer des IAM politiques. L'administrateur peut ensuite ajouter les IAM politiques aux rôles, et les utilisateurs peuvent assumer les rôles.

Pour savoir comment créer une politique IAM basée sur l'identité à l'aide de ces exemples de documents de JSON stratégie, consultez la section [Création de IAM politiques](#) dans le guide de l'IAMutilisateur.

Pour plus de détails sur les actions et les types de ressources définis par Amazon EMR Serverless, y compris le format du ARNs pour chacun des types de ressources, consultez la section [Actions, ressources et clés de condition pour Amazon EMR Serverless](#) dans la référence d'autorisation de service.

## Rubriques

- [Bonnes pratiques en matière de politiques](#)
- [Autorisation accordée aux utilisateurs pour afficher leurs propres autorisations](#)

## Bonnes pratiques en matière de politiques

### Note

EMRServerless ne prend pas en charge les politiques gérées. La première pratique répertoriée ci-dessous ne s'applique donc pas.

Les politiques basées sur l'identité déterminent si quelqu'un peut créer, accéder ou supprimer des ressources Amazon EMR Serverless dans votre compte. Ces actions peuvent entraîner des coûts pour votre Compte AWS. Lorsque vous créez ou modifiez des politiques basées sur l'identité, suivez les directives et recommandations suivantes :

- Commencez avec AWS politiques gérées et évolution vers des autorisations de moindre privilège — Pour commencer à accorder des autorisations à vos utilisateurs et à vos charges de travail, utilisez le AWS politiques gérées qui accordent des autorisations pour de nombreux cas d'utilisation courants. Ils sont disponibles dans votre Compte AWS. Nous vous recommandons de réduire davantage les autorisations en définissant AWS des politiques gérées par le client qui sont spécifiques à vos cas d'utilisation. Pour plus d'informations, consultez [.AWS politiques gérées](#) ou [AWS politiques gérées pour les fonctions professionnelles](#) dans le guide de IAM l'utilisateur.

- Appliquer les autorisations du moindre privilège : lorsque vous définissez des autorisations à IAM l'aide de politiques, accordez uniquement les autorisations nécessaires à l'exécution d'une tâche. Pour ce faire, vous définissez les actions qui peuvent être entreprises sur des ressources spécifiques dans des conditions spécifiques, également appelées autorisations de moindre privilège. Pour plus d'informations sur l'utilisation IAM pour appliquer des autorisations, consultez la section [Politiques et autorisations](#) du Guide de IAM l'utilisateur. IAM
- Utilisez des conditions dans IAM les politiques pour restreindre davantage l'accès : vous pouvez ajouter une condition à vos politiques pour limiter l'accès aux actions et aux ressources. Par exemple, vous pouvez rédiger une condition de politique pour spécifier que toutes les demandes doivent être envoyées en utilisant SSL. Vous pouvez également utiliser des conditions pour accorder l'accès aux actions de service si elles sont utilisées par le biais d'un Service AWS, comme AWS CloudFormation. Pour plus d'informations, voir [Éléments IAM JSON de politique : Condition](#) dans le guide de IAM l'utilisateur.
- Utilisez IAM Access Analyzer pour valider vos IAM politiques afin de garantir des autorisations sécurisées et fonctionnelles. IAM Access Analyzer valide les politiques nouvelles et existantes afin qu'elles respectent le langage des politiques (JSON) et IAM les IAM meilleures pratiques. IAM Access Analyzer fournit plus de 100 vérifications des politiques et des recommandations exploitables pour vous aider à créer des politiques sécurisées et fonctionnelles. Pour plus d'informations, consultez la section [Validation des politiques d'IAM Access Analyzer](#) dans le guide de IAM l'utilisateur.
- Exiger une authentification multifactorielle (MFA) — Si vous avez un scénario qui nécessite IAM des utilisateurs ou un utilisateur root dans votre Compte AWS, activez MFA pour plus de sécurité. Pour exiger le MFA moment où les API opérations sont appelées, ajoutez MFA des conditions à vos politiques. Pour plus d'informations, consultez [la section Configuration de l'API accès MFA protégé](#) dans le Guide de l'IAM utilisateur.

Pour plus d'informations sur les meilleures pratiques en matière de [sécurité IAM](#), consultez la section [Bonnes pratiques en matière](#) de sécurité IAM dans le Guide de IAM l'utilisateur.

## Autorisation accordée aux utilisateurs pour afficher leurs propres autorisations

Cet exemple montre comment créer une politique qui permet aux IAM utilisateurs de consulter les politiques intégrées et gérées associées à leur identité d'utilisateur. Cette politique inclut les autorisations permettant d'effectuer cette action sur la console ou par programmation à l'aide du AWS CLI or AWS API.

```
{
```



```
"Version": "2012-10-17",
"Statement": [
  {
    "Sid": "ViewOwnUserInfo",
    "Effect": "Allow",
    "Action": [
      "iam:GetUserPolicy",
      "iam:ListGroupsWithUser",
      "iam:ListAttachedUserPolicies",
      "iam:ListUserPolicies",
      "iam:GetUser"
    ],
    "Resource": ["arn:aws:iam::*:user/${aws:username}"]
  },
  {
    "Sid": "NavigateInConsole",
    "Effect": "Allow",
    "Action": [
      "iam:GetGroupPolicy",
      "iam:GetPolicyVersion",
      "iam:GetPolicy",
      "iam:ListAttachedGroupPolicies",
      "iam:ListGroupPolicies",
      "iam:ListPolicyVersions",
      "iam:ListPolicies",
      "iam:ListUsers"
    ],
    "Resource": "*"
  }
]
```

## Mises à jour Amazon EMR Serverless vers AWS stratégies gérées

Afficher les détails des mises à jour de AWS politiques gérées pour Amazon EMR Serverless depuis que ce service a commencé à suivre ces modifications. Pour recevoir des alertes automatiques concernant les modifications apportées à cette page, abonnez-vous au RSS flux sur la page d'[historique des documents](#) Amazon EMR Serverless.

Modification	Description	Date
A mazonEMRServerless ServiceRolePolicy — Mise à jour d'une politique existante	Amazon EMR Serverless a ajouté le nouveau « Sid CloudWatchPolicyStatement et » EC2PolicyStatement à la <a href="#">mazonEMRServerless ServiceRolePolicy politique A.</a>	25 janvier 2024
A mazonEMRServerless ServiceRolePolicy — Mise à jour d'une politique existante	Amazon EMR Serverless a ajouté de nouvelles autorisations pour permettre à Amazon EMR Serverless de publier des statistiques de compte agrégées pour l'CPU utilisation de v dans l'"AWS/Usage" espace de noms.	20 avril 2023
Amazon EMR Serverless a commencé à suivre les modifications	Amazon EMR Serverless a commencé à suivre les modifications apportées à son AWS politiques gérées.	20 avril 2023

## Résolution des problèmes d'identité et d'EMRaccès Amazon Serverless

Utilisez les informations suivantes pour vous aider à diagnostiquer et à résoudre les problèmes courants que vous pouvez rencontrer lorsque vous travaillez avec Amazon EMR Serverless etIAM.

### Rubriques

- [Je ne suis pas autorisé à effectuer une action dans Amazon EMR Serverless](#)
- [Je ne suis pas autorisé à effectuer iam : PassRole](#)
- [Je souhaite autoriser des personnes extérieures à mon AWS compte pour accéder à mes ressources Amazon EMR Serverless](#)

## Je ne suis pas autorisé à effectuer une action dans Amazon EMR Serverless

Si l'icône AWS Management Console vous indique que vous n'êtes pas autorisé à effectuer une action. Vous devez alors contacter votre administrateur pour obtenir de l'aide. Votre administrateur est la personne qui vous a fourni votre nom d'utilisateur et votre mot de passe.

L'exemple d'erreur suivant se produit quand l'utilisateur `mateojackson` tente d'utiliser la console pour afficher des informations détaillées sur une ressource `my-example-widget` fictive, mais ne dispose pas des autorisations `emr-serverless:GetWidget` fictives.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform: emr-serverless:GetWidget on resource: my-example-widget
```

Dans ce cas, Mateo demande à son administrateur de mettre à jour ses politiques pour lui permettre d'accéder à la ressource `my-example-widget` à l'aide de l'action `emr-serverless:GetWidget`.

## Je ne suis pas autorisé à effectuer iam : PassRole

Si vous recevez un message d'erreur indiquant que vous n'êtes pas autorisé à effectuer l'action `iam:PassRole`, vos politiques doivent être mises à jour pour vous permettre de transmettre un rôle à Amazon EMR Serverless.

Momentanée Services AWS vous permettent de transmettre un rôle existant à ce service au lieu de créer un nouveau rôle de service ou un rôle lié à un service. Pour ce faire, un utilisateur doit disposer des autorisations nécessaires pour transmettre le rôle au service.

L'exemple d'erreur suivant se produit lorsqu'un IAM utilisateur nommé `marymajor` essaie d'utiliser la console pour effectuer une action dans Amazon EMR Serverless. Toutefois, l'action nécessite que le service ait des autorisations accordées par un rôle de service. Mary ne dispose pas des autorisations nécessaires pour transférer le rôle au service.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform: iam:PassRole
```

Dans ce cas, les politiques de Mary doivent être mises à jour pour lui permettre d'exécuter l'action `iam:PassRole`.

Si vous avez besoin d'aide, contactez votre AWS administrateur. Votre administrateur vous a fourni vos informations d'identification de connexion.

