



Entwicklerhandbuch

Amazon Machine Learning



Version Latest

Copyright © 2026 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Amazon Machine Learning: Entwicklerhandbuch

Copyright © 2026 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Die Marken und Handelsmarken von Amazon dürfen nicht in einer Weise in Verbindung mit nicht von Amazon stammenden Produkten oder Services verwendet werden, die geeignet ist, Kunden irrezuführen oder Amazon in irgendeiner Weise herabzusetzen oder zu diskreditieren. Alle anderen Handelsmarken, die nicht Eigentum von Amazon sind, gehören den jeweiligen Besitzern, die möglicherweise zu Amazon gehören oder nicht, mit Amazon verbunden sind oder von Amazon gesponsert werden.

Table of Contents

.....	ix
Was ist Amazon Machine Learning?	1
Die wichtigsten Konzepte von Amazon Machine Learning	1
Datenquellen	1
ML-Modelle	4
Auswertungen	4
Stapelvoraussagen	5
Echtzeitvoraussagen	6
Zugriff auf Amazon Machine Learning	6
Regionen und Endpunkte	7
Preise für Amazon ML	8
Einschätzen von Stapelvoraussagekosten	8
Einschätzen von Echtzeit-Voraussagekosten	10
Machine Learning-Konzepte	11
Lösen von wirtschaftlichen Problemen mit Amazon Machine Learning	11
Einsatzgebiete von Machine Learning	12
Die Erstellung einer Machine Learning-Anwendung	13
Erarbeitung des Problems	13
Sammeln von Daten mit Bezeichnung	14
Analysieren Ihrer Daten	15
Feature-Verarbeitung	15
Aufteilung von Daten in Schulungs- und Evaluierungsdaten	17
Schulen des Modells	18
Evaluation der Modellrichtigkeit	21
Optimierung der Modellrichtigkeit	26
Mit dem Modell Voraussagenerstellen	27
Modelle auf neue Daten umschulen	28
Der Amazon Machine Learning Learning-Prozess	28
Einrichten von Amazon Machine Learning	31
Anmelden bei AWS	31
Tutorial: Verwenden von Amazon ML zum Voraussagen der Reaktionen auf ein Marketingangebot	32
Voraussetzung	32
Schritte	32

Schritt 1: Vorbereitung Ihrer Daten	33
Schritt 2: Erstellen einer Schulungsdatenquelle	35
Schritt 3: Erstellen eines ML-Modells	41
Schritt 4: Überprüfen der Voraussageleistung des ML-Modells und Festlegen eines Punktzahlschwellenwerts	42
Schritt 5: Verwenden des ML-Modells zum Generieren von Voraussagen	46
Schritt 6: Aufräumen	53
Erstellen und Verwenden von Datenquellen	55
Das Datenformat für Amazon ML verstehen	55
Attribute	56
Anforderungen an das Eingabedateiformat	56
Verwenden mehrerer Dateien als Dateneingabe für Amazon ML	57
End-of-Line Zeichen im CSV-Format	58
Erstellen eines Datenschemas für Amazon ML	59
Beispielschema	59
Das targetAttributeName Feld verwenden	61
Verwenden des Felds rowID	61
Verwenden des Felds AttributeType	62
Bereitstellung eines Schemas für Amazon ML	64
Aufteilen Ihrer Daten	65
Vorabtrennung Ihrer Daten	66
Sequenzielle Aufteilung Ihrer Daten	66
Zufällige Aufteilung Ihrer Daten	67
Dateneinblicke	69
Beschreibende Statistiken	69
Zugreifen auf Data Insights über die Amazon ML-Konsole	70
Amazon S3 mit Amazon ML verwenden	79
Ihre Daten auf Amazon S3 hochladen	80
Berechtigungen	81
Erstellen einer Amazon ML-Datenquelle aus Daten in Amazon Redshift	81
Erforderliche Parameter für den Assistenten Datenquelle erstellen	82
Erstellen einer Datenquelle mit Amazon Redshift Redshift-Daten (Konsole)	86
Behebung von Problemen mit Amazon Redshift	90
Verwenden von Daten aus einer Amazon RDS-Datenbank zur Erstellung einer Amazon ML-Datenquelle	96
RDS-Datenbank-Instance-Kennung	98

MySQL-Datenbankname	98
Benutzeranmeldeinformationen für die Datenbank	98
Sicherheitsinformationen zur AWS Data Pipeline	98
Amazon RDS-Sicherheitsinformationen	99
MySQL-SQL-Abfragen	99
S3-Ausgabespeicherort	100
Schulung von ML-Modellen	101
ML-Modelltypen	101
Binäres Klassifizierungsmodell	102
Mehrklassen-Klassifizierungsmodell	102
Regressionsmodell	102
Schulungsprozess	103
Schulungsparameter	103
Maximale Modellgröße	104
Maximale Anzahl von Datendurchläufen	105
Art der Mischung von Schulungsdaten	105
Regularisationstyp und -umfang	106
Schulungsparameter: Typen und Standardwerte	107
Erstellen eines ML-Modells	108
Voraussetzungen	109
Erstellen eines ML-Modells mit Standardoptionen	109
Erstellen eines ML-Modells mit benutzerdefinierten Optionen	110
Datentransformationen für maschinelles Lernen	113
Bedeutung der Funktionstransformation	113
Funktionstransformation mit Datenrezepten	114
Referenz zum Rezeptformat	114
Gruppen	115
Zuweisungen	116
Outputs	116
Beispiel eines vollständigen Rezepts	119
Empfohlene Rezepte	120
Referenz zur Datentransformation	120
N-Gramm-Transformation	121
Orthogonal Sparse Bigram (OSB)-Transformation	122
Umwandlung in Kleinbuchstaben	123
Transformation zum Entfernen von Satzzeichen	123

Quartile-Binning-Transformation	124
Normierungstransformation	125
Kartesische Produkt-Transformation	125
Neuordnung von Daten	127
DataRearrangement Parameter	128
Evaluation von ML-Modellen	132
Einblicke in ML-Modelle	133
Einblicke in binäre Modelle	133
Interpretieren der Voraussagen	133
Einblicke in Mehrklassen-Modelle	138
Interpretieren der Voraussagen	138
Regressionsmodell-Einblicke	140
Interpretieren der Voraussagen	140
Verhindern von Overfitting	142
Kreuzvalidierung	143
Anpassen Ihrer Modelle	145
Auswertungswarnungen	146
Generieren und Interpretieren von Voraussagen	148
Erstellen einer Stapelvoraussage	148
Erstellen einer Stapelvoraussage (Konsole)	149
Erstellen einer Stapelvoraussage (API)	149
Überprüfen von Stapelvoraussage-Metriken	150
Überprüfen von Stapelvoraussage-Metriken (Konsole)	151
Überprüfen von Stapelvoraussage-Metriken und -Details (API)	151
Lesen der Ausgangsdateien für Stapelvoraussagen	151
Suchen der Manifestdatei für Stapelvoraussagen	152
Lesen der Manifestdatei	152
Abrufen der Ausgangsdateien für Stapelvoraussagen	153
Den Inhalt von Stapelvoraussagedateien für ein binäres ML-Klassifikationsmodell interpretieren	153
Den Inhalt von Stapelvoraussagedateien für ein Multiclass-ML-Klassifikationsmodell interpretieren	154
Den Inhalt von Stapelvoraussagedateien für ein Regressions-ML-Modell interpretieren	156
Anfordern von Echtzeitvoraussagen	156
Testen von Echtzeitvoraussagen	157
Erstellen eines Echtzeitendpunkts	159

Auffinden des Endpunkts für Echtzeitvoraussagen (Konsole)	161
Auffinden des Endpunkts für Echtzeitvoraussagen (API)	161
Erstellen einer Echtzeitvoraussage-Anforderung	162
Löschen eines Echtzeitendpunkts	164
Amazon ML-Objekte verwalten	166
Auflisten von Objekten	166
Auflisten von Objekten (Konsole)	167
Auflisten von Objekten (API)	168
Das Abrufen von Objektbeschreibungen	169
Detaillierte Beschreibungen in der Konsole	169
Detaillierte Beschreibungen von der API	169
Aktualisieren von Objekten	170
Löschen von Objekten	170
Löschen von Objekten (Konsole)	171
Löschen von Objekten (API)	172
Überwachung von Amazon ML mit Amazon CloudWatch Metrics	173
Protokollieren von Amazon ML-API-Aufrufen mit AWS CloudTrail	174
Amazon ML-Informationen in CloudTrail	174
Beispiel: Amazon ML-Protokolldateieinträge	176
Markieren von Objekten	180
Grundlagen zu Tags	180
Tag-Einschränkungen	181
Taggen von Amazon ML-Objekten (Konsole)	182
Taggen von Amazon ML-Objekten (API)	184
Amazon Machine Learning-Referenz	185
Gewähren von Amazon ML-Berechtigungen zum Lesen von Daten aus Amazon S3	185
Gewähren von Berechtigungen für Amazon ML zwecks Ausgabe von Voraussagen in Amazon S3	187
Steuern des Zugriffs auf Amazon ML-Ressourcen – mit IAM	190
Syntax der IAM-Richtlinie	191
Spezifizieren von IAM-Richtlinienaktionen für Amazon ML MLAmazon	192
Angabe von ARNs Amazon ML-Ressourcen in IAM-Richtlinien	193
Beispielrichtlinien für Amazon MLs	194
Serviceübergreifende Confused-Deputy-Prävention	197
Dependency Management von asynchrone Operationen	199
Das Überprüfen des Status einer Anfrage	200

Systemeinschränkungen	201
Namen und IDs für alle Objekte	202
Objektlebensdauer	203
Ressourcen	204
Dokumentverlauf	205

Wir aktualisieren den Amazon Machine Learning Learning-Service nicht mehr und akzeptieren auch keine neuen Benutzer mehr dafür. Diese Dokumentation ist für bestehende Benutzer verfügbar, wir aktualisieren sie jedoch nicht mehr. Weitere Informationen finden Sie unter [Was ist Amazon Machine Learning](#).

Die vorliegende Übersetzung wurde maschinell erstellt. Im Falle eines Konflikts oder eines Widerspruchs zwischen dieser übersetzten Fassung und der englischen Fassung (einschließlich infolge von Verzögerungen bei der Übersetzung) ist die englische Fassung maßgeblich.

Was ist Amazon Machine Learning?

Wir aktualisieren den Service Amazon Machine Learning (Amazon ML) nicht mehr und akzeptieren auch keine neuen Nutzer mehr dafür. Diese Dokumentation ist für bestehende Benutzer verfügbar, wir aktualisieren sie jedoch nicht mehr.