## Je souhaite autoriser des personnes extérieures à mon AWS compte pour accéder à mes ressources Amazon EMR Serverless

Vous pouvez créer un rôle que les utilisateurs provenant d'autres comptes ou les personnes extérieures à votre organisation pourront utiliser pour accéder à vos ressources. Vous pouvez spécifier qui est autorisé à assumer le rôle. Pour les services qui prennent en charge les politiques basées sur les ressources ou les listes de contrôle d'accès (ACLs), vous pouvez utiliser ces politiques pour autoriser les utilisateurs à accéder à vos ressources.

Pour en savoir plus, consultez les éléments suivants :

- Pour savoir si Amazon EMR Serverless prend en charge ces fonctionnalités, consultez [Identity and Access Management \(IAM\) dans Amazon EMR Serverless](#).
- Pour savoir comment fournir un accès à vos ressources sur Comptes AWS dont vous êtes le propriétaire, voir [Fournir un accès à un IAM utilisateur dans un autre Compte AWS dont vous êtes propriétaire](#) dans le guide de IAM l'utilisateur.
- Pour savoir comment fournir l'accès à vos ressources à des tiers Comptes AWS, voir [Fournir un accès à Comptes AWS appartenant à des tiers](#) dans le Guide de IAM l'utilisateur.
- Pour savoir comment fournir un accès via la fédération d'identité, consultez la section [Fournir un accès aux utilisateurs authentifiés de manière externe \(fédération d'identité\)](#) dans le guide de l'IAM utilisateur.
- Pour connaître la différence entre l'utilisation de rôles et de politiques basées sur les ressources pour l'accès entre comptes, voir Accès aux [ressources entre comptes IAM dans le guide](#) de l'IAM utilisateur.

## Utilisation du mode EMR Serverless avec AWS Lake Formation pour un contrôle d'accès précis

### Présentation

Avec les EMR versions 7.2.0 et supérieures d'Amazon, vous pouvez tirer parti AWS Lake Formation pour appliquer des contrôles d'accès précis sur les tables du catalogue de données soutenues par S3. Cette fonctionnalité vous permet de configurer les contrôles d'accès au niveau des tables, des lignes, des colonnes et des cellules pour read requêtes dans vos tâches Amazon EMR Serverless Spark. Pour configurer un contrôle d'accès précis pour les tâches par lots et les sessions interactives

d'Apache Spark, utilisez EMR Studio. Consultez les sections suivantes pour en savoir plus sur Lake Formation et comment l'utiliser avec EMR Serverless.

Utilisation d'Amazon EMR Serverless avec AWS Lake Formation entraîne des frais supplémentaires. Pour plus d'informations, consultez les [EMRtarifs Amazon](#).

## Comment fonctionne EMR Serverless avec AWS Lake Formation

L'utilisation de EMR Serverless avec Lake Formation vous permet d'appliquer une couche d'autorisations à chaque tâche Spark afin d'appliquer le contrôle des autorisations de Lake Formation lorsque EMR Serverless exécute des tâches. EMRServerless utilise les [profils de ressources Spark](#) pour créer deux profils afin d'exécuter efficacement les tâches. Le profil utilisateur exécute le code fourni par l'utilisateur, tandis que le profil système applique les politiques de Lake Formation. Pour plus d'informations, voir [Qu'est-ce que AWS Lake Formation](#) et [Considérations et limites](#).

Lorsque vous utilisez une capacité préinitialisée avec Lake Formation, nous vous recommandons de disposer d'au moins deux pilotes Spark. Chaque tâche activée par Lake Formation utilise deux pilotes Spark, l'un pour le profil utilisateur et l'autre pour le profil système. Pour de meilleures performances, vous devez utiliser deux fois plus de pilotes pour les tâches compatibles avec Lake Formation que si vous n'utilisez pas Lake Formation.


Lorsque vous exécutez des tâches Spark sur EMR Serverless, vous devez également tenir compte de l'impact de l'allocation dynamique sur la gestion des ressources et les performances du cluster. La configuration `spark.dynamicAllocation.maxExecutors` du nombre maximum d'exécuteurs par profil de ressource s'applique à la fois aux exécuteurs utilisateur et système. Si vous configurez ce nombre pour qu'il soit égal au nombre maximum autorisé d'exécuteurs, l'exécution de votre tâche risque de se bloquer car un type d'exécuteur utilise toutes les ressources disponibles, ce qui empêche l'autre exécuteur d'exécuter des tâches.

Pour ne pas manquer de ressources, EMR Serverless définit le nombre maximum d'exécuteurs par défaut par profil de ressource à 90 % de la `spark.dynamicAllocation.maxExecutors` valeur. Vous pouvez remplacer cette configuration lorsque vous spécifiez `spark.dynamicAllocation.maxExecutorsRatio` une valeur comprise entre 0 et 1. En outre, vous pouvez également configurer les propriétés suivantes pour optimiser l'allocation des ressources et les performances globales :

- `spark.dynamicAllocation.cachedExecutorIdleTimeout`
- `spark.dynamicAllocation.shuffleTracking.timeout`

- `spark.cleaner.periodicGC.interval`

Voici un aperçu général de la manière dont EMR Serverless accède aux données protégées par les politiques de sécurité de Lake Formation.



1. Un utilisateur soumet une tâche Spark à un AWS Lake Formation application EMR Serverless activée.
2. EMRServerless envoie la tâche à un pilote utilisateur et exécute la tâche dans le profil utilisateur. Le pilote utilisateur exécute une version allégée de Spark qui n'est pas en mesure de lancer des tâches, de demander des exécuteurs, d'accéder à S3 ou au catalogue Glue. Il élabore un plan d'emploi.
3. EMRServerless configure un deuxième pilote appelé pilote système et l'exécute dans le profil système (avec une identité privilégiée). EMRServerless établit un TLS canal crypté entre les

deux pilotes pour la communication. Le pilote utilisateur utilise le canal pour envoyer les plans de travail au pilote du système. Le pilote du système n'exécute pas le code envoyé par l'utilisateur. Il exécute Spark dans son intégralité et communique avec S3 et le catalogue de données pour l'accès aux données. Il demande des exécuteurs et compile le Job Plan en une séquence d'étapes d'exécution.

4. EMRServerless exécute ensuite les étapes sur les exécuteurs avec le pilote utilisateur ou le pilote système. À n'importe quel stade, le code utilisateur est exécuté exclusivement sur les exécuteurs de profil utilisateur.
5. Stages qui lisent les données des tables du catalogue de données protégées par AWS Lake Formation ou ceux qui appliquent des filtres de sécurité sont délégués aux exécuteurs du système.

## Favoriser la formation de Lake en Amazon EMR

Pour activer Lake Formation, vous devez définir le paramètre de configuration `spark.emr-serverless.lakeformation.enabled` d'exécution sur « `true` spark-defaults sous-classification » lors de la [création d'une application EMR Serverless](#).

```
aws emr-serverless create-application \  
  --release-label emr-7.2.0 \  
  --runtime-configuration '{  
    "classification": "spark-defaults",  
    "properties": {  
      "spark.emr-serverless.lakeformation.enabled": "true"  
    }  
  }' \  
  --type "SPARK"
```

Vous pouvez également activer Lake Formation lorsque vous créez une nouvelle application dans EMR Studio. Choisissez Utiliser Lake Formation pour un contrôle d'accès précis, disponible dans la section Configurations supplémentaires.

[Le chiffrement entre utilisateurs](#) est activé par défaut lorsque vous utilisez Lake Formation avec EMR Serverless, de sorte que vous n'avez pas à réactiver explicitement le chiffrement entre utilisateurs.

### Permettre la formation de Lake Formation pour les emplois de Spark

Pour activer Lake Formation pour des tâches Spark individuelles, définissez ce paramètre `spark.emr-serverless.lakeformation.enabled` sur `true` lors de l'utilisation `spark-submit`.

```
--conf spark.emr-serverless.lakeformation.enabled=true
```

## IAMAutorisations relatives aux rôles d'exécution des tâches

Les autorisations de Lake Formation contrôlent l'accès à AWS Glue les ressources du catalogue de données, les sites Amazon S3 et les données sous-jacentes présentes sur ces sites. IAMles autorisations contrôlent l'accès à la Lake Formation et AWS Glue APIs et ressources. Bien que vous ayez l'autorisation Lake Formation d'accéder à une table du catalogue de données (SELECT), votre opération échoue si vous n'en avez pas l'IAMglue: Get\*APIautorisation.

Voici un exemple de politique expliquant comment fournir des IAM autorisations pour accéder à un script dans S3, en téléchargeant des journaux vers S3, AWS APIAutorisations Glue et autorisation d'accéder à Lake Formation.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ScriptAccess",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3::*.DOC-EXAMPLE-BUCKET/scripts",
        "arn:aws:s3::*.DOC-EXAMPLE-BUCKET/*" ]
    },
    {
      "Sid": "LoggingAccess",
      "Effect": "Allow",
      "Action": [
        "s3:PutObject"
      ],
      "Resource": [
        "arn:aws:s3:::DOC-EXAMPLE-BUCKET/logs/*"
      ]
    },
    {
      "Sid": "GlueCatalogAccess",
      "Effect": "Allow",
```



```

    "Action": [
      "glue:Get*",
      "glue:Create*",
      "glue:Update*"
    ],
    "Resource": ["*"]
  },
  {
    "Sid": "LakeFormationAccess",
    "Effect": "Allow",
    "Action": [
      "lakeformation:GetDataAccess"
    ],
    "Resource": ["*"]
  }
]
}

```

## Configuration des autorisations de Lake Formation pour le rôle d'exécution des tâches

Tout d'abord, enregistrez l'emplacement de votre table Hive avec Lake Formation. Créez ensuite des autorisations pour votre rôle d'exécution des tâches dans le tableau de votre choix. Pour plus de détails sur Lake Formation, voir [Qu'est-ce que AWS Lake Formation?](#) dans le AWS Lake Formation Guide du développeur.

Après avoir configuré les autorisations de Lake Formation, vous pouvez soumettre des tâches Spark sur Amazon EMR Serverless. Pour plus d'informations sur les tâches Spark, consultez les [exemples de Spark](#).

## Soumission d'une exécution de tâche

Une fois que vous aurez fini de configurer les subventions Lake Formation, vous pourrez [soumettre des tâches Spark sur EMR Serverless](#). Pour exécuter des tâches Iceberg, vous devez fournir les `spark-submit` propriétés suivantes.

```

--conf spark.sql.catalog.spark_catalog=org.apache.iceberg.spark.SparkSessionCatalog
--conf spark.sql.catalog.spark_catalog.warehouse=<S3_DATA_LOCATION>
--conf spark.sql.catalog.spark_catalog.glue.account-id=<ACCOUNT_ID>
--conf spark.sql.catalog.spark_catalog.client.region=<REGION>

```

```
--conf spark.sql.catalog.spark_catalog.glue.endpoint=https://
glue.<REGION>.amazonaws.com
```

## Support du format de tableau ouvert

La EMR version 7.2.0 d'Amazon inclut la prise en charge d'un contrôle d'accès précis basé sur Lake Formation. EMRServerless prend en charge les types de tables Hive et Iceberg. Le tableau suivant décrit toutes les opérations prises en charge.

Opérations	Hive	Iceberg
DDLcommandes	Avec des autorisations de IAM rôle uniquement	Avec des autorisations de IAM rôle uniquement
Requêtes progressives	Ne s'applique pas	Entièrement pris en charge
Requêtes Time Travel	Non applicable à ce format de tableau	Entièrement pris en charge
Tables de métadonnées	Non applicable à ce format de tableau	Supporté, mais certaines tables sont masquées. Consultez les <a href="#">considérations et les limites</a> pour plus d'informations.
DML INSERT	Avec IAM autorisations uniquement	Avec IAM autorisations uniquement
DML UPDATE	Non applicable à ce format de tableau	Avec IAM autorisations uniquement
DML DELETE	Non applicable à ce format de tableau	Avec IAM autorisations uniquement
Opérations de lecture	Entièrement pris en charge	Entièrement pris en charge
Procédures stockées	Ne s'applique pas	Pris en charge à l'exception de <code>register_table</code> et <code>migrate</code> . Consultez les

Opérations	Hive	Iceberg
		<a href="#">considérations et les limites</a> pour plus d'informations.

## Considérations et restrictions

Tenez compte des considérations et limitations suivantes lorsque vous utilisez Lake Formation avec EMR Serverless.

### Note

Lorsque vous activez Lake Formation pour une tâche Spark sur EMR Serverless, la tâche lance un pilote système et un pilote utilisateur. Si vous avez spécifié une capacité préinitialisée au lancement, les pilotes sont fournis à partir de la capacité préinitialisée, et le nombre de pilotes système est égal au nombre de pilotes utilisateur que vous spécifiez. Si vous choisissez la capacité On Demand, EMR Serverless lance un pilote système en plus d'un pilote utilisateur. Pour estimer les coûts associés à votre projet EMR Serverless with Lake Formation, utilisez [AWS Pricing Calculator](#).

Amazon EMR Serverless with Lake Formation est disponible dans toutes les régions [EMRsans serveur](#) prises en charge, à l'exception de AWS GovCloud (USA Est) et AWS GovCloud (Ouest des États-Unis).

- Amazon EMR Serverless prend en charge le contrôle d'accès précis via Lake Formation uniquement pour les tables Apache Hive et Apache Iceberg. Les formats Apache Hive incluent Parquet et XSV. ORC
- Les applications compatibles avec Lake Formation ne prennent pas en charge l'utilisation d'images [EMRsans serveur personnalisées](#).
- Vous ne pouvez pas désactiver `DynamicResourceAllocation` les jobs de Lake Formation.
- Vous ne pouvez utiliser Lake Formation qu'avec des tâches Spark.
- EMRServerless with Lake Formation ne prend en charge qu'une seule session Spark tout au long d'une tâche.
- EMRServerless with Lake Formation ne prend en charge que les requêtes de table entre comptes partagées via des liens de ressources.

- Les éléments suivants ne sont pas pris en charge :
  - Ensembles de données distribués résilients ( ) RDD
  - Streaming Spark
  - Écrivez avec les autorisations accordées à Lake Formation
  - Contrôle d'accès pour les colonnes imbriquées
- EMRLe mode Serverless bloque les fonctionnalités susceptibles de compromettre l'isolation complète du pilote système, notamment les suivantes :
  - UDTsiveUDFs, H et toute fonction définie par l'utilisateur qui implique des classes personnalisées
  - Sources de données personnalisées
  - Fourniture de fichiers JAR supplémentaires pour l'extension, le connecteur ou le metastore Spark
  - ANALYZE TABLE commande
- Pour appliquer les contrôles d'accès EXPLAIN PLAN et les DDL opérations telles que le fait de DESCRIBE TABLE ne pas exposer les informations restreintes.
- EMRServerless restreint l'accès aux journaux Spark du pilote système sur les applications compatibles avec Lake Formation. Étant donné que le pilote système s'exécute avec plus d'accès, les événements et les journaux générés par le pilote système peuvent inclure des informations sensibles. Pour empêcher les utilisateurs ou le code non autorisés d'accéder à ces données sensibles, EMR Serverless a désactivé l'accès aux journaux des pilotes du système. Pour résoudre les problèmes, contactez AWS soutien.
- Si vous avez enregistré l'emplacement d'une table auprès de Lake Formation, le chemin d'accès aux données passe par les informations d'identification stockées dans Lake Formation, indépendamment de l'IAMautorisation accordée au rôle d'exécution de tâches EMR sans serveur. Si vous configurez mal le rôle enregistré avec l'emplacement de la table, les tâches soumises qui utilisent le rôle avec l'IAMautorisation S3 sur l'emplacement de la table échoueront.
- L'écriture dans une table de Lake Formation utilise des IAM autorisations plutôt que des autorisations accordées par Lake Formation. Si votre rôle d'exécution de tâches dispose des autorisations S3 nécessaires, vous pouvez l'utiliser pour exécuter des opérations d'écriture.

Les considérations et les limites suivantes sont à prendre en compte lors de l'utilisation d'Apache Iceberg :

- Vous ne pouvez utiliser Apache Iceberg qu'avec un catalogue de sessions et non avec des catalogues nommés arbitrairement.
- Les tables Iceberg enregistrées dans Lake Formation ne prennent en charge que les tables de métadonnées `historymetadata_log_entries`, `snapshots`, `filesmanifests`, et `refs`. Amazon EMR masque les colonnes susceptibles de contenir des données sensibles, telles que `partitionspath`, et `summaries`. Cette limitation ne s'applique pas aux tables Iceberg qui ne sont pas enregistrées dans Lake Formation.
- Les tables que vous n'enregistrez pas dans Lake Formation prennent en charge toutes les procédures stockées par Iceberg. Les migrate procédures `register_table` et ne sont prises en charge pour aucune table.
- Nous vous recommandons d'utiliser Iceberg `DataFrameWriter V2` au lieu de `V1`.

## Résolution des problèmes

Consultez les sections suivantes pour découvrir les solutions de dépannage.

### Journalisation

EMRServerless utilise les profils de ressources Spark pour diviser l'exécution des tâches. EMRServerless utilise le profil utilisateur pour exécuter le code que vous avez fourni, tandis que le profil système applique les politiques de Lake Formation. Vous pouvez accéder aux journaux des tâches exécutées en tant que profil utilisateur.

### Interface utilisateur en direct et serveur d'historique Spark

L'interface utilisateur Live et le serveur d'historique Spark contiennent tous les événements Spark générés à partir du profil utilisateur et les événements expurgés générés à partir du pilote système.

Vous pouvez voir toutes les tâches des pilotes utilisateur et système dans l'onglet Exécuteurs. Toutefois, les liens du journal ne sont disponibles que pour le profil utilisateur. En outre, certaines informations sont supprimées de Live UI, telles que le nombre d'enregistrements de sortie.

### Échec de la tâche en raison d'autorisations insuffisantes pour Lake Formation

Assurez-vous que votre rôle d'exécution des tâches dispose des autorisations nécessaires pour s'exécuter `SELECT` et `DESCRIBE` sur la table à laquelle vous accédez.

## Job dont RDD l'exécution a échoué

EMRServerless ne prend actuellement pas en charge les opérations résilientes de jeux de données distribués (RDD) sur les tâches compatibles avec Lake Formation.

## Impossible d'accéder aux fichiers de données dans Amazon S3

Assurez-vous d'avoir enregistré l'emplacement du lac de données dans Lake Formation.

## Exception de validation de sécurité

EMRServerless a détecté une erreur de validation de sécurité. Contact AWS soutien à l'assistance.

## Partage AWS Glue Data Catalog et tableaux pour tous les comptes

Vous pouvez partager des bases de données et des tables entre comptes tout en continuant à utiliser Lake Formation. Pour plus d'informations, voir [Partage de données entre comptes dans Lake Formation](#) et [How do I share AWS Glue Data Catalog et tables utilisant des comptes croisés AWS Lake Formation?](#).

## Chiffrement inter-travailleurs

Avec EMR les versions 6.15.0 et supérieures d'Amazon, vous pouvez activer les communications TLS cryptées entre les collaborateurs lors de vos exécutions de tâches Spark. Lorsqu'il est activé, EMR Serverless génère et distribue automatiquement un certificat unique pour chaque travailleur approvisionné dans le cadre de vos cycles de travail. Lorsque ces travailleurs communiquent pour échanger des messages de contrôle ou transférer des données de shuffle, ils établissent une TLS connexion mutuelle et utilisent les certificats configurés pour vérifier l'identité des autres. Si un travailleur n'est pas en mesure de vérifier un autre certificat, la TLS prise de contact échoue et EMR Serverless interrompt la connexion entre eux.

Si vous utilisez Lake Formation avec EMR Serverless, le TLS chiffrement mutuel est activé par défaut.

## Activation du TLS chiffrement mutuel sur EMR Serverless

Pour activer le TLS chiffrement mutuel sur votre application Spark, définissez ce paramètre sur `true` lors `spark.ssl.internode.enabled` de la [création de l'application EMR Serverless](#). Si vous utilisez le AWS console pour créer une application EMR sans serveur, choisissez

Utiliser les paramètres personnalisés, puis développez la configuration de l'application et entrez votre `runtimeConfiguration`.