AWS bietet jetzt einen robusten, cloudbasierten Service — Amazon SageMaker AI —, sodass Entwickler aller Qualifikationsstufen die Technologie für maschinelles Lernen nutzen können. SageMaker KI ist ein vollständig verwalteter Service für maschinelles Lernen, mit dem Sie leistungsstarke Modelle für maschinelles Lernen erstellen können. Mit SageMaker KI können Datenwissenschaftler und Entwickler Modelle für maschinelles Lernen erstellen und trainieren und sie dann direkt in einer produktionsbereiten gehosteten Umgebung bereitstellen.

Weitere Informationen finden Sie in der [SageMaker KI-Dokumentation](#).

Themen

- [Die wichtigsten Konzepte von Amazon Machine Learning](#)
- [Zugriff auf Amazon Machine Learning](#)
- [Regionen und Endpunkte](#)
- [Preise für Amazon ML](#)

Die wichtigsten Konzepte von Amazon Machine Learning

In diesem Abschnitt werden die folgenden Schlüsselkonzepte zusammengefasst und detaillierter beschrieben, wie sie in Amazon ML verwendet werden:

- [Datenquellen](#) enthalten Metadaten, die mit Dateneingaben in Amazon ML verknüpft sind
- [ML-Modelle](#) generieren Voraussagen mithilfe der aus den Eingabedaten extrahierten Muster
- [Auswertungen](#) messen die Qualität von ML-Modellen
- [Stapelvoraussagen](#) generieren Voraussagen asynchron für mehrere Eingabedatenbeobachtungen
- [Echtzeitvoraussagen](#) generieren Voraussagen synchron für einzelne Datenbeobachtungen

Datenquellen

Eine Datenquelle ist ein Objekt, das Metadaten zu Ihren Eingabedaten enthält. Amazon ML liest Ihre Eingabedaten, berechnet deskriptive Statistiken zu ihren Attributen und speichert die Statistiken —

zusammen mit einem Schema und anderen Informationen — als Teil des Datenquellenobjekts. Als Nächstes verwendet Amazon ML die Datenquelle, um ein ML-Modell zu trainieren und auszuwerten und Batch-Vorhersagen zu generieren.

Important

Eine Datenquelle speichert keine Kopie Ihrer Eingabedaten. Stattdessen wird ein Verweis auf den Speicherort in Amazon S3 gespeichert, an dem sich Ihre Eingabedaten befinden. Wenn Sie die Amazon S3 S3-Datei verschieben oder ändern, kann Amazon ML nicht darauf zugreifen oder sie verwenden, um ein ML-Modell zu erstellen, Bewertungen zu generieren oder Prognosen zu generieren.

In der folgenden Tabelle sind Bedingungen definiert, die im Zusammenhang mit Datenquellen stehen.

Laufzeit	Definition
Attribut	<p>Eine eindeutige und benannte Eigenschaft innerhalb einer Beobachtung. In tabellarischen Daten (z. B. Kalkulationstabellen oder Dateien im CSV-Format (durch Komma getrennte Werte)) stellen die Spaltenüberschriften die Attribute dar, in den Zeilen sind Werte für diese Attribute enthalten.</p> <p>Synonyme: Variable, Variablenname, Feld, Spalte</p>
Datenquellenname	<p>(Optional) Sie können einen lesbaren Namen für eine Datenquelle definieren. Diese Namen ermöglichen es Ihnen, Ihre Datenquellen in der Amazon ML-Konsole zu finden und zu verwalten.</p>
Eingabedaten	<p>Sammelbezeichnung für alle Beobachtungen, auf die von einer Datenquelle verwiesen wird.</p>
Ort	<p>Speicherort der Eingabedaten. Derzeit kann Amazon ML Daten verwenden, die in Amazon S3-Buckets, Amazon Redshift Redshift-Datenbanken oder MySQL-Datenbanken in Amazon Relational Database Service (RDS) gespeichert sind.</p>
Beobachtung	<p>Eine einzelne Einheit von Eingabedaten. Wenn Sie beispielsweise ein ML-Modell erstellen, um betrügerische Transaktionen zu ermitteln, bestehen</p>

Laufzeit	Definition
	<p>Ihre Eingabedaten aus vielen Beobachtungen, von denen jede eine einzelne Transaktion darstellt.</p> <p>Synonyme: Datensatz, Beispiel, Instanz, Zeile</p>
Zeilen-ID	<p>(Optional) – Ein Flag, das, falls angegeben, ein Attribut in den Eingabedaten identifiziert, das in das Voraussageergebnis eingeschlossen werden soll. Anhand dieses Attributs kann einfacher zugeordnet werden, welche Voraussage welcher Beobachtung entspricht.</p> <p>Synonyme: Zeilen-ID</p>
Schema	<p>Die Informationen, die zur Deutung der Eingabedaten benötigt werden, einschließlich Attributnamen und ihre zugeordneten Datentypen sowie die Namen besonderer Attribute.</p>
Statistiken	<p>Zusammenfassende Statistik für jedes Attribut in den Eingabedaten. Diese Statistiken dienen zwei Zwecken:</p> <p>Die Amazon ML-Konsole zeigt sie in Diagrammen an, damit Sie Ihre Daten besser verstehen at-a-glance und Unregelmäßigkeiten oder Fehler erkennen können.</p> <p>Amazon ML verwendet sie während des Trainingsprozesses, um die Qualität des resultierenden ML-Modells zu verbessern.</p>
Status	<p>Gibt den aktuellen Status der Datenquelle an, beispielsweise Laufend, Abgeschlossen oder Fehlgeschlagen.</p>
Zielattribut	<p>Beim Training eines ML-Modells identifiziert das Zielattribut den Namen des Attributs in den Eingabedaten, das die „richtigen“ Antworten enthält. Amazon ML verwendet dies, um Muster in den Eingabedaten zu erkennen und ein ML-Modell zu generieren. Im Kontext des Auswertens und Generierens von Voraussagen, ist das Zielattribut das Attribut, dessen Wert vorhergesagt von einem qualifizierten ML-Modell vorhergesagt wird.</p> <p>Synonyme: Ziel</p>

ML-Modelle

Ein ML-Modell ist ein mathematisches Modell, das Vorhersagen generiert, indem es Muster in Ihren Daten findet. Amazon ML unterstützt drei Arten von ML-Modellen: binäre Klassifikation, Mehrklassenklassifikation und Regression.

In der folgenden Tabelle sind Begriffe definiert, die im Zusammenhang mit ML-Modellen stehen.

Laufzeit	Definition
Regression	Das Ziel der Schulung eines Regressions-ML-Modells besteht darin, einen numerischen Wert vorherzusagen.
Mehrklassen	Das Ziel der Schulung eines Mehrklassen-ML-Modells besteht darin, Werte vorherzusagen, die zu einem begrenzten und vordefinierten Satz an zulässigen Werten gehören.
Binär	Das Ziel der Schulung eines Binär-ML-Modells besteht darin, Werte vorherzusagen, die nur einen von zwei Status aufweisen können, z. B. "true" oder "false".
Modellgröße	ML-Modelle erfassen und speichern Muster. Je mehr Muster in einem ML-Modell gespeichert sind, desto größer ist es. Die ML-Modellgröße wird in MB beschrieben.
Anzahl der Durchläufe	Wenn Sie ein ML-Modell schulen, verwenden Sie Daten aus einer Datenquelle. Es ist manchmal von Vorteil, jeden Datensatz im Lernprozess mehrmals zu verwenden. Die Häufigkeit, mit der Sie Amazon ML dieselben Datensätze verwenden lassen, wird als Anzahl der Durchläufe bezeichnet.
Regularisation	Regularisierung ist eine Technik des maschinellen Lernens, mit der Sie qualitativ hochwertigere Modelle erhalten können. Amazon ML bietet eine Standardeinstellung, die in den meisten Fällen gut funktioniert.

Auswertungen

Eine Auswertung misst die Qualität Ihres ML-Modells und bestimmt, ob es gute Leistungen bringt.

In der folgenden Tabelle sind Begriffe im Zusammenhang mit Auswertungen definiert.

Laufzeit	Definition
Einblicke in Modelle	Amazon ML bietet Ihnen eine Metrik und eine Reihe von Erkenntnissen, anhand derer Sie die Prognoseleistung Ihres Modells bewerten können.
AUC	AUC (Area Under the ROC Curve) misst die Fähigkeit eines binären ML-Modells, eine höhere Bewertung für positive Beispiele im Vergleich zu negativen Beispielen vorherzusagen.
F1-Bewertung mit Makro-Durchschnitt	Die F1-Bewertung mit Makro-Durchschnitt wird zum Auswerten der prädiktiven Leistung von Mehrklassen-ML-Modellen verwendet.
RMSE	Der Root Mean Square Error (RMSE) ist eine Metrik zur Bewertung der prädiktiven Leistung von Regressions-ML-Modellen.
Grenzwert	ML-Modelle arbeiten durch Generierung von numerischen Voraussageergebnissen. Durch Anwenden eines Grenzwerts konvertiert das System diese Werte in 0- und 1-Bezeichnungen.
Accuracy	Die Richtigkeit misst den Anteil der richtigen Voraussagen.
Genauigkeit	„Precision“ zeigt den Prozentsatz der tatsächlichen positiven Instances (im Gegensatz zu Fehlalarmen) unter den Instances an, die abgerufen wurden (diejenigen, die als positiv vorausgesagt wurden). Mit anderen Worten: Wie viele ausgewählte Elemente sind positiv?
Wiedererkennung	„Recall“ zeigt den Prozentsatz der tatsächlichen positiven Instances in der Gesamtanzahl der betreffenden Instances an (tatsächliche positive Instances). Mit anderen Worten: Wie viele positive Elemente sind ausgewählt?

Stapelvoraussagen

Stapelvoraussagen werden für eine Reihe von Beobachtungen verwendet, die alle gleichzeitig ausgeführt werden können. Diese Lösung eignet sich optimal für prädiktive Analysen, die keine Echtzeitanforderung aufweisen.

In der folgenden Tabelle sind Begriffe im Zusammenhang mit Stapelvoraussagen definiert.

Laufzeit	Definition
Ausgabesp eicherort	Die Ergebnisse einer Stapelvoraussage werden in einem S3-Bucket-Ausgabespeicherort gespeichert.
Manifestdatei	Diese Datei verknüpft die Eingabedatendatei mit den zugehörigen Ergebnissen der Stapelvoraussage. Sie wird am S3-Ausgabespeicherort gespeichert.

Echtzeitvoraussagen

Echtzeitvoraussagen werden für Anwendungen mit geringer Latenzanforderung verwendet, z. B. interaktive Webanwendungen, mobile Anwendungen oder Desktopanwendungen. Jedes ML-Modell kann im Hinblick auf Voraussagen mithilfe der latenzarmen Echtzeitvoraussage-API abgefragt werden.