```
aws emr-serverless create-application \  
--release-label emr-6.15.0 \  
--runtime-configuration '{  
  "classification": "spark-defaults",  
  "properties": {"spark.ssl.internode.enabled": "true"}  
}' \  
--type "SPARK"
```

Si vous souhaitez activer le TLS chiffrement mutuel pour chaque exécution de tâches Spark, définissez ce paramètre sur `spark.ssl.internode.enabled true` lors de l'utilisation `spark-submit`.

```
--conf spark.ssl.internode.enabled=true
```

## Secrets Manager pour la protection des données avec EMR Serverless

AWS Secrets Manager est un service de stockage secret que vous pouvez utiliser pour protéger les informations d'identification, API les clés et autres informations secrètes de base de données. Ensuite, dans votre code, vous pouvez remplacer les informations d'identification codées en dur par un API appel à Secrets Manager. Cela permet de s'assurer que le secret ne peut pas être compromis par quelqu'un qui examine votre code, car le secret n'existe pas. Pour un aperçu, consultez le [AWS Secrets Manager Guide de l'utilisateur](#).

Secrets Manager chiffre les secrets à l'aide de AWS Key Management Service clés. Pour plus d'informations, consultez la section [Chiffrement et déchiffrement secrets](#) dans le AWS Secrets Manager Guide de l'utilisateur.

Vous pouvez configurer Secrets Manager pour qu'il fasse automatiquement pivoter les secrets selon un calendrier que vous spécifiez. Cela vous permet de remplacer les secrets à long terme par ceux à court terme, ce qui réduit considérablement le risque de mise en péril. Pour plus d'informations, voir [Rotation AWS Secrets Manager secrets](#) dans le AWS Secrets Manager Guide de l'utilisateur.

Amazon EMR Serverless s'intègre à AWS Secrets Manager afin que vous puissiez stocker vos données dans Secrets Manager et utiliser l'identifiant secret dans vos configurations.

## Comment EMR Serverless utilise les secrets

Lorsque vous stockez vos données dans Secrets Manager et que vous utilisez l'ID secret dans vos configurations pour EMR Serverless, vous ne transmettez pas de données de configuration sensibles à EMR Serverless en texte brut et ne les exposez pas à des données externes. APIs Si vous indiquez qu'une paire clé-valeur contient un identifiant secret pour un secret que vous avez stocké dans Secrets Manager, EMR Serverless récupère le secret lorsqu'il envoie des données de configuration aux opérateurs pour exécuter des tâches.

Pour indiquer qu'une paire clé-valeur d'une configuration contient une référence à un secret stocké dans Secrets Manager, ajoutez l'EMR . secret@annotation à la valeur de configuration. Pour toute propriété de configuration comportant une annotation d'identifiant secret, EMR Serverless appelle Secrets Manager et résout le secret au moment de l'exécution de la tâche.

## Comment créer un secret

Pour créer un secret, suivez les étapes décrites dans [Créer un AWS Secrets Manager secret](#) dans le AWS Secrets Manager Guide de l'utilisateur. À l'étape 3, choisissez le champ de texte en clair pour saisir votre valeur sensible.

## Fournir un secret dans une classification de configuration

Les exemples suivants montrent comment fournir un secret dans une classification de configuration à `StartJobRun`. Si vous souhaitez configurer les classifications pour Secrets Manager au niveau de l'application, consultez [Configuration d'application par défaut pour EMR Serverless](#).

Dans les exemples, remplacez *SecretName* par le nom du secret à récupérer. Incluez le trait d'union, suivi des six caractères que Secrets Manager ajoute à la fin du secretARN. Pour de plus amples informations, veuillez consulter [Comment créer un secret](#).

Dans cette section

- [Spécifier des références secrètes - Spark](#)
- [Spécifier des références secrètes - Hive](#)



## Spécifier des références secrètes - Spark

Exemple — Spécifiez des références secrètes dans la configuration du métastore Hive externe pour Spark

```
aws emr-serverless start-job-run \
  --application-id "application-id" \
  --execution-role-arn "job-role-arn" \
  --job-driver '{
    "sparkSubmit": {
      "entryPoint": "s3://DOC-EXAMPLE-BUCKET/scripts/spark-jdbc.py",
      "sparkSubmitParameters": "--jars s3://DOC-EXAMPLE-BUCKET/mariadb-connector-
java.jar
      --conf
spark.hadoop.javax.jdo.option.ConnectionDriverName=org.mariadb.jdbc.Driver
      --conf spark.hadoop.javax.jdo.option.ConnectionUserName=connection-user-
name
      --conf
spark.hadoop.javax.jdo.option.ConnectionPassword=EMR.secret@SecretName
      --conf spark.hadoop.javax.jdo.option.ConnectionURL=jdbc:mysql://db-host:db-
port/db-name
      --conf spark.driver.cores=2
      --conf spark.executor.memory=10G
      --conf spark.driver.memory=6G
      --conf spark.executor.cores=4"
    }
  }' \
  --configuration-overrides '{
    "monitoringConfiguration": {
      "s3MonitoringConfiguration": {
        "logUri": "s3://DOC-EXAMPLE-BUCKET/spark/logs/"
      }
    }
  }'
```

Exemple — Spécifiez des références secrètes pour la configuration du métastore Hive externe dans la classification **spark-defaults**

```
{
  "classification": "spark-defaults",
  "properties": {
    "spark.hadoop.javax.jdo.option.ConnectionDriverName": "org.mariadb.jdbc.Driver"
```

```

        "spark.hadoop.javax.jdo.option.ConnectionURL":"jdbc:mysql://db-host:db-
port/db-name"
        "spark.hadoop.javax.jdo.option.ConnectionUserName":"connection-user-name"
        "spark.hadoop.javax.jdo.option.ConnectionPassword":
"EMR.secret@SecretName",
    }
}

```

## Spécifier des références secrètes - Hive

Exemple — Spécifiez des références secrètes dans la configuration du métastore Hive externe pour Hive

```

aws emr-serverless start-job-run \
  --application-id "application-id" \
  --execution-role-arn "job-role-arn" \
  --job-driver '{
    "hive": {
      "query": "s3://DOC-EXAMPLE-BUCKET/emr-serverless-hive/query/hive-query.ql",
      "parameters": "--hiveconf hive.exec.scratchdir=s3://DOC-EXAMPLE-BUCKET/emr-
serverless-hive/hive/scratch
                    --hiveconf hive.metastore.warehouse.dir=s3://DOC-EXAMPLE-BUCKET/
emr-serverless-hive/hive/warehouse
                    --hiveconf javax.jdo.option.ConnectionUserName=username
                    --hiveconf
javax.jdo.option.ConnectionPassword=EMR.secret@SecretName
                    --hiveconf
hive.metastore.client.factory.class=org.apache.hadoop.hive.ql.metadata.SessionHiveMetaStoreCli
                    --hiveconf
javax.jdo.option.ConnectionDriverName=org.mariadb.jdbc.Driver
                    --hiveconf javax.jdo.option.ConnectionURL=jdbc:mysql://db-host:db-
port/db-name"
    }
  }' \
  --configuration-overrides '{
    "monitoringConfiguration": {
      "s3MonitoringConfiguration": {
        "logUri": "s3://EXAMPLE-LOG-BUCKET"
      }
    }
  }'

```

Exemple — Spécifiez des références secrètes pour la configuration du métastore Hive externe dans la classification **hive-site**

```
{
  "classification": "hive-site",
  "properties": {
    "hive.metastore.client.factory.class":
"org.apache.hadoop.hive.q1.metadata.SessionHiveMetaStoreClientFactory",
    "javax.jdo.option.ConnectionDriverName": "org.mariadb.jdbc.Driver",
    "javax.jdo.option.ConnectionURL": "jdbc:mysql://db-host:db-port/db-name",
    "javax.jdo.option.ConnectionUserName": "username",
    "javax.jdo.option.ConnectionPassword": "EMR.secret@SecretName"
  }
}
```

## Accordez l'accès à EMR Serverless pour récupérer le secret

Pour permettre à EMR Serverless de récupérer la valeur secrète depuis Secrets Manager, ajoutez la déclaration de politique suivante à votre secret lorsque vous le créez. Vous devez créer votre secret à l'aide de la KMS clé gérée par le client pour que EMR Serverless puisse lire la valeur du secret. Pour plus d'informations, consultez la section [Autorisations relatives à la KMS clé](#) dans le AWS Secrets Manager Guide de l'utilisateur.

Dans la politique suivante, remplacez-le *applicationId* par l'ID de votre application.

Politique en matière de ressources pour le secret

Vous devez inclure les autorisations suivantes dans la politique de ressources pour le secret dans AWS Secrets Manager pour permettre à EMR Serverless de récupérer des valeurs secrètes. Pour garantir que seule une application spécifique peut récupérer ce secret, vous pouvez éventuellement spécifier l'ID de l'application EMR sans serveur comme condition dans la politique.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "secretsmanager:GetSecretValue",
        "secretsmanager:DescribeSecret"
      ],
    }
  ],
}
```

```

    "Principal": {
      "Service": [
        "emr-serverless.amazonaws.com"
      ]
    },
    "Resource": [
      "*"
    ],
    "Condition": {
      "StringEquals": {
        "aws:SourceArn": "arn:aws:emr-serverless:Région AWS:aws_account_id:/
applications/applicationId"
      }
    }
  }
]
}

```

Créez votre secret avec la politique suivante pour le service géré par le client AWS Key Management Service (AWS KMS) clé :

Politique de gestion par le client AWS KMS clé

```

{
  "Sid": "Allow EMR Serverless to use the key for decrypting secrets",
  "Effect": "Allow",
  "Principal": {
    "Service": [
      "emr-serverless.amazonaws.com"
    ]
  },
  "Action": [
    "kms:Decrypt",
    "kms:DescribeKey"
  ],
  "Resource": "*",
  "Condition": {
    "StringEquals": {
      "kms:ViaService": "secretsmanager.Région AWS.amazonaws.com"
    }
  }
}

```

## Transformer le secret

La rotation se produit lorsque vous mettez régulièrement à jour un secret. Vous pouvez configurer AWS Secrets Manager pour faire automatiquement pivoter le secret pour vous selon un calendrier que vous spécifiez. De cette façon, vous pouvez remplacer les secrets à long terme par des secrets à court terme. Cela permet de réduire le risque de compromission. EMRServerless récupère la valeur secrète d'une configuration annotée lorsque la tâche passe à l'état en cours d'exécution. Si vous ou un processus mettez à jour la valeur secrète dans Secrets Manager, vous devez soumettre une nouvelle tâche afin que la tâche puisse récupérer la valeur mise à jour.

### Note

Les tâches déjà en cours d'exécution ne peuvent pas récupérer une valeur secrète mise à jour. Cela peut entraîner un échec professionnel.

## Utilisation des autorisations d'accès Amazon S3 avec EMR Serverless

### Présentation des subventions d'accès S3 pour EMR Serverless

Avec les EMR versions 6.15.0 et supérieures d'Amazon, Amazon S3 Access Grants fournit une solution de contrôle d'accès évolutive que vous pouvez utiliser pour augmenter l'accès à vos données Amazon S3 depuis Serverless. EMR Si vos exigences en matière de données S3 nécessitent une configuration d'autorisations complexe ou importante, vous pouvez utiliser S3 Access Grants pour mettre à l'échelle les autorisations de données S3 pour les utilisateurs, les groupes, les rôles et les applications.

Utilisez les subventions d'accès S3 pour augmenter l'accès aux données Amazon S3 au-delà des autorisations accordées par le rôle d'exécution ou IAM des rôles associés aux identités ayant accès à votre application EMR sans serveur.

Pour plus d'informations, consultez [Gestion de l'accès avec S3 Access Grants pour Amazon EMR](#) dans le Guide de EMR gestion Amazon et [Gestion de l'accès avec S3 Access Grants](#) dans le Guide de l'utilisateur d'Amazon Simple Storage Service.

Cette section décrit comment lancer une application EMR sans serveur qui utilise les autorisations d'accès S3 pour fournir un accès aux données dans Amazon S3. Pour savoir comment utiliser S3 Access Grants avec d'autres EMR déploiements Amazon, consultez la documentation suivante :

- [Utilisation de S3 Access Grants avec Amazon EMR](#)
- [Utilisation de S3 Access Grants avec Amazon EMR sur EKS](#)

## Lancez une application EMR sans serveur avec des autorisations d'accès S3 pour la gestion des données

Vous pouvez activer S3 Access Grants sur EMR Serverless et lancer une application Spark. Lorsque votre application demande à accéder aux données S3, Amazon S3 fournit des informations d'identification temporaires limitées au compartiment, au préfixe ou à l'objet concerné.

1. Configurez un rôle d'exécution de tâches pour votre application EMR Serverless. Incluez les IAM autorisations requises pour exécuter des tâches Spark et utiliser S3 Access Grants, `s3:GetDataAccess` et `s3:GetAccessGrantsInstanceForPrefix` :

```
{
  "Effect": "Allow",
  "Action": [
    "s3:GetDataAccess",
    "s3:GetAccessGrantsInstanceForPrefix"
  ],
  "Resource": [
    //LIST ALL INSTANCE ARNS THAT THE ROLE IS ALLOWED TO QUERY
    "arn:aws_partition:s3:Region:account-id1:access-grants/default",
    "arn:aws_partition:s3:Region:account-id2:access-grants/default"
  ]
}
```

### Note

Si vous spécifiez IAM des rôles pour l'exécution des tâches dotés d'autorisations supplémentaires pour accéder directement à S3, les utilisateurs pourront accéder aux données autorisées par le rôle même s'ils n'ont pas l'autorisation de S3 Access Grants.

2. Lancez votre application EMR Serverless avec une étiquette de EMR version Amazon 6.15.0 ou supérieure et la `spark-defaults` classification, comme le montre l'exemple suivant.

Remplacez les valeurs dans *red text* par les valeurs appropriées pour votre scénario d'utilisation.

```
aws emr-serverless start-job-run \  
  --application-id application-id \  
  --execution-role-arn job-role-arn \  
  --job-driver '{  
    "sparkSubmit": {  
      "entryPoint": "s3://us-east-1.elasticmapreduce/emr-containers/samples/  
wordcount/scripts/wordcount.py",  
      "entryPointArguments": ["s3://DOC-EXAMPLE-BUCKET-OUTPUT/  
wordcount_output"],  
      "sparkSubmitParameters": "--conf spark.executor.cores=1 --conf  
spark.executor.memory=4g --conf spark.driver.cores=1 --conf spark.driver.memory=4g  
--conf spark.executor.instances=1"  
    }  
  }' \  
  --configuration-overrides '{  
    "applicationConfiguration": [{  
      "classification": "spark-defaults",  
      "properties": {  
        "spark.hadoop.fs.s3.s3AccessGrants.enabled": "true",  
        "spark.hadoop.fs.s3.s3AccessGrants.fallbackToIAM": "false"  
      }  
    }  
  ]  
}'
```

## Considérations relatives aux autorisations d'accès S3 avec EMR Serverless

Pour obtenir des informations importantes sur l'assistance, la compatibilité et le comportement lorsque vous utilisez Amazon S3 Access Grants avec EMR Serverless, consultez les [considérations relatives aux subventions d'accès S3 avec Amazon EMR](#) dans le guide de EMR gestion Amazon.

## Enregistrement des API appels Amazon EMR Serverless à l'aide de AWS CloudTrail

Amazon EMR Serverless est intégré à AWS CloudTrail, un service qui fournit un enregistrement des actions entreprises par un utilisateur, un rôle ou un AWS service en mode EMR Serverless. CloudTrail capture tous les API appels pour EMR Serverless sous forme d'événements. Les appels

capturés incluent des appels provenant de la console EMR Serverless et des appels de code vers les opérations EMR Serverless API. Si vous créez un suivi, vous pouvez activer la diffusion continue d' CloudTrail événements vers un compartiment Amazon S3, y compris des événements pour EMR Serverless. Si vous ne configurez pas de suivi, vous pouvez toujours consulter les événements les plus récents dans la CloudTrail console dans Historique des événements. À l'aide des informations collectées par CloudTrail, vous pouvez déterminer la demande qui a été faite à EMR Serverless, l'adresse IP à partir de laquelle la demande a été faite, qui a fait la demande, quand elle a été faite et des détails supplémentaires.

Pour en savoir plus CloudTrail, consultez le [AWS CloudTrail Guide de l'utilisateur](#).

## EMR Informations sans serveur dans CloudTrail

CloudTrail est activé sur votre Compte AWS lorsque vous créez le compte. Lorsqu'une activité se produit dans EMR Serverless, cette activité est enregistrée dans un CloudTrail événement avec d'autres AWS événements de service dans l'historique des événements. Vous pouvez consulter, rechercher et télécharger les événements récents dans votre Compte AWS. Pour plus d'informations, consultez la section [Affichage des événements à l'aide de l'historique des CloudTrail événements](#).

Pour un enregistrement continu des événements survenus dans votre Compte AWS, y compris les événements pour EMR Serverless, créez une trace. Un suivi permet CloudTrail de fournir des fichiers journaux à un compartiment Amazon S3. Par défaut, lorsque vous créez un parcours dans la console, celui-ci s'applique à tous Régions AWS. Le sentier enregistre les événements de toutes les régions du AWS partitionnez et transmettez les fichiers journaux au compartiment Amazon S3 que vous spécifiez. De plus, vous pouvez configurer d'autres AWS des services permettant d'analyser plus en détail les données d'événements collectées dans les CloudTrail journaux et d'agir en conséquence. Pour plus d'informations, consultez les ressources suivantes :

- [Présentation de la création d'un journal de suivi](#)
- [CloudTrail services et intégrations pris en charge](#)
- [Configuration des SNS notifications Amazon pour CloudTrail](#)
- [Réception de fichiers CloudTrail journaux de plusieurs régions](#) et [réception de fichiers CloudTrail journaux de plusieurs comptes](#)

Toutes les actions EMR sans serveur sont enregistrées CloudTrail et documentées dans la référence [EMR sans serveur API](#). Par exemple, les appels au `CreateApplication StartJobRun` et les `CancelJobRun` actions génèrent des entrées dans les fichiers CloudTrail journaux.