In der folgenden Tabelle sind Begriffe im Zusammenhang mit Echtzeitvoraussagen definiert.

Laufzeit	Definition
Echtzeitv oraussage-API	Die Echtzeitvoraussage-API akzeptiert eine einzelne Eingabebeobachtung in der Nutzlast der Anforderung und gibt die Voraussage synchron in der Antwort zurück.
Endpunkt für Echtzeitv oraussagen	Um ein ML-Modell mit einer Echtzeitvoraussage-API zu verwenden, müssen Sie einen Endpunkt für Echtzeitvoraussagen erstellen. Nach der Erstellung enthält der Endpunkt die URL, die Sie verwenden können, um Echtzeitvoraussagen anzufordern.

Zugriff auf Amazon Machine Learning

Sie können mit einer der folgenden Methoden auf Amazon ML zugreifen:

Amazon ML-Konsole

Sie können auf die Amazon ML-Konsole zugreifen, indem Sie sich bei der AWS-Managementkonsole anmelden und die Amazon ML-Konsole unter öffnen <https://console.aws.amazon.com/machinelearning/>.

AWS-CLI

Informationen zur Installation und Konfiguration der AWS-CLI finden Sie unter [Getting Setup with the AWS Command Line Interface](#) im [AWS Command Line Interface Benutzerhandbuch](#).

Amazon ML-API

Weitere Informationen zur Amazon ML-API finden Sie unter [Amazon ML API-Referenz](#).

AWS SDKs

Weitere Informationen zu AWS finden Sie SDKs unter [Tools for Amazon Web Services](#).

Regionen und Endpunkte

Amazon Machine Learning (Amazon ML) unterstützt Echtzeit-Prognoseendpunkte in den folgenden zwei Regionen:

Name der Region	Region	Endpunkt	Protokoll
USA Ost (Nord-Virginia)	us-east-1	machinelearning.us-east-1.amazonaws.com	HTTPS
Europa (Irland)	eu-west-1	machinelearning.eu-west-1.amazonaws.com	HTTPS

Sie können Datensätze hosten, Modelle schulen und auswerten und Voraussagen in einer beliebigen Region auslösen.

Wir empfehlen, dass Sie alle Ressourcen in derselben Region belassen. Wenn sich Ihre Eingabedaten in einer anderen Region als Ihre Amazon ML-Ressourcen befinden, fallen für Sie regionsübergreifende Datenübertragungsgebühren an. Sie können einen Echtzeitvoraussage-Endpunkt aus einer beliebigen Region aufrufen, das Aufrufen eines Endpunkts aus einer Region, die nicht über den Endpunkt verfügt, den Sie aufrufen, kann zu Latenzen bei der Echtzeitvoraussage führen.

Preise für Amazon ML

Bei AWS Services zahlen Sie nur für das, was Sie tatsächlich nutzen. Es fallen keine Mindestgebühren oder Vorauszahlungen an.

Amazon Machine Learning (Amazon ML) berechnet einen Stundensatz für die Rechenzeit, die für die Berechnung von Datenstatistiken und das Trainieren und Auswerten von Modellen verwendet wird. Anschließend zahlen Sie für die Anzahl der Prognosen, die für Ihre Anwendung generiert wurden. Für Echtzeit-Voraussagen können Sie auch für eine reservierte Kapazität bezahlen, deren Größe sich nach der Größe Ihres Modells richtet.

Amazon ML schätzt die Kosten für Prognosen nur in der [Amazon ML-Konsole](#).

Weitere Informationen zu den Amazon ML-Preisen finden Sie unter [Amazon Machine Learning Learning-Preise](#).

Themen

- [Einschätzen von Stapelvoraussagekosten](#)
- [Einschätzen von Echtzeit-Voraussagekosten](#)

Einschätzen von Stapelvoraussagekosten

Wenn Sie mithilfe des Assistenten „Batch-Vorhersage erstellen“ Batch-Prognosen aus einem Amazon ML-Modell anfordern, schätzt Amazon ML die Kosten dieser Prognosen. Die Methode zum Berechnen der Schätzung variiert je nach Art der verfügbaren Daten.

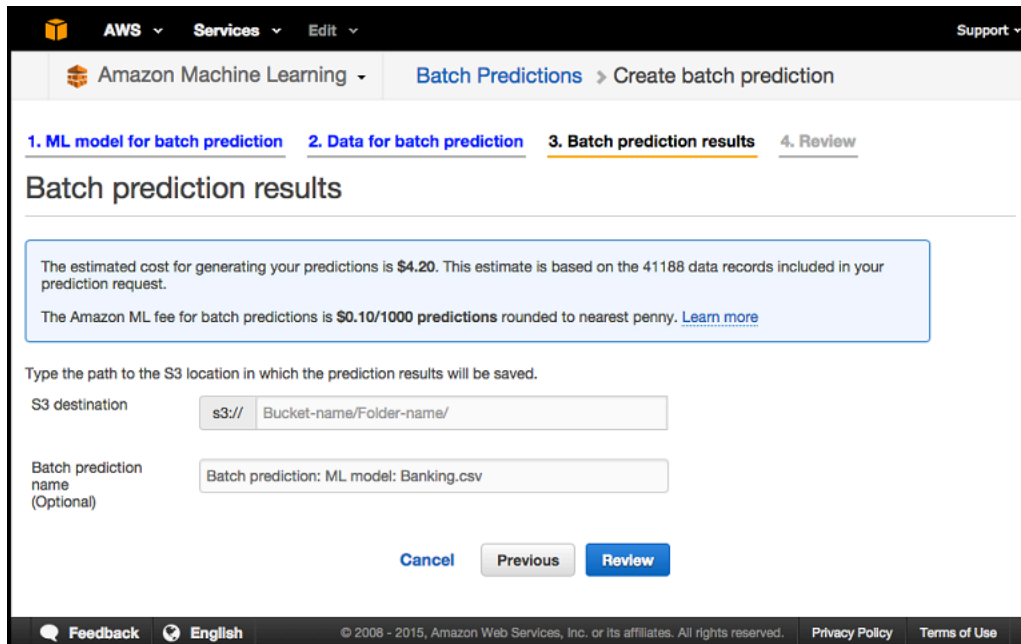
Einschätzen der Kosten für eine Stapelvoraussage mit verfügbaren Datenstatistiken

Die genaueste Kostenschätzung erhält man, wenn Amazon ML bereits zusammenfassende Statistiken über die Datenquelle berechnet hat, die für die Anforderung von Prognosen verwendet wurde. Diese Statistiken werden immer für Datenquellen berechnet, die mit der Amazon ML-Konsole erstellt wurden. [API-Benutzer müssen das ComputeStatistics Flag auf setzen, True wenn sie Datenquellen programmgesteuert mit dem S3, oder dem CreateDataSourceFrom RDS erstellen. CreateDataSourceFromRedshiftCreateDataSourceFrom](#) APIs Die Datenquelle muss den Status READY aufweisen, damit die Statistiken zur Verfügung stehen.

Eine der Statistiken, die Amazon ML berechnet, ist die Anzahl der Datensätze. Wenn die Anzahl der Datensätze verfügbar ist, schätzt der Amazon ML Create Batch Prediction Wizard die Anzahl der Prognosen, indem er die Anzahl der Datensätze mit der [Gebühr für Batch-Prognosen](#) multipliziert.

Ihre tatsächlichen Kosten können von dieser Schätzung aus folgenden Gründen abweichen:

- Einige der Datensätze werden nicht verarbeitet. Datensätze von nicht verarbeiteten Voraussagen werden nicht in Rechnung gestellt.
- Die Schätzung berücksichtigt keine Gutschriften oder andere Anpassungen, die von AWS angewendet werden.



The screenshot shows the AWS Batch Prediction results page. The page title is "Batch prediction results". The estimated cost for generating predictions is \$4.20, based on 41,188 data records. The Amazon ML fee for batch predictions is \$0.10/1000 predictions rounded to nearest penny. The user is prompted to enter the S3 destination path for the prediction results and the batch prediction name (optional). The "Review" button is highlighted.

Einschätzen der Kosten für eine Stapelvoraussage mit verfügbarer Datengröße

Wenn Sie eine Batch-Vorhersage anfordern und die Datenstatistiken für die Anforderungsdatenquelle nicht verfügbar sind, schätzt Amazon ML die Kosten auf der Grundlage der folgenden Werte:

- Die Größe der gesamten Daten, die während der Datenquellenvalidierung berechnet und beibehalten werden.
- Die durchschnittliche Datensatzgröße, die Amazon ML durch Lesen und Analysieren der ersten 100 MB Ihrer Datendatei schätzt

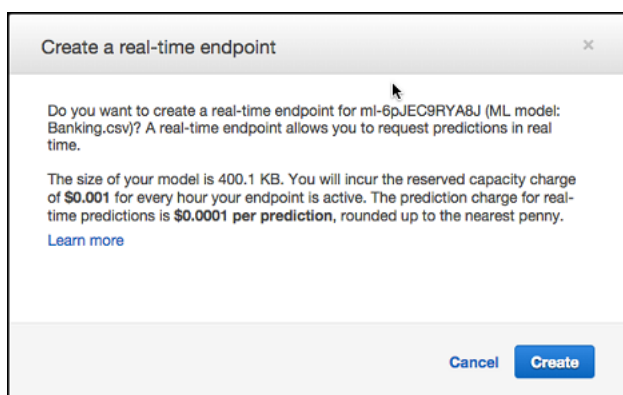
Um die Kosten Ihrer Batch-Vorhersage zu schätzen, dividiert Amazon ML die Gesamtdatengröße durch die durchschnittliche Datensatzgröße. Diese Methode der Kostenvoraussage ist weniger genau als die Methode, die verwendet wird, wenn die Anzahl der Datensätze verfügbar ist, da die ersten Datensätze der Datendatei die durchschnittliche Datensatzgröße möglicherweise nicht genau wiedergeben.

Einschätzen der Kosten für eine Stapelvoraussage ohne Datenstatistiken und Datengröße

Wenn weder Datenstatistiken noch die Datengröße verfügbar sind, kann Amazon ML die Kosten Ihrer Batchprognosen nicht abschätzen. Dies ist häufig der Fall, wenn die Datenquelle, die Sie für die Anforderung von Batch-Vorhersagen verwenden, noch nicht von Amazon ML validiert wurde. Dies kann passieren, wenn Sie eine Datenquelle erstellt haben, die auf einer Amazon Redshift- (Amazon Redshift) - oder Amazon Relational Database Service (Amazon RDS) -Abfrage basiert, und die Datenübertragung noch nicht abgeschlossen ist, oder wenn die Erstellung einer Datenquelle hinter anderen Vorgängen in Ihrem Konto in der Warteschlange steht. In diesem Fall informiert Sie die Amazon ML-Konsole über die Gebühren für die Batch-Vorhersage. Sie können dann entweder ohne Einschätzung mit der Anfrage der Stapelvoraussage fortfahren, oder Sie können den Assistenten beenden und zurückkehren, nachdem die für Voraussagen verwendete Datenquelle den Status INPROGRESS oder READY aufweist.