Chaque événement ou entrée de journal contient des informations sur la personne ayant initié la demande. Les informations relatives à l'identité permettent de déterminer les éléments suivants :

- Si la demande a été faite avec root ou AWS Identity and Access Management (IAM) informations d'identification de l'utilisateur.
- Si la demande a été effectuée avec les informations d'identification de sécurité temporaires d'un rôle ou d'un utilisateur fédéré.
- Si la demande a été faite par un autre AWS service.

Pour plus d'informations, consultez l'[CloudTrail userIdentity élément](#).

## Comprendre les EMR entrées des fichiers journaux sans serveur

Un suivi est une configuration qui permet de transmettre des événements sous forme de fichiers journaux à un compartiment Amazon S3 que vous spécifiez. CloudTrail les fichiers journaux contiennent une ou plusieurs entrées de journal. Un événement représente une demande unique provenant de n'importe quelle source et inclut des informations sur l'action demandée, la date et l'heure de l'action, les paramètres de la demande, etc. CloudTrail les fichiers journaux ne constituent pas une trace ordonnée des API appels publics, ils n'apparaissent donc pas dans un ordre spécifique.

L'exemple suivant montre une entrée de CloudTrail journal illustrant l'CreateApplicationaction.

```
{
  "eventVersion": "1.08",
  "userIdentity": {
    "type": "AssumedRole",
    "principalId": "AIDACKCEVSQ6C2EXAMPLE:admin",
    "arn": "arn:aws:sts::012345678910:assumed-role/Admin/admin",
    "accountId": "012345678910",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "sessionContext": {
      "sessionIssuer": {
        "type": "Role",
        "principalId": "AIDACKCEVSQ6C2EXAMPLE",
        "arn": "arn:aws:iam::012345678910:role/Admin",
        "accountId": "012345678910",
        "userName": "Admin"
      },
      "webIdFederationData": {},
    },
  },
}
```

```
        "attributes": {
            "creationDate": "2022-06-01T23:46:52Z",
            "mfaAuthenticated": "false"
        }
    },
    "eventTime": "2022-06-01T23:49:28Z",
    "eventSource": "emr-serverless.amazonaws.com",
    "eventName": "CreateApplication",
    "awsRegion": "us-west-2",
    "sourceIPAddress": "203.0.113.0",
    "userAgent": "PostmanRuntime/7.26.10",
    "requestParameters": {
        "name": "my-serverless-application",
        "releaseLabel": "emr-6.6",
        "type": "SPARK",
        "clientToken": "0a1b234c-de56-7890-1234-567890123456"
    },
    "responseElements": {
        "name": "my-serverless-application",
        "applicationId": "1234567890abcdef0",
        "arn": "arn:aws:emr-serverless:us-west-2:555555555555:/
applications/1234567890abcdef0"
    },
    "requestID": "890b8639-e51f-11e7-b038-EXAMPLE",
    "eventID": "874f89fa-70fc-4798-bc00-EXAMPLE",
    "readOnly": false,
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "012345678910",
    "eventCategory": "Management"
}
```

## Validation de conformité pour Amazon EMR Serverless

La sécurité et la conformité de EMR Serverless sont évaluées par des auditeurs tiers dans le cadre de plusieurs AWS des programmes de conformité, notamment les suivants :

- Contrôles du système et de l'organisation (SOC)
- Norme de sécurité des données du secteur des cartes de paiement (PCIDSS)
- Programme fédéral de gestion des risques et des autorisations (FedRAMP) modéré

- Loi sur la portabilité et la responsabilité de l'assurance maladie (HIPAA)

AWS fournit une liste fréquemment mise à jour des AWS services dans le cadre de programmes de conformité spécifiques à [AWS Services visés par le programme de conformité](#).

Les rapports d'audit tiers peuvent être téléchargés à l'aide de AWS Artifact. Pour plus d'informations, voir [Téléchargement de rapports dans AWS Artifact](#).

Pour plus d'informations sur AWS programmes de conformité, voir [AWS Programmes de conformité](#).

Lorsque vous utilisez EMR Serverless, votre responsabilité en matière de conformité dépend de la sensibilité de vos données, des objectifs de conformité de votre entreprise et des lois et réglementations applicables. Si votre utilisation de EMR Serverless est soumise au respect de normes telles que HIPAAPCI, ou Fed RAMP Moderate, AWS fournit des ressources pour vous aider à :

- [Guides de démarrage rapide sur la sécurité et la conformité](#) qui abordent les considérations architecturales et les étapes à suivre pour déployer des environnements de base axés sur la sécurité et la conformité sur AWS.
- [AWS Les guides de conformité destinés aux clients](#) peuvent vous aider à comprendre le modèle de responsabilité partagée sous l'angle de la conformité. Les guides résument les meilleures pratiques en matière de sécurisation Services AWS et cartographiez les directives relatives aux contrôles de sécurité dans de multiples cadres (notamment le National Institute of Standards and Technology (NIST), le Payment Card Industry Security Standards Council (PCI) et l'Organisation internationale de normalisation (ISO)).
- [AWS Config](#) Le service peut permettre d'évaluer comment les configurations de vos ressources se conforment aux pratiques internes, aux normes et aux directives industrielles.
- [AWS Les ressources de conformité](#) sont un ensemble de classeurs et de guides qui peuvent s'appliquer à votre secteur d'activité et à votre région.
- [AWS Security Hub vous](#) fournit une vue complète de votre état de sécurité au sein de AWS et vous aide à vérifier votre conformité aux normes et aux meilleures pratiques du secteur de la sécurité.
- [AWS Audit Manager](#)— ce Service AWS vous aide à auditer en permanence votre AWS utilisation pour simplifier la gestion des risques et la conformité aux réglementations et aux normes du secteur.

## Résilience dans Amazon EMR Serverless

Le AWS l'infrastructure mondiale est construite autour de AWS Régions et zones de disponibilité. AWS Les régions fournissent plusieurs zones de disponibilité physiquement séparées et isolées, reliées par un réseau à latence faible, à haut débit et hautement redondant. Avec les zones de disponibilité, vous pouvez concevoir et exploiter des applications et des bases de données qui basculent automatiquement d'une zone à l'autre sans interruption. Les zones de disponibilité sont davantage disponibles, tolérantes aux pannes et ont une plus grande capacité de mise à l'échelle que les infrastructures traditionnelles à un ou plusieurs centres de données.

Pour plus d'informations sur AWS Régions et zones de disponibilité, voir [AWS Infrastructure mondiale](#).

En plus du AWS infrastructure mondiale, Amazon EMR Serverless propose une intégration à Amazon S3 pour vous aider EMRFS à répondre à vos besoins en matière de résilience et de sauvegarde des données.

## Sécurité de l'infrastructure dans Amazon EMR Serverless

En tant que service géré, Amazon EMR est protégé par AWS sécurité du réseau mondial. Pour plus d'informations sur AWS services de sécurité et comment AWS protège l'infrastructure, voir [AWS Sécurité dans le cloud](#). Pour concevoir votre AWS environnement utilisant les meilleures pratiques en matière de sécurité de l'infrastructure, voir [Protection de l'infrastructure](#) dans le pilier de sécurité AWS Framework bien conçu.

Vous utilisez AWS API appels publiés pour accéder à Amazon EMR via le réseau. Les clients doivent prendre en charge les éléments suivants :

- Sécurité de la couche de transport (TLS). Nous avons besoin de la TLS version 1.2 et recommandons la TLS version 1.3.
- Des suites de chiffrement parfaitement confidentielles (PFS) telles que (Ephemeral Diffie-Hellman) ou DHE ECDHE (Elliptic Curve Ephemeral Diffie-Hellman). La plupart des systèmes modernes tels que Java 7 et les versions ultérieures prennent en charge ces modes.

En outre, les demandes doivent être signées à l'aide d'un identifiant de clé d'accès et d'une clé d'accès secrète associés à un IAM principal. Ou vous pouvez utiliser [AWS Security Token Service](#) (AWS STS) pour générer des informations de sécurité temporaires pour signer les demandes.

# Analyse de configuration et de vulnérabilité dans Amazon EMR Serverless

AWS gère les tâches de sécurité de base telles que l'application de correctifs au système d'exploitation client (OS) et aux bases de données, la configuration du pare-feu et la reprise après sinistre. Ces procédures ont été vérifiées et certifiées par les tiers appropriés. Pour plus de détails, consultez les ressources suivantes :

- [Validation de conformité pour Amazon EMR Serverless](#)
- [Modèle de responsabilité partagée](#)
- [Amazon Web Services : Présentation des procédures de sécurité](#) (livre blanc)

# Points de terminaison et quotas pour EMR Serverless

## Points de terminaison de service

Pour vous connecter par programmation à un Service AWS, vous utilisez un point de terminaison. Un point URL de terminaison est le point d'entrée d'un AWS service Web. En plus de la norme AWS points de terminaison, certains Services AWS proposer des FIPS points de terminaison dans certaines régions. Le tableau suivant répertorie les points de terminaison de service pour EMR Serverless. Pour plus d'informations, consultez [Service AWS points de terminaison](#).