Einschätzen von Echtzeit-Voraussagekosten

Wenn Sie mit der Amazon ML-Konsole einen Echtzeit-Prognoseendpunkt erstellen, wird Ihnen die geschätzte Reservekapazitätsgebühr angezeigt. Dabei handelt es sich um eine fortlaufende Gebühr für die Reservierung des Endpunkts für die Prognoseverarbeitung. Diese Gebühr variiert je nach Größe des Modells, wie auf der [Service-Seite mit den Preisen](#) erläutert. Sie werden auch über die Standardgebühr für Echtzeitprognosen von Amazon ML informiert.



Machine Learning-Konzepte

Mittels Machine learning (ML) können Sie archivierte Daten verwenden, um bessere Business-Entscheidungen zu treffen. ML-Algorithmen entdecken Muster in Daten und konstruieren anhand dieser Entdeckungen mathematische Modelle. Anschließend können Sie die Modelle verwenden, um Voraussagen für zukünftige Daten zu erstellen. Eine mögliche Anwendung des Machine Learning-Modells ist beispielsweise die Voraussage der Wahrscheinlichkeit, mit der ein Kunde auf der Grundlage seines vergangenen Verhaltens ein bestimmtes Produkt kaufen wird.

Themen

- [Lösen von wirtschaftlichen Problemen mit Amazon Machine Learning](#)
- [Einsatzgebiete von Machine Learning](#)
- [Die Erstellung einer Machine Learning-Anwendung](#)
- [Der Amazon Machine Learning Learning-Prozess](#)

Lösen von wirtschaftlichen Problemen mit Amazon Machine Learning

Mit Amazon Machine Learning können Sie maschinelles Lernen auf Probleme anwenden, für die Sie bereits Beispiele mit tatsächlichen Antworten haben. Wenn Sie beispielsweise Amazon Machine Learning verwenden möchten, um vorherzusagen, ob eine E-Mail Spam ist, müssen Sie E-Mail-Beispiele sammeln, die korrekt als Spam-Nachrichten oder kein Spam gekennzeichnet sind. Sie können dann diese E-Mail-Beispiele für das maschinelle Lernen nutzen, um vorherzusagen, wie wahrscheinlich eine neue E-Mail Spam ist oder nicht. Dieser Ansatz zum Lernen aus Daten, die mit der tatsächlichen Antwort markiert sind, wird als überwacht maschinelles Lernen bezeichnet.

Sie können den überwachten ML-Ansatz für folgende spezifischen Machine Learning-Aufgaben verwenden: binäre Klassifizierung (Vorhersage von einem aus zwei möglichen Ergebnissen), Mehrklassen-Klassifizierung (Vorhersage von einem aus mehr als zwei Ergebnissen) und Regression (Vorhersage eines numerischen Werts).

Beispiele für binäre Klassifizierungsprobleme:

- Wird der Kunde das Produkt kaufen oder nicht?
- Ist diese E-Mail Spam oder nicht?

- Ist Ihr Produkt ein Buch oder ein Nutztier?
- Wurde diese Bewertung von einem Kunden oder einer Maschine geschrieben?

Beispiele für Mehrklassen-Klassifizierungsprobleme:

- Ist das Produkt ein Buch, ein Film oder Kleidung?
- Ist dieser Film ein Liebeskomödie, eine Dokumentation oder ein Thriller?
- Welche Kategorie von Produkten für diesen Kunden am interessantesten?

Beispiele für Regressions-Klassifizierungsprobleme:

- Wie wird die Temperatur in Seattle morgen sein?
- Wie viele Einheiten dieses Produkts werden wir verkaufen?
- Wie viele Tage dauert es, bis der Kunde die Anwendung nicht mehr verwendet?
- Für welchen Preis wird dieses Haus verkauft?

Einsatzgebiete von Machine Learning

Beachten Sie, dass ML nicht für jede Art von Problemen eine Lösung ist. Es gibt bestimmte Fälle, in denen robuste Lösungen ohne ML-Techniken entwickelt werden können. Beispielsweise benötigen Sie kein ML, wenn Sie einen Zielwert bestimmen können, indem Sie einfache Regeln, Berechnungen oder vorbestimmte Schritte anwenden, die ohne datengesteuertes Lernen programmiert werden können.

Verwenden Sie das maschinelle Lernen für folgende Situationen:

- Sie können die Regeln nicht codieren: Viele Aufgaben, die von Menschen durchgeführt werden (z. B. das Erkennen von Spam-Nachrichten) können mit einer einfachen (deterministischen), regelbasierten Lösung nicht ausreichend gelöst werden. Eine große Anzahl von Faktoren beeinflusst das Ergebnis. Wenn zu viele Regeln von zu vielen Faktoren abhängen und sich viele dieser Regeln überlappen oder sehr fein abgestimmt werden müssen, wird es schnell schwierig, diese Regeln präzise zu codieren. Mit ML können Sie dieses Problem effektiv lösen.
- Sie können nicht skalieren: Sie können manuell ein paar Hundert E-Mails erkennen und entscheiden, ob sie Spam sind oder nicht. Doch diese Aufgabe wird bei Millionen von E-Mails zu aufwendig. ML-Lösungen sind für die Verarbeitung von Problemen in großem Umfang effektiv.

Die Erstellung einer Machine Learning-Anwendung

Die Erstellung von ML-Anwendungen ist ein iterativer Prozess mit mehreren Schritten. Um eine ML-Anwendung zu erstellen, führen Sie die folgenden Schritte durch:

1. Stellen Sie auf der Grundlage Ihrer Beobachtungen das/die wichtigste(n) ML-Problem(e) heraus und welche Antwort das Modell voraussagen soll.
2. Erheben und bereinigen sie Daten und bereiten Sie diese auf, sodass sie von Schulungsalgorithmen für das ML-Modell verwendet werden können. Visualisieren und analysieren Sie die Daten, und führen Sie Kontrollprüfungen durch, um die Qualität der Daten sicherzustellen, und um die Daten zu verstehen.
3. Oftmals werden die Rohdaten (Eingabevariablen) und die Antwort (Ziel) nicht so dargestellt, dass sie zur Schulung eines Voraussagemodells verwendet werden können. Daher sollten Sie versuchen, mehr Eingaben oder Funktionen aus den Rohvariablen mit voraussagendem Charakter zu erstellen.
4. Geben Sie die daraus hervorgehenden Funktionen in den Lernalgorithmus ein, um Modelle zu erstellen und die Qualität der Modelle anhand der Daten auszuwerten, die nicht für die Erstellung des Modells verwendet wurden.
5. Verwenden Sie das Modell zum Generieren von Voraussagen der Zielantwort für neue Daten-Instances.

Erarbeitung des Problems

Der erste Schritt im Machine Learning besteht darin, zu entscheiden, was Sie voraussagen möchten; dies ist das Label oder die Zielantwort. Stellen Sie sich vor, Sie möchten Produkte herstellen, aber die Entscheidung für die Herstellung eines Produkts hängt von der Anzahl der Verkaufschancen ab. In diesem Szenario möchten Sie voraussagen, wie oft jedes Produkt erworben werden wird (Anzahl Verkäufe voraussagen). Es gibt mehrere Möglichkeiten, dieses Problem mittels Machine Learning zu definieren. Die Art und Weise, wie Sie das Problem definieren, hängt von Ihrem Anwendungsfall bzw. Ihren Geschäftsbedürfnissen ab.

Möchten Sie die Anzahl Käufe voraussagen, die Ihre Kunden für jedes Produkt tätigen werden (in diesem Fall ist das Ziel numerisch und Sie lösen ein Regressionsproblem)? Oder möchten Sie voraussagen, welche Produkte mehr als 10 Mal gekauft werden (in diesem Fall ist das Ziel binär und Sie lösen ein binäres Klassifikationsproblem)?

Es ist wichtig, das Problem nicht zu verkomplizieren und die einfachste Lösung zu erarbeiten, die auf Ihre Bedürfnisse zugeschnitten ist. Allerdings ist es ebenso wichtig, keine Informationen zu verlieren, insbesondere Informationen in den historischen Antworten. Durch das Konvertieren einer vergangenen Verkaufszahl in die binäre Variable "über 10" statt "weniger" würden wertvolle Informationen verloren gehen. Investieren Sie Zeit in Ihre Entscheidung für die Ziele, die für Ihre Voraussage am meisten Sinn machen, um Modelle zu erstellen, die Ihre Frage nicht beantworten.

Sammeln von Daten mit Bezeichnung

ML-Probleme starten mit den Daten – vorzugsweise viele Daten (Beispiele oder Beobachtungen), deren Zielantwort Ihnen bereits bekannt ist. Daten, deren Zielantwort Ihnen bereits bekannt ist, werden bezeichnete Daten genannt. Im überwachten ML lernt der Algorithmus selbst, wie er aus bezeichneten Beispielen, die wir bereitstellen, lernen muss.

Jede example/observation Ihrer Daten muss zwei Elemente enthalten:

- Das Ziel – Die Antwort, die Sie voraussagen möchten. Sie stellen dem ML-Algorithmus zum Lernen Daten bereit, die mit dem Ziel (richtige Antwort) bezeichnet sind. Anschließend verwenden Sie das geschulte ML-Modell für Daten, deren Zielantwort Sie nicht kennen, um diese Antwort vorauszusagen.
- Variablen/Funktionen – Hierbei handelt es sich um Attribute des Beispiels, die verwendet werden können, um Muster zu erkennen und die Zielantwort vorauszusagen.

Beispielsweise ist beim E-Mail-Klassifizierungsproblem das Ziel eine Bezeichnung, die angibt, ob eine E-Mail Spam ist oder nicht. Beispiele für Variablen sind der Absender der E-Mail, der Text im Textkörper der E-Mail, der Text in der Betreff-Zeile, der Zeitpunkt, zu dem die E-Mail gesendet wurde, und vorangegangene Korrespondenz zwischen Sender und Empfänger.

Häufig stehen die Daten nicht als bezeichnete Daten zur Verfügung. Das Sammeln und Vorbereiten von Variablen und Ziel ist oft der wichtigste Schritt für die Lösung eines ML-Problems. Das Beispieldaten sollten die Daten repräsentieren, die Ihnen vorliegen, wenn Sie das Modell für eine Voraussage verwenden. Beispiel: Wenn Sie voraussagen möchten, ob eine E-Mail Spam ist oder nicht, müssen Sie sowohl positive (Spam-E-Mails) als auch negative (keine Spam-E-Mails) sammeln, damit der Machine Learning-Algorithmus Muster erkennen kann, die diese beiden Arten von E-Mails voneinander unterscheiden.

Sobald Sie über die bezeichneten Daten verfügen, müssen Sie diese möglicherweise in einem Format konvertieren, das Ihr Algorithmus oder Ihre Software akzeptiert. Um beispielsweise Amazon

ML zu verwenden, müssen Sie die Daten in das kommagetrennte Format (CSV) konvertieren, wobei jedes Beispiel eine Zeile der CSV-Datei bildet, wobei jede Spalte eine Eingabevariable und eine Spalte die Zielantwort enthält.

Analysieren Ihrer Daten

Bevor Sie den ML-Algorithmus mit Ihren bezeichneten Daten füttern, sollten Sie Ihre Daten überprüfen, um Probleme festzustellen und einen Einblick in die Daten zu erhalten, die Sie verwenden. Die Voraussagekraft Ihres Modells ist nur so gut wie die Daten, mit denen Sie es füttern.

Beim Analysieren Ihrer Daten sollten Sie die Folgendes beachten:

- **Variablen- und Zieldatenzusammenfassung** – Es ist nützlich, die Werte zu verstehen, die Ihre Variablen annehmen, und welche Werte in Ihren Daten dominant sind. Sie können diese Zusammenfassungen von einem Experte für das zu lösende Problem erstellen lassen. Fragen Sie sich oder den Experten: Erfüllen die Daten Ihre Erwartungen? Haben Sie allem Anschein nach ein Problem mit dem Sammeln von Daten? Kommt eine Klasse in Ihrem Ziel häufiger vor als die anderen Klassen? Gibt es mehrere fehlende Werte oder ungültige Daten als erwartet?
- **Variable-Ziel-Korrelationen** – Es ist nützlich, die Korrelation zwischen Variablen und Zielklassen zu kennen, da eine hohe Korrelation darauf hindeutet, dass zwischen der Variablen und der Ziel-Klasse eine Beziehung besteht. Im Allgemeinen sollten Sie Variablen mit hoher Korrelation verwenden, da diese eine stärkere Voraussagekraft (Signal) haben, und Variablen mit niedriger Korrelation auslassen, da sie wahrscheinlich nicht relevant sind.

In Amazon ML können Sie Ihre Daten analysieren, indem Sie eine Datenquelle erstellen und den resultierenden Datenbericht überprüfen.

Feature-Verarbeitung

Nachdem Sie sich mithilfe von Datenzusammenfassungen und Visualisierungen mit Ihren vertraut gemacht haben, möchten Sie Ihre Variablen möglicherweise weiter transformieren, damit sie aussagekräftiger sind. Dieser Vorgang wird Funktionsverarbeitung genannt. Beispiel: Sie haben eine Variable, die Datum und Uhrzeit eines Ereignisses erfasst. Dieses Datum und diese Uhrzeit treten nie wieder auf und sind daher nicht für eine Voraussage Ihres Ziels geeignet. Wenn Sie diese Variable jedoch in Funktionen transformieren, welche die Stunden eines Tags, den Wochentag und den Monat angeben, können diese Variablen nützlich sein, um zu erfahren, ob das Ereignis zu einer bestimmten Stunde, an einem bestimmten Wochentag oder in einem bestimmten Monat auftritt. Eine solche

Funktionsverarbeitung für generalisierbare Datenpunkte können das Voraussagemodell deutlich verbessern.

Weitere Beispiele für eine gängige Funktionsverarbeitung:

- Ersetzen fehlender oder ungültiger Daten durch aussagekräftige Werte (wenn Sie z. B. wissen, dass ein fehlender Wert für eine Produktart-Variable bedeutet, dass es sich um ein Buch handelt, können Sie alle fehlenden Werte in der Produktart durch den Wert für Buch ersetzen). Eine gängige Strategie für das Ersetzen fehlender Werte ist das Austauschen der fehlenden Werte mit einem Mittel- oder Durchschnittswert. Es ist wichtig, dass Sie Ihre Daten verstehen, bevor Sie sich für eine Strategie für das Austauschen fehlender Werte entscheiden.
- Bilden kartesischer Produkte aus einer Variable mit einer anderen. Wenn Sie beispielsweise über zwei Variablen verfügen, nämlich Bevölkerungsdichte (Stadt, Vorort, Land) und Staat (Washington, Oregon, Kalifornien), können sich in den Funktionen, die aus einem kartesischen Produkt aus diesen beiden Variablen zu neuen Funktionen geformt werden (urban_Washington, suburban_Washington, rural_Washington, urban_Oregon, suburban_Oregon, rural_Oregon, urban_California, suburban_California, rural_California), nützliche Informationen verbergen.
- Nicht-lineare Transformationen wie das Binning von numerischen Variablen zu Kategorien. In vielen Fällen ist die Beziehung zwischen einer numerischen Funktion und dem Ziel nicht linear (der numerische Funktionswert wird nicht gleichmäßig mit dem Ziel erhöht oder verringert). In solchen Fällen kann es nützlich sein, die numerische Funktion in kategorische Funktionen zu packen, um verschiedene Bereiche der numerischen Funktion darzustellen. Jede kategorische Funktion (Bin) kann dann mit einer eigenen linearen Beziehung zum Ziel im Modell dargestellt werden. Nehmen wir an, Sie wissen, dass die kontinuierliche numerische Funktion "age" nicht linear mit der Wahrscheinlichkeit verläuft, ein Buch zu kaufen. Sie können die Dauer also in kategorische Funktionen packen, die in der Lage sind, die Beziehung zum Ziel genauer zu erfassen. Die optimale Anzahl von Paketen für eine numerische Variable hängt von den Eigenschaften der Variablen und ihrer Beziehung mit dem Ziel ab und wird am besten durch Experimente bestimmt. Amazon ML schlägt die optimale Lagerplatznummer für ein numerisches Merkmal auf der Grundlage der Datenstatistiken in der vorgeschlagenen Rezeptur vor. Weitere Informationen zum empfohlenen Rezept finden Sie im Developer-Handbuch.
- Domain-spezifische Funktionen (z. B. können Sie mit Länge, Breite und Höhe als separate Variablen eine neue Volume-Funktion als Produkt dieser drei Variablen erstellen).
- Variable-spezifische Funktionen. Einige Variable-Typen, z. B. SMS-Funktionen oder Funktionen, welche die Struktur einer Webseite oder die Struktur eines Satzes erfassen, haben generische Verarbeitungsmöglichkeiten, welche die Extraktion von Struktur und Kontext unterstützen.

Beispielsweise kann das Bilden von n-grams aus dem Text "the fox jumped over the fence" mit unigrams dargestellt werden: the, fox, jumped, over, fence, oder bigrams: the fox, fox jumped, jumped over, over the, the fence.

Das Einbeziehen relevanter Funktionen verbessert die Voraussagekraft. Natürlich ist es nicht immer möglich, die Funktionen mit "signal"- oder Voraussagekraft im Voraus zu kennen. Deshalb ist es gut, dass alle Funktionen, die möglicherweise einen Bezug zur Zielbezeichnung haben, einzubeziehen und den Modellschulungsalgorithmus die stärksten Korrelationen wählen zu lassen. In Amazon ML kann die Feature-Verarbeitung beim Erstellen eines Modells im Rezept angegeben werden. Eine Liste der verfügbaren Funktionsprozessoren finden Sie im Developer-Handbuch.

Aufteilung von Daten in Schulungs- und Evaluierungsdaten

Grundlegendes Ziel von ML ist es, über die Daten-Instances, die für die Schulung von Modellen verwendet werden, hinaus zu generalisieren. Wir möchten das Modell so evaluieren, dass es die Qualität seiner Mustergeneralisierung für Daten, für die das Modell nicht geschult wurde, einschätzt. Da zukünftige Instances unbekannte Zielwerte enthalten können wir die Richtigkeit unserer Voraussagen für zukünftige Instances jetzt nicht prüfen können, müssen wir die Daten, deren Antwort wir bereits kennen, als Proxy für zukünftige Daten verwenden. Das Testen des Modells mit denselben Daten, die für die Schulung verwendet wurden, ist nicht sinnvoll, weil sich Modelle an spezifische Schulungsdaten „erinnern“ anstatt sie zu verallgemeinern.

Eine gängige Strategie ist es, alle verfügbaren bezeichneten Daten in Schulungs- und Evaluierungssätze aufzuteilen; in der Regel erfolgt dies mit einem Verhältnis von 70 bis 80 Prozent für Schulungen und 20-30 Prozent für die Evaluation. Das ML-System verwendet die Schulungsdaten, um Modelle auf die Mustererkennung zu schulen, und verwendet die Evaluierungsdaten, um die Voraussagequalität der geschulten Modell zu bewerten. Das ML-System bewertet die Voraussageleistung durch Vergleichen der Voraussagen auf der Grundlage eines Evaluierungsdatensatzes mit den tatsächlichen Werten (bekannt als Referenzwert) und mithilfe einer Vielzahl von Metriken. In der Regel verwenden Sie die Modelle, die den Evaluierungsdatensatz am besten für ihre Voraussagen verwendet haben, für zukünftige Instances, deren Zielantwort Sie nicht kennen.

Amazon ML teilt Daten, die zum Trainieren eines Modells über die Amazon ML-Konsole gesendet werden, in 70 Prozent für Schulungen und 30 Prozent für Evaluierungszwecke auf. Standardmäßig verwendet Amazon ML die ersten 70 Prozent der Eingabedaten in der Reihenfolge, in der sie in den Quelldaten für die Trainingsdatenquelle erscheinen, und die restlichen 30 Prozent der Daten für die Bewertungsdatenquelle. Amazon ML ermöglicht es Ihnen auch, 70 Prozent der Quelldaten nach dem

Zufallsprinzip für das Training auszuwählen, anstatt die ersten 70 Prozent zu verwenden und das Komplement dieser zufälligen Teilmenge für die Auswertung zu verwenden. Sie können Amazon ML verwenden APIs , um benutzerdefinierte Aufteilungsverhältnisse festzulegen und Schulungs- und Bewertungsdaten bereitzustellen, die außerhalb von Amazon ML aufgeteilt wurden. Amazon ML bietet auch Strategien für die Aufteilung Ihrer Daten. Weitere Informationen zu Aufteilungsoptionen finden Sie unter [Aufteilen Ihrer Daten](#).