Nom de la région	Région	Point de terminaison	Protocole
USA Est (Ohio)	us-east-2 (limité aux zones de disponibilité suivantes : use2-az1, use2-az2, et use2-az3)	emr-serverless.us-east-2.amazonaws.com	HTTPS
USA Est (Virginie du Nord)	us-east-1 (limité aux zones de disponibilité suivantes : use1-az1, use1-az2, use1-az4, use1-az5, et use1-az6)	emr-serverless.us-east-1.amazonaws.com  emr-serverless-fips.us-east-1.amazonaws.com	HTTPS
USA Ouest (Californie du Nord)	us-west-1	emr-serverless.us-west-1.amazonaws.com	HTTPS
USA Ouest (Oregon)	us-west-2	emr-serverless.us-	HTTPS

Nom de la région	Région	Point de terminaison	Protocole
		west-2.amazonaws.com  emr-serverless-fips.us-west-2.amazonaws.com	
Afrique (Le Cap)	af-south-1	emr-serverless.af-south-1.amazonaws.com	HTTPS
Asie-Pacifique (Hong Kong)	ap-east-1	emr-serverless.ap-east-1.amazonaws.com	HTTPS
Asie-Pacifique (Jakarta)	ap-southeast-3	emr-serverless.ap-southeast-3.amazonaws.com	HTTPS
Asie-Pacifique (Mumbai)	ap-south-1	emr-serverless.ap-south-1.amazonaws.com	HTTPS
Asie-Pacifique (Osaka)	ap-northeast-3	emr-serverless.ap-northeast-3.amazonaws.com	HTTPS

Nom de la région	Région	Point de terminaison	Protocole
Asia Pacific (Seoul)	ap-northeast-2	emr-serverless.ap-northeast-2.amazonaws.com	HTTPS
Asie-Pacifique (Singapour)	ap-southeast-1	emr-serverless.ap-southeast-1.amazonaws.com	HTTPS
Asie-Pacifique (Sydney)	ap-southeast-2	emr-serverless.ap-southeast-2.amazonaws.com	HTTPS
Asie-Pacifique (Tokyo)	ap-northeast-1	emr-serverless.ap-northeast-1.amazonaws.com	HTTPS
Canada (Centre)	ca-central-1 (limité aux zones de disponibilité suivantes : cac1-az1 etcac1-az2)	emr-serverless.ca-central-1.amazonaws.com	HTTPS
Europe (Francfort)	eu-central-1	emr-serverless.eu-central-1.amazonaws.com	HTTPS



Nom de la région	Région	Point de terminaison	Protocole
Europe (Irlande)	eu-west-1	emr-serverless.eu-west-1.amazonaws.com	HTTPS
Europe (Londres)	eu-west-2	emr-serverless.eu-west-2.amazonaws.com	HTTPS
Europe (Milan)	eu-south-1	emr-serverless.eu-south-1.amazonaws.com	HTTPS
Europe (Paris)	eu-west-3	emr-serverless.eu-west-3.amazonaws.com	HTTPS
Europe (Espagne)	eu-south-2	emr-serverless.eu-south-2.amazonaws.com	HTTPS
Europe (Stockholm)	eu-north-1	emr-serverless.eu-north-1.amazonaws.com	HTTPS
Moyen-Orient (Bahreïn)	me-south-1	emr-serverless.me-south-1.amazonaws.com	HTTPS

Nom de la région	Région	Point de terminaison	Protocole
Moyen-Orient (UAE)	me-central-1	emr-serverless.me-central-1.amazonaws.com	HTTPS
Amérique du Sud (São Paulo)	sa-east-1	emr-serverless.sa-east-1.amazonaws.com	HTTPS
AWS GovCloud (USA Est)	us-gov-east-1	emr-serverless.us-gov-east-1.amazonaws.com	HTTPS
AWS GovCloud (US-Ouest)	us-gov-west-1	emr-serverless.us-gov-west-1.amazonaws.com	HTTPS

## Quotas de service

Les quotas de service, également appelés limites, sont le nombre maximum de ressources de service ou d'opérations que votre Compte AWS peut utiliser. EMRServerless collecte les métriques d'utilisation des quotas de service toutes les minutes et les publie dans l'espace de AWS/Usage noms.

### Note

New AWS les comptes peuvent avoir des quotas initiaux inférieurs qui peuvent augmenter au fil du temps. Amazon EMR Serverless surveille l'utilisation des comptes au sein de chaque Région AWS, puis augmente automatiquement les quotas en fonction de votre utilisation.

Le tableau suivant répertorie les quotas de service pour EMR Serverless. Pour plus d'informations, consultez [Service AWS quotas](#).

Nom	Limite par défaut	Ajustable?	Description
Nombre maximal de simultanés vCPUs par compte	16	Oui	Le nombre maximum de vCPUs personnes pouvant être exécutées simultanément pour le compte dans le Région AWS.

## API limites

Ce qui suit décrit les API limites par région pour votre Compte AWS.

Ressource	Quota par défaut
<a href="#">ListApplications</a>	10 transactions par seconde. Une rafale de 50 transactions par seconde.
<a href="#">CreateApplication</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">DeleteApplication</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">GetApplication</a>	10 transactions par seconde. Une rafale de 50 transactions par seconde.
<a href="#">UpdateApplication</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">ListJobRuns</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">StartJobRun</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.

Ressource	Quota par défaut
<a href="#">GetDashboardForJobRun</a>	1 transaction par seconde. Une rafale de 2 transactions par seconde.
<a href="#">CancelJobRun</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">GetJobRun</a>	10 transactions par seconde. Une rafale de 50 transactions par seconde.
<a href="#">StartApplication</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.
<a href="#">StopApplication</a>	1 transaction par seconde. Une rafale de 25 transactions par seconde.

## Autres considérations

La liste suivante contient d'autres considérations relatives à EMR Serverless.

- EMRServerless est disponible dans les versions suivantes Régions AWS:
  - USA Est (Ohio)
  - USA Est (Virginie du Nord)
  - USA Ouest (Californie du Nord)
  - USA Ouest (Oregon)
  - Afrique (Le Cap)
  - Asie-Pacifique (Hong Kong)
  - Asie-Pacifique (Jakarta)
  - Asie-Pacifique (Mumbai)
  - Asie-Pacifique (Osaka)
  - Asia Pacific (Seoul)
  - Asie-Pacifique (Singapour)
  - Asie-Pacifique (Sydney)
  - Asie-Pacifique (Tokyo)
  - Canada (Centre)
  - Europe (Francfort)
  - Europe (Irlande)
  - Europe (Londres)
  - Europe (Milan)
  - Europe (Paris)
  - Europe (Espagne)
  - Europe (Stockholm)
  - Moyen-Orient (Bahreïn)
  - Moyen-Orient (UAE)
  - Amérique du Sud (São Paulo)
- AWS GovCloud (USA Est)
- AWS GovCloud (US-Ouest)

Pour obtenir la liste des points de terminaison associés à ces régions, consultez [Points de terminaison de service](#).

- Le délai d'expiration par défaut pour l'exécution d'une tâche est de 12 heures. Vous pouvez modifier ce paramètre à l'aide de la `executionTimeoutMinutes` propriété dans le `startJobRun` API ou AWS SDK. Vous pouvez `executionTimeoutMinutes` définir la valeur 0 si vous souhaitez que l'exécution de votre tâche ne s'arrête jamais. Par exemple, si vous avez une application de streaming, vous pouvez définir la valeur 0 `executionTimeoutMinutes` pour permettre à la tâche de streaming de s'exécuter en continu.
- La `billedResourceUtilization` propriété dans le `getJobRun` API indique l'agrégat vCPU, la mémoire et le stockage qui AWS a facturé l'exécution du travail. Les ressources facturées incluent une utilisation minimale d'une minute pour les employés, ainsi qu'un stockage supplémentaire de plus de 20 Go par travailleur. Ces ressources n'incluent pas l'utilisation pour les travailleurs préinitialisés inactifs.
- Sans VPC connectivité, une tâche peut accéder à certains Service AWS points de terminaison dans le même Région AWS. Ces services incluent Amazon S3, AWS Glue, Amazon CloudWatch Logs, AWS KMS, AWS Security Token Service, Amazon DynamoDB, et AWS Secrets Manager. Vous pouvez activer la VPC connectivité pour accéder à d'autres Services AWS à travers [AWS PrivateLink](#), mais vous n'êtes pas obligé de le faire. Pour accéder à des services externes, vous pouvez créer votre application avec unVPC.
- EMRLe mode Serverless n'est pas compatibleHDFS. Les disques locaux situés sur les travailleurs constituent un stockage temporel que EMR Serverless utilise pour mélanger et traiter les données lors de l'exécution des tâches.
- EMRServerless ne prend pas en charge l'existant [emr-dynamodb-connector](#).

# Versions publiées d'Amazon EMR Serverless

Une EMR version d'Amazon est un ensemble d'applications open source issues de l'écosystème des mégadonnées. Chaque version inclut des applications, des composants et des fonctionnalités Big Data que vous sélectionnez pour qu'Amazon EMR Serverless déploie et configure lorsque vous exécutez votre tâche.

Avec Amazon EMR 6.6.0 et versions ultérieures, vous pouvez déployer EMR Serverless. Cette option de déploiement n'est pas disponible avec les EMR versions antérieures d'Amazon. Lorsque vous soumettez votre travail, vous devez spécifier l'une des versions prises en charge suivantes.

## Rubriques

- [EMR Serverless 7.2.0](#)
- [EMR Serverless 7.1.0](#)
- [EMR Serverless 7.0.0](#)
- [EMR Serverless 6,15,0](#)
- [EMR Serverless 6,14.0](#)
- [EMR Serverless 6,13.0](#)
- [EMR Serverless 6,12,0](#)
- [EMR Serverless 6,11,0](#)
- [EMR Serverless 6.10.0](#)
- [EMR Serverless 6,9.0](#)
- [EMR Serverless 6,8.0](#)
- [EMR Serverless 6.7.0](#)
- [EMR Serverless 6.6.0](#)

## EMR Serverless 7.2.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 7.2.0.

Application	Version
Apache Spark	3.5.1

Application	Version
Apache Hive	3.1.3
Apache Tez	0,1,2

### EMRNotes de mise à jour de Serverless 7.2.0

- Lake Formation avec EMR Serverless — vous pouvez désormais utiliser AWS Lake Formation pour appliquer des contrôles d'accès précis sur les tables du catalogue de données soutenues par S3. Cette fonctionnalité vous permet de configurer des contrôles d'accès au niveau des tables, des lignes, des colonnes et des cellules pour les requêtes de lecture dans vos tâches Spark EMR sans serveur. Pour plus d'informations, consultez [the section called “Lake Formation pour FGAC”](#) et [the section called “Considérations”](#).