Schulen des Modells

Sie sind nun bereit, den ML-Algorithmus (also den Lernalgorithmus) mit den Schulungsdaten zu füttern. Der Algorithmus lern von den Schulungsdatenmustern, welche die Variablen dem Ziel zuweisen, und gibt ein Modell aus, das diese Beziehungen erfasst. Das ML-Modell kann verwendet werden, um Voraussagen für neue Daten zu erhalten, bei denen Sie die Zielantwort nicht kennen.

Lineare Modelle

Es ist eine große Anzahl von ML-Modellen verfügbar. Amazon ML lernt eine Art von ML-Modell kennen: lineare Modelle. Der Begriff lineares Modell deutet darauf hin, dass das Modell als eine lineare Kombination von Funktionen spezifiziert ist. Basierend auf den Schulungsdaten berechnet der Lernprozess eine Gewichtung für jede Funktion, woraus sich ein Modell ergibt, das den Zielwert voraussagen oder einschätzen kann. Beispiel: Wenn Ihr Ziel die Höhe der Versicherung ist, die der Kunde kaufen wird, und Ihre Variablen sind Alter und Einkommen, wäre ein einfaches lineares Modell wie folgt:

```
Estimated target = 0.2 + 5·age + 0.0003·income
```

Lernalgorithmus

Der Lernalgorithmus soll die Gewichtungen für ein Modell lernen. Die Gewichtungen beschreiben die Wahrscheinlichkeit, dass die Muster, die das Modell lernt, die tatsächlichen Beziehungen in den Daten widerspiegeln. Ein Lernalgorithmus besteht aus einer Verlustfunktion und eine Optimierungsmethode. Der Verlust ist die Strafe dafür, wenn die vom ML-Modell bereitgestellte Einschätzung des Ziels nicht genau dem Ziel entspricht. Eine Verlustfunktion quantifiziert diese Strafe als einzelnen Wert. Ein Optimierungsmethode dient dazu, den Verlust zu minimieren. In Amazon Machine Learning verwenden wir drei Verlustfunktionen, eine für jeden der drei Typen von Voraussageproblemen. Die in Amazon ML verwendete Optimierungstechnik ist Online Stochastic Gradient Descent (SGD). Der SGD macht sequenzielle Durchgänge durch die Schulungsdaten und aktualisiert in jedem Durchgang die Funktionsgewichtungen der einzelnen Beispiels, um eine optimale Gewichtung zu erzielen und den Verlust zu minimieren.

Amazon ML verwendet die folgenden Lernalgorithmen:

- Für die binäre Klassifizierung verwendet Amazon ML die logistische Regression (logistische Verlustfunktion + SGD).
- Für die Klassifizierung mehrerer Klassen verwendet Amazon ML die multinomiale logistische Regression (multinomiale logistische Verlustfunktion + SGD).
- Für die Regression verwendet Amazon ML die lineare Regression (quadratische Verlustfunktion + SGD).

Schulungsparameter

Der Lernalgorithmus von Amazon ML akzeptiert Parameter, sogenannte Hyperparameter oder Trainingsparameter, mit denen Sie die Qualität des resultierenden Modells kontrollieren können. Abhängig vom Hyperparameter wählt Amazon ML automatisch Einstellungen aus oder stellt statische Standardwerte für die Hyperparameter bereit. Obwohl die Einstellungen der Standard-Hyperparameter in der Regel nützliche Modelle produzieren, können Sie die Voraussageleistung Ihrer Modelle verbessern, indem Sie die Hyperparameterwerte ändern. In den folgenden Abschnitten werden allgemeine Hyperparameter im Zusammenhang mit Lernalgorithmen für lineare Modelle beschrieben, wie sie beispielsweise von Amazon ML erstellt wurden.

Lernrate

Bei der Lernrate handelt es sich um einen konstanten Wert im Algorithmus des Stochastic Gradient Descent (SGD). Die Lernrate wirkt sich die Geschwindigkeit aus, mit welcher der Algorithmus die optimalen Gewichtungen erreicht bzw. sich diesen annähert. Der SGD-Algorithmus aktualisiert die Gewichtungen des linearen Modells für jedes greifbare Datenbeispiel. Die Größe dieser Aktualisierungen wird von der Lernrate bestimmt. Eine zu große Lernrate kann verhindern, dass sich die Gewichtungen der optimalen Lösung annähern. Eine zu kleine Lernrate führt dazu, dass der Algorithmus viele Durchläufe benötigt, um eine optimale Gewichtung zu erzielen.

In Amazon ML wird die Lernrate anhand Ihrer Daten automatisch ausgewählt.

Modellgröße

Wenn Sie über viele Eingabefunktionen verfügen, kann die Anzahl der möglichen Muster in den Daten zu einem großen Modell führen. Große Modelle haben praktische Implikationen, sie erfordern z. B. mehr RAM für das Modell während der Schulung und beim Generieren von Voraussagen. In Amazon ML können Sie die Modellgröße reduzieren, indem Sie die L1-Regularisierung verwenden

oder indem Sie die Modellgröße gezielt einschränken, indem Sie die maximale Größe angeben. Beachten Sie, dass wenn Sie die Modellgröße zu sehr verringern, die Voraussagekraft Ihres Modells eingeschränkt sein kann.

Weitere Informationen zur Standard-Modellgröße finden Sie unter [Schulungsparameter: Typen und Standardwerte](#). Weitere Informationen zur Regularisation finden Sie unter [Regularisation](#).

Anzahl der Durchläufe

Der SGD-Algorithmus macht sequenzielle Durchgänge durch die Schulungsdaten. Der `Number of passes`-Parameter steuert die Anzahl von Durchgängen, die der Algorithmus durch die Schulungsdaten vornimmt. Mehr Durchgänge führen dazu, dass das Modell besser auf die Daten abgestimmt ist (sofern die Lernrate nicht zu hoch ist). Mit der deutlichen Zunahme der Anzahl der Durchgänge jedoch schrumpft dieser Vorteil wieder. Bei kleineren Datensätzen können Sie die Anzahl von Durchläufen deutlich erhöhen, sodass der Lernalgorithmus effektiv auf die Daten abgestimmt werden kann. Bei besonders großen Datensätzen ist ein einzelner Durchgang möglicherweise ausreichend.

Weitere Informationen zur standardmäßigen Anzahl an Durchläufen finden Sie unter [Schulungsparameter: Typen und Standardwerte](#).

Daten-Shuffling

In Amazon ML müssen Sie Ihre Daten mischen, da der SGD-Algorithmus von der Reihenfolge der Zeilen in den Trainingsdaten beeinflusst wird. Das Mischen oder Shuffling Ihrer Schulungsdaten führt zu besseren ML-Modellen, da der SGD-Algorithmus Lösungen vermeidet, die zwar für den ersten Datentyp aber nicht für alle Daten optimal sind. Beim Mischen wird die Reihenfolge der Daten so geändert, dass der SGD-Algorithmus nacheinander nicht nur einen Datentyp bei zahlreichen Beobachtungen erkennt. Wenn für mehrere aufeinanderfolgende Durchgänge nur eine Art von Daten erkannt werden, kann der Algorithmus die Modellgewichtungen möglicherweise nicht für einen neuen Datentyp korrigieren, da die Aktualisierung zu groß sein kann. Wenn die Daten zudem nicht in zufälliger Reihenfolge präsentiert werden, ist es für den Algorithmus schwierig, schnell die optimale Lösung für alle Datentypen zu finden; in einigen Fällen findet der Algorithmus möglicherweise überhaupt keine optimale Lösung. Das Mischen der Schulungsdaten hilft dem Algorithmus, die optimale Lösung schneller zu finden.

Angenommen, Sie möchten ein ML-Modell so schulen, dass es eine Produktart voraussagt, und Ihre Schulungsdaten enthalten die Produktarten Film, Spielzeug und Videospiel. Wenn Sie die Daten vor dem Hochladen auf Amazon S3 nach der Spalte Produkttyp sortieren, sortiert der Algorithmus

die Daten alphabetisch nach Produkttyp. Der Algorithmus erkennt alle Daten für Filme zuerst, und das ML-Modell beginnt, Muster für Filme zu erlernen. Wenn das Modell dann Daten zu Spielsachen erkennt, würde jedes Update, das der Algorithmus vornimmt, das Modell an den Produkttyp "Spielzeug" anpassen, auch wenn diese Updates die Muster herabsetzen, die Filmen entsprechen. Durch diesen plötzlichen Wechsel vom Typ "Film" zu "Spielzeug" kann ein Modell erzeugen, das nicht lernt, wie Produkttypen korrekt vorhergesagt werden.

Weitere Informationen zur Mischart finden Sie unter [Schulungsparameter: Typen und Standardwerte](#).

Regularisation

Die Regularisation hilft dabei, zu verhindern, dass lineare Modelle Schulungsdatenbeispiele übermäßig anpassen (d. h. sich Muster merken statt sie zu verallgemeinern), indem Werte mit extremer Gewichtung mit einer Strafe belegt werden. Die L1-Regularisation mindert Anzahl von Funktionen, die im Modell verwendet werden, indem sie die Gewichtungen von Funktionen mit kleinen Gewichtungen auf Null setzt. Infolgedessen führt die L1-Regularisation zu platzsparenden Modellen und reduziert die Störungsmenge im Modell. Die L2-Regularisation führt zu kleineren Gesamtgewichtungswerten und stabilisiert die Gewichtungen, wenn zwischen den Eingabefunktionen eine hohe Korrelation besteht. Mithilfe der Parameter `Regularization type` und `Regularization amount` steuern Sie die Höhe der angewendeten L1- und L2-Regularisation. Durch einen extrem hohen Regularisationswert kann die Gewichtung aller Funktionen Null sein, sodass ein Modell keine Muster mehr lernen kann.

Weitere Informationen zu Regularisationswerten finden Sie unter [Schulungsparameter: Typen und Standardwerte](#).

Evaluation der Modellrichtigkeit

Ziel des ML-Modells ist es, Muster zu lernen, die gut für unbekannte Daten verallgemeinert werden können, statt sich die Daten aus einer Schulung zu merken. Sobald Sie über ein Modell verfügen, überprüfen Sie, ob Ihr Modell unbekannte Beispiele, die Sie nicht für die Schulung des Modells verwendet haben, gut verarbeitet. Verwenden Sie also das Modell, um die Antwort für einen Evaluationsdatensatz (zurückgehaltene Daten) vorauszusagen, und vergleichen Sie dann das vorausgesagte Ziel mit der tatsächlichen Antwort (Referenzwert).

Das ML verwendet eine Reihe von Metriken, um die Voraussagerichtigkeit eines Modells zu messen. Die Wahl für eine Richtigkeitsmetrik ist abhängig von der Art der ML-Aufgabe. Es ist wichtig, diese Metriken zu prüfen, um zu entscheiden, ob Ihr Modell gut funktioniert.

Binäre Klassifikation

Die tatsächliche Ausgabe von vielen binären Klassifizierungsalgorithmen ist eine Voraussagepunktzahl. Die Punktzahl gibt die Sicherheit des Systems an, dass die angegebene Beobachtung der positiven Klasse angehört. Sie können die Punktzahl interpretieren, indem Sie einen Klassifizierungsschwellenwert oder Grenzwert festlegen und die Punktzahl damit vergleichen, um zu entscheiden, ob die Beobachtung als positiv oder negativ klassifiziert wird. Alle Beobachtungen mit Punkteständen höher als der Schwellenwert werden als positive Klasse vorausgesagt, und Punktestände unter dem Schwellenwert werden als negative Klasse vorausgesagt.

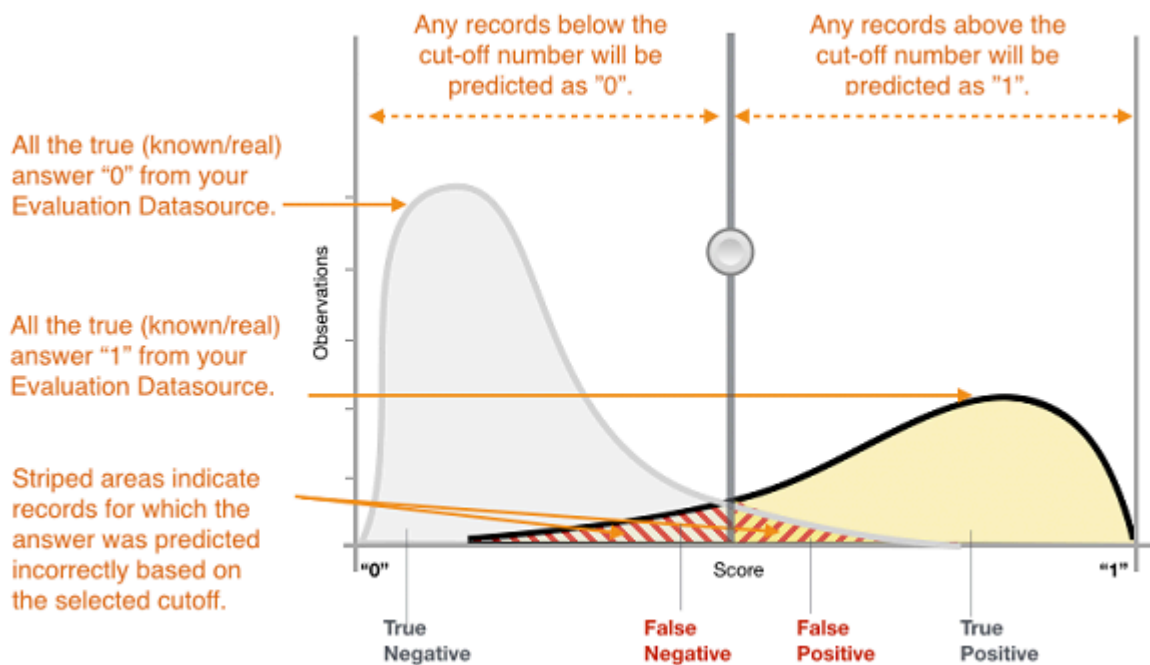


Abbildung 1: Verteilung der Punkte für ein binäres Klassifikationsmodell

Die Voraussagen werden nun basierend auf der tatsächlichen bekannten Antwort und der vorausgesagten Antwort in vier Gruppen unterteilt: richtige positive Voraussagen (echte Positive), richtige negative Voraussagen (echte Negative), falsche positive Voraussagen (falsche Positive) und falsche negative Voraussagen (falsche Negative).

Richtigkeitsmetriken für die binäre Klassifizierung quantifizieren zwei Arten von richtigen Voraussagen und zwei Arten von Fehlern. Typische Metriken sind Richtigkeit (ACC), Präzision, Wiedererkennung, Falschpositivrate, F1-measure. Jede Metrik misst einen anderen Aspekt des Voraussagemodells. Die Richtigkeit (ACC) misst den Anteil der richtigen Voraussagen. Genauigkeit misst den Anteil der tatsächlichen Positiva unter den Beispielen, die als positiv vorausgesagt wurden.

Wiedererkennung misst, wie viele tatsächliche Positive als positiv vorausgesagt wurden. F1-measure ist das harmonische Mittel von Genauigkeit und Wiedererkennung.

AUC ist eine andere Art der Metrik. Sie misst die Fähigkeit des Modells, eine höhere Bewertung für positive Beispiele im Vergleich zu negativen Beispielen vorherzusagen. Da die AUC unabhängig vom ausgewählten Schwellenwert ist, bekommen Sie ein Gefühl für die Voraussageleistung Ihres Modells aus der AUC-Metrik, ohne einen Schwellenwert auszuwählen.

Abhängig von Ihrem Unternehmensproblem benötigen Sie vielleicht eher ein Modell, das für eine bestimmte Teilmenge dieser Metriken gut funktioniert. Zwei Unternehmensanwendungen können beispielsweise sehr unterschiedliche Anforderungen an ihre ML-Modelle haben:

- Eine Anwendung muss vielleicht sehr sicher sein, dass die positiven Voraussagen tatsächlich positiv sind (hohe Präzision) und kann es verkraften, dass einige positive Beispiele falsch als negativ klassifiziert werden (moderate Wiedererkennung).
- Eine andere Anwendung soll so viele positive Beispiele wie möglich korrekt voraussagen (hohe Wiedererkennung) und nimmt es in Kauf, dass einige negative Beispiele falsch als positiv klassifiziert werden (moderate Genauigkeit).

In Amazon ML erhalten Beobachtungen eine prognostizierte Punktzahl im Bereich $[0,1]$. Der Schwellenwert für die Entscheidung, Beispiele als 0 oder 1 zu klassifizieren, ist standardmäßig auf 0,5 festgelegt. Mit Amazon ML können Sie überprüfen, welche Auswirkungen die Wahl verschiedener Score-Schwellenwerte hat, und Sie können einen geeigneten Schwellenwert auswählen, der Ihren Geschäftsanforderungen entspricht.

Mehrklassen-Klassifizierung

Im Gegensatz zum Prozess für binäre Klassifizierungsprobleme müssen Sie keinen Schwellenwert wählen, um Voraussagen zu treffen. Die vorausgesagte Antwort ist die Klasse (z. B. Bezeichnung) mit der höchsten vorausgesagten Punktzahl. In einigen Fällen möchten Sie die vorausgesagte Antwort vielleicht nur dann verwenden, wenn sie mit einer hohen Punktzahl vorausgesagt wurde. In diesem Fall können Sie einen Schwellenwert für die vorausgesagten Punktzahlen wählen, anhand dessen Sie die vorausgesagte Antwort akzeptieren oder nicht.

Typische in Mehrklassen verwendete Metriken sind dieselben wie die Metriken, die für den binären Klassifizierungsfall verwendet werden. Die Metrik wird für jede einzelne Klasse berechnet, indem sie nach der Gruppierung aller anderen Klassen in die zweite Klasse als binäres Klassifizierungsproblem behandelt wird. Dann wird die binäre Klasse gemittelt, um entweder eine Makro-Mittelmetrik (jede

Klasse wird gleich behandelt) oder gewichtete Mittelmetrik (gewichtet nach Klassenfrequenz) zu erhalten. In Amazon ML wird das F1-Maß für den Makrodurchschnitt verwendet, um den prädiktiven Erfolg eines Klassifikators mit mehreren Klassen zu bewerten.




Abbildung 2: Konfusionsmatrix für ein Mehrklassen-Klassifizierungsmodell

Es ist hilfreich, die Konfusionsmatrix auf Mehrklassen-Probleme zu prüfen. Die Konfusionsmatrix ist eine Tabelle, die jeder Klasse in den Evaluationsdaten und die Anzahl oder den Prozentsatz der richtigen und falschen Voraussagen darstellt.

Regression

Die typischen Richtigkeitsmetriken für Regressionsaufgaben sind root mean square error (RMSE) und mean absolute percentage error (MAPE). Diese Metriken messen die Abweichung zwischen dem vorausgesagten numerischen Ziel und der tatsächlichen numerischen Antwort (Referenzdaten). In Amazon ML wird die RMSE-Metrik verwendet, um die Vorhersagegenauigkeit eines Regressionsmodells zu bewerten.




Abbildung 3: Verteilung von Resten für ein Regressionsmodell

Es ist eine gängige Vorgehensweise, den Rest bei Regressionsproblemen zu überprüfen. Ein Rest für eine Beobachtung in der Evaluierungsdaten ist der Unterschied zwischen dem wahren Ziel und dem vorausgesagten Ziel. Reste stellen den Teil des Ziels dar, den das Modell nicht voraussagen konnte. Ein positiver Rest deutet darauf hin, dass das Modell das Ziel unterschätzt (das tatsächliche Ziel ist größer als das vorausgesagte Ziel). Ein negativer Rest deutet auf eine Überbewertung hin (das tatsächliche Ziel ist kleiner als das vorausgesagte Ziel). Das Histogramm der Reste für die Evaluierungsdaten deutet bei glockenförmiger Anordnung und Zentrierung auf Null darauf hin, dass das Modell willkürliche Fehler macht und keinen spezifischen Zielwertbereich systematisch über- oder unterschätzt. Wenn die Reste keine Glockenform mit Zentrierung auf Null bilden, gibt es eine gewisse Struktur bei den Voraussagefehlern des Modells. Das Hinzufügen von weiteren Variablen kann es dem Modell ermöglichen, Muster zu erfassen, die vom aktuellen Modell nicht erfasst werden.


Optimierung der Modellrichtigkeit

Um ein ML-Modell zu erhalten, das Ihren Anforderungen genügt, müssen Sie für gewöhnlich diesen ML-Prozess durchlaufen und ein paar Varianten ausprobieren. Vielleicht erhalten Sie nach dem ersten Durchlauf kein voraussagestarkes Modell, oder Sie möchten Ihr Modell optimieren, um noch bessere Voraussagen treffen zu können. Um die Leistung zu verbessern, führen Sie die folgenden Schritte aus:

1. Sammeln von Daten: Erhöhen Sie die Anzahl der Schulungsbeispiele
2. Funktionsverarbeitung: Fügen Sie zusätzlichen Variablen und eine bessere Funktionsverarbeitung hinzu
3. Modellparametereinstellung: Erwägen Sie alternative Werte für die Schulungsparameter, die von Ihrem Lernalgorithmus verwendet werden.