## EMR Serverless 7.1.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 7.1.0.

Application	Version
Apache Spark	3.5.0
Apache Hive	3.1.3
Apache Tez	0,1,2

## EMR Serverless 7.0.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 7.0.0.

Application	Version
Apache Spark	3.5.0
Apache Hive	3.1.3



Application	Version
Apache Tez	0,1,2

## EMR Serverless 6,15,0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6,15.0.

Application	Version
Apache Spark	3.4.1
Apache Hive	3.1.3
Apache Tez	0,1,2

### EMR Notes de mise à jour de Serverless 6.15.0

- **TLS support** — Avec les versions 6.15.0 et supérieures d'Amazon EMR Serverless, vous pouvez activer les communications TLS cryptées entre les collaborateurs lors de vos exécutions de tâches Spark. Lorsqu'il est activé, EMR Serverless génère automatiquement un certificat unique pour chaque travailleur, qu'il fournit dans le cadre d'une exécution de tâches que les travailleurs utilisent lors de la TLS poignée de main pour s'authentifier mutuellement et établir un canal crypté pour traiter les données en toute sécurité. Pour plus d'informations sur le TLS chiffrement mutuel, consultez la section [Chiffrement inter-opérateurs](#).

## EMR Serverless 6,14.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6,14.0.

Application	Version
Apache Spark	3.4.1
Apache Hive	3.1.3

Application	Version
Apache Tez	0,1,2

## EMR Serverless 6,13,0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6,13,0.

Application	Version
Apache Spark	3.4.1
Apache Hive	3.1.3
Apache Tez	0,1,2

## EMR Serverless 6,12,0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.12,0.

Application	Version
Apache Spark	3.4.0
Apache Hive	3.1.3
Apache Tez	0,1,2

## EMR Serverless 6,11,0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6,11,0.

Application	Version
Apache Spark	3.3.2

Application	Version
Apache Hive	3.1.3
Apache Tez	0,1,2

### EMRNotes de mise à jour de Serverless 6.11.0

- [Accès aux ressources S3 depuis d'autres comptes](#) : avec les versions 6.11.0 et supérieures, vous pouvez configurer plusieurs IAM rôles à assumer lorsque vous accédez à des compartiments Amazon S3 dans différents AWS comptes de EMR Serverless.

## EMR Serverless 6.10.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.10,0.

Application	Version
Apache Spark	3.3.1
Apache Hive	3.1.3
Apache Tez	0,1,2

### EMRNotes de mise à jour de Serverless 6.10.0

- Pour les applications EMR sans serveur de version 6.10.0 ou supérieure, la valeur par défaut de la propriété `estspark.dynamicAllocation.maxExecutors.infinity` Les versions antérieures sont définies par défaut sur `100`. Pour de plus amples informations, veuillez consulter [Propriétés de la tâche Spark](#).

## EMR Serverless 6,9.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.9.0.

Application	Version
Apache Spark	3.3.0
Apache Hive	3.1.3
Apache Tez	0,1,2

## EMRNotes de mise à jour de Serverless 6.9.0

- L'intégration Amazon Redshift pour Apache Spark est incluse dans les EMR versions 6.9.0 et ultérieures d'Amazon. Auparavant un outil open-source, l'intégration native est un connecteur Spark que vous pouvez utiliser pour créer des applications Apache Spark capables de lire et d'écrire des données sur Amazon Redshift et Amazon Redshift sans serveur. Pour de plus amples informations, veuillez consulter [Utilisation de l'intégration Amazon Redshift pour Apache Spark sur Amazon Serverless EMR](#).
- EMRLa version 6.9.0 sans serveur ajoute la prise en charge de AWS Architecture de Graviton 2 (arm64). Vous pouvez utiliser le `architecture` paramètre pour `create-application` et pour `update-application` APIs choisir l'architecture arm64. Pour de plus amples informations, veuillez consulter [Options d'architecture Amazon EMR Serverless](#).
- Vous pouvez désormais exporter, importer, interroger et joindre des tables Amazon DynamoDB directement depuis EMR vos applications Serverless Spark et Hive. Pour de plus amples informations, veuillez consulter [Connexion à DynamoDB avec Amazon Serverless EMR](#).

## Problèmes connus

- Si vous utilisez l'intégration Amazon Redshift à Apache Spark et que vous disposez d'un champ de type heure, `timetz`, horodatage ou `timestamptz` avec une précision de l'ordre de la microseconde au format Parquet, le connecteur arrondit les valeurs temporelles à la milliseconde la plus proche. Pour contourner le problème, utilisez le paramètre `unload_s3_format` de format de déchargement du texte.

## EMR Serverless 6,8.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.8.0.

Application	Version
Apache Spark	3.3.0
Apache Hive	3.1.3
Apache Tez	0.9.2

## EMR Serverless 6.7.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.7.0.

Application	Version
Apache Spark	3.2.1
Apache Hive	3.1.3
Apache Tez	0.9.2

## Modifications, améliorations et problèmes résolus spécifiques au moteur

Le tableau suivant répertorie une nouvelle fonctionnalité spécifique au moteur.

Modification	Description
Fonctionnalité	Le planificateur Tez prend désormais en charge la préemption de la tâche Tez au lieu de la préemption du conteneur

## EMR Serverless 6.6.0

Le tableau suivant répertorie les versions de l'application disponibles avec EMR Serverless 6.6.0.

Application	Version
Apache Spark	3.2.0
Apache Hive	3.1.2
Apache Tez	0.9.2

## EMRNotes de mise à jour initiales sans serveur

- EMRServerless prend en charge la classification `spark-defaults` de configuration Spark. Cette classification modifie les valeurs du `spark-defaults.conf` XML fichier de Spark. Les classifications de configuration vous permettent de personnaliser les applications. Pour plus d'informations, consultez [Configuration des applications](#).
- EMRServerless prend en charge les classifications de configuration `Hivehive-site`, `tez-siteemrfs-site`, et `core-site`. Cette classification peut modifier les valeurs du fichier Hive, du `hive-site.xml` `tez-site.xml` fichier de Tez, des EMRFS paramètres d'Amazon ou EMR du `core-site.xml` fichier Hadoop, respectivement. Les classifications de configuration vous permettent de personnaliser les applications. Pour plus d'informations, consultez [Configuration des applications](#).

## Modifications, améliorations et problèmes résolus spécifiques au moteur

- Le tableau suivant répertorie les rétroportages Hive et Tez.

### Changements liés à Hive et Tez

Modification	Description
Rétroportage	<a href="#">TEZ-4430</a> : Correction d'un problème de propriété <code>tez.task.launch.cmd-opts</code>
Rétroportage	<a href="#">HIVE-25971</a> : correction des retards d'arrêt des tâches Tez dus à l'ouverture d'un pool de threads en cache

## Historique du document

Le tableau suivant décrit les modifications importantes apportées à la documentation depuis la dernière version de EMR Serverless. Pour plus d'informations sur les mises à jour de cette documentation, vous pouvez vous abonner à un RSS flux.

Modification	Description	Date
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 7.2.0</a>	25 juillet 2024
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 7.1.0</a>	17 avril 2024
<a href="#">Mise à jour d'une politique existante.</a>	Le nouveau Sid CloudWatchPolicyStatement et a été ajouté EC2PolicyStatement <a href="#">à la mazonEMRServerless ServiceRolePolicy politique A.</a>	25 janvier 2024
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 7.0.0</a>	29 décembre 2023
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 6,15,0</a>	17 novembre 2023
<a href="#">Nouvelle fonction</a>	<a href="#">Configurez plusieurs IAM rôles à assumer lorsque vous accédez à des compartiments Amazon S3 dans différents comptes depuis EMR Serverless (6.11 et versions ultérieures)</a>	18 octobre 2023
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 6,14.0</a>	17 octobre 2023
<a href="#">Nouvelle fonction</a>	<a href="#">Configuration d'application par défaut pour EMR Serverless</a>	25 septembre 2023
<a href="#">Mise à jour des propriétés Hive par défaut</a>	Mise à jour des valeurs par défaut pour les <a href="#">propriétés des tâches hive.driv</a>	12 septembre 2023

	<a href="#">er.disk hive.tez. disk.size hive.tez. auto.reducer.paral lelism ,, et tez.group ing.min-size Hive.</a>	
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 6,13.0</a>	11 septembre 2023
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 6,12,0</a>	21 juillet 2023
<a href="#">Nouvelle version</a>	<a href="#">EMR Serverless 6,11,0</a>	8 juin 2023
<a href="#">Mise à jour de la politique relative aux rôles liés aux services</a>	Le <a href="#">AmazonEMRServerlessServiceRolePolicy</a> _SLRrôle a été mis à jour pour publier l'utilisation au niveau du compte dans "AWS/Usage" l'espace de noms.	20 avril 2023
<a href="#">EMR Serverless disponibilité générale (GA)</a>	Il s'agit de la première version publique de EMR Serverless.	1 juin 2022



Les traductions sont fournies par des outils de traduction automatique. En cas de conflit entre le contenu d'une traduction et celui de la version originale en anglais, la version anglaise prévaudra.