Modellanpassung: Unteranpassung vs. Überanpassung

Wenn Sie die Modellanpassung verstehen, verstehen Sie auch die Ursache für eine schlechte Modellrichtigkeit. Auf der Grundlage dieses Verständnisses können Sie korrigierende Maßnahmen ergreifen. Wir können bestimmen, ob ein Voraussagemodell die Schulungsdaten zu viel oder zu wenig anpasst, indem wir uns den Voraussagefehler für die Schulungsdaten und Evaluationsdaten ansehen.



Ihr Modell führt eine Unteranpassung der Schulungsdaten durch, wenn das Modell die Schulungsdaten nicht gut verarbeitet. Der Grund hierfür ist, dass das Modell die Beziehung zwischen den Eingabebeispielen (häufig als "X" bezeichnet) und den Zielwerten (häufig als "Y" bezeichnet) nicht erfassen kann. Ihr Modell führt eine Überanpassung Ihrer Schulungsdaten durch, wenn die Leistung des ML-Modells an den Lerndaten selbst gut ist, es jedoch an der Datenauswertung

scheitert. Der Grund hierfür ist, dass das Modell sich die bekannten Daten merkt und diese nicht auf unbekannte Beispiele anwenden kann.

Eine schlechte Leistung an den Lerndaten kann daran liegen, dass das Modell zu einfach ist (die Eingabefunktionen sind nicht ausdrucksstark genug), um das Ziel gut zu beschreiben. Die Leistung kann verbessert werden, indem die Flexibilität des Modells erhöht wird. Um die Flexibilität des Modells zu erhöhen, führen Sie die folgenden Schritte aus:

- Fügen Sie neue Domain-spezifische Funktionen und mehr kartesischen Produkte hinzu, und ändern Sie die Art der verwendeten Funktionsverarbeitung (z. B. Erhöhen der n-grams-Größe)
- Verringern Sie den Umfang der verwendeten Regularisation

Wenn Ihr Modell die Schulungsdaten übermäßig stark anpasst, ist es durchaus sinnvoll, entsprechende Maßnahmen zu ergreifen, um die Flexibilität des Modells zu reduzieren. Um die Flexibilität des Modells zu reduzieren, führen Sie die folgenden Schritte aus:

- Funktionsauswahl: Verwenden Sie weniger Funktionskombinationen, reduzieren Sie die n-grams-Größe, und reduzieren Sie die Anzahl der Bins für numerische Attribute.
- Erhöhen Sie den Umfang der verwendeten Regularisation.

Die Richtigkeit von Schulungs- und Prüfdaten kann gering sein, da der Lernalgorithmus nicht ausreichend Daten zum lernen zur Verfügung hatte. Sie können die Leistung verbessern, indem Sie die folgenden Schritte ausführen:

- Erhöhen Sie die Anzahl der Schulungsdatenbeispiele.
- Erhöhen Sie die Anzahl von Durchläufen durch die vorhandenen Schulungsdaten.

Mit dem Modell Voraussagenerstellen

Nachdem Sie nun über ein gut funktionierendes ML-Modell verfügen, verwenden Sie es, um Voraussagen zu treffen. In Amazon Machine Learning gibt es zwei Möglichkeiten für die Verwendung eines Modells für Voraussagen:

Stapelvoraussagen

Stapelvoraussagen sind nützlich, wenn Sie für eine Reihe von Beobachtungen gleichzeitig Voraussagen erstellen und anschließend auf einen bestimmten Prozentsatz oder an einer

bestimmten Anzahl Beobachtungen Maßnahmen ergreifen möchten. In der Regel benötigen Sie für eine solche Anwendung keine niedrige Latenz. Wenn Sie beispielsweise entscheiden möchten, welche Kunden Sie als Teil einer Werbekampagne für ein Produkt ansprechen möchten, und Sie erhalten Voraussagepunktzahlen für alle Kunden, sortieren Sie die Voraussagen Ihres Modells so, dass die Kunden identifiziert werden, die am ehesten kaufen werden, und nehmen Sie dann die top 5 %, die am wahrscheinlichsten kaufen werden.

Online-Voraussagen

Online-Vorhersageszenarien eignen sich für Fälle, in denen Sie Vorhersagen auf der one-by-one Grundlage jedes Beispiels unabhängig von den anderen Beispielen in einer Umgebung mit niedriger Latenz generieren möchten. Sie können Voraussagen beispielsweise verwenden, um direkte Entscheidungen darüber zu treffen, ob eine bestimmte Transaktion eine betrügerische Transaktion ist.

Modelle auf neue Daten umschulen

Damit ein Modell eine richtige Voraussage treffen kann, müssen die Daten, anhand derer die Voraussage getroffen wird, eine ähnliche Verteilung haben wie die Daten, mit denen das Modell geschult wurde. Da sich die Datenverteilung im Laufe der Zeit verschiebt, ist die Bereitstellung eines Modells keine einmalige Sache, sondern ein kontinuierlicher Prozess. Es empfiehlt sich, die eingehenden Daten fortlaufend zu überwachen und Ihr Modell neu zu schulen, wenn Sie feststellen, dass die Datenverteilung deutlich von der Datenverteilung der ursprünglichen Schulung abgewichen ist. Wenn die Überwachung der Daten zur Erkennung von Änderungen in der Datenverteilung im Rückstand ist, empfiehlt sich eine regelmäßige Schulung des Modells, beispielsweise täglich, wöchentlich oder monatlich. Um Modelle in Amazon ML neu zu schulen, müssen Sie auf der Grundlage Ihrer neuen Schulungsdaten ein neues Modell erstellen.

Der Amazon Machine Learning Learning-Prozess

In der folgenden Tabelle wird beschrieben, wie Sie die Amazon ML-Konsole verwenden, um den in diesem Dokument beschriebenen ML-Prozess durchzuführen.

ML-Prozess	Amazon ML-Aufgabe
Analysieren Ihrer Daten	Um Ihre Daten in Amazon ML zu analysieren, erstellen Sie eine Datenquelle und überprüfen Sie die Seite mit den Dateneinblicken.

ML-Prozess	Amazon ML-Aufgabe
Aufteilung von Daten in Schulungs- und Evaluierungsdatenquellen	<p>Amazon ML kann die Datenquelle so aufteilen, dass 70% der Daten für das Modelltraining und 30% für die Bewertung der Prognoseleistung Ihres Modells verwendet werden.</p> <p>Wenn Sie den Assistenten „ML-Modell erstellen“ mit den Standardeinstellungen verwenden, teilt Amazon ML die Daten für Sie auf.</p> <p>Wenn Sie den Assistenten zum Erstellen eines ML-Modells mit den benutzerdefinierten Einstellungen verwenden und das ML-Modell auswerten möchten, wird Ihnen eine Option angezeigt, mit der Amazon ML die Daten für Sie aufteilen und eine Auswertung für 30% der Daten durchführen kann.</p>
Ihre Schulungsdaten mischen	<p>Wenn Sie den Assistenten „ML-Modell erstellen“ mit den Standardeinstellungen verwenden, mischt Amazon ML Ihre Daten für Sie. Sie können Ihre Daten auch mischen, bevor Sie sie in Amazon ML importieren.</p>
Prozessfunktionen	<p>Der Prozess des Zusammenstellens von Schulungsdaten in einem optimalen Format für das Lernen und die Generalisierung wird als Funktionstransformation bezeichnet. Wenn Sie den Assistenten „ML-Modell erstellen“ mit Standardeinstellungen verwenden, schlägt Amazon ML Einstellungen zur Feature-Verarbeitung für Ihre Daten vor.</p> <p>Um Funktionsverarbeitungseinstellungen festzulegen, wählen Sie die Option Benutzerdefiniert des Assistenten zur ML-Modellerstellung aus und geben Sie ein Funktionsverarbeitungsrezept an.</p>
Schulen des Modells	<p>Wenn Sie den Assistenten „ML-Modell erstellen“ verwenden, um ein Modell in Amazon ML zu erstellen, trainiert Amazon ML Ihr Modell.</p>

ML-Prozess	Amazon ML-Aufgabe
Auswählen von Modellparametern	In Amazon ML können Sie vier Parameter einstellen, die sich auf die Prognoseleistung Ihres Modells auswirken: Modellgröße, Anzahl der Durchläufe, Art der Mischung und Regularisierung. Sie können diese Parameter einstellen, wenn Sie den Assistenten zur ML-Modellerstellung für die Erstellung eines ML-Modells verwenden und die Option Custom wählen.
Evaluieren der Modell-Performance	Verwenden Sie den Assistenten zum Erstellen von Evaluierungen, um die Voraussage-Performance Ihres Modells zu bewerten.
Funktionsauswahl	Der Lernalgorithmus von Amazon ML kann Funktionen entfernen, die nicht viel zum Lernprozess beitragen. Um anzugeben, dass Sie diese Funktionen auslassen möchten, wählen Sie bei der Erstellung des ML-Modells den <code>L1 regularization</code> -Parameter aus.
Festlegen eines Schwellenwerts für die Voraussagegenauigkeit	Überprüfen Sie Voraussage-Performance Ihre Modells im Evaluierungsbericht für verschiedene Schwellenwerte und legen Sie den Schwellenwert auf Basis Ihrer Business-Anwendung fest. Der Schwellenwert bestimmt, wie das Modell eine Voraussageübereinstimmung definiert. Passen Sie die Zahl an, um Fehleinstufungen zu steuern.
Verwenden des Modells	<p>Verwenden Sie Ihr Modell, um Voraussagen für einen Stapel von Beobachtungen zu erhalten, indem Sie den Assistenten zur Erstellung von Stapelvoraussagen verwenden.</p> <p>Alternativ können Sie mithilfe der <code>Predict-API</code> auch Voraussagen für individuelle Beobachtungen auf Abruf erhalten, indem Sie es Ihrem ML-Modell ermöglichen, Echtzeitvoraussagen zu verarbeiten.</p>

Einrichten von Amazon Machine Learning

Sie benötigen ein AWS-Konto, bevor Sie Amazon Machine Learning verwenden können. Falls Sie noch nicht über ein AWS-Konto verfügen, finden Sie weitere Informationen bei der Anmeldung zu AWS.

Anmelden bei AWS

Bei der Registrierung für Amazon Web Services (AWS) wird Ihr AWS-Konto automatisch für alle Dienste in AWS einschließlich Amazon ML registriert. Berechnet werden Ihnen aber nur die Services, die Sie nutzen. Wenn Sie bereits ein AWS-Konto haben, überspringen Sie diesen Schritt. Wenn Sie kein AWS-Konto haben, führen Sie die folgenden Schritte zum Erstellen eines Kontos aus.

Registrieren Sie sich für ein AWS-Konto wie folgt:

1. Gehen Sie zu <http://aws.amazon.com> und wählen Sie Anmeldung.
2. Folgen Sie den Anweisungen auf dem Bildschirm.

Der Anmeldeprozess beinhaltet auch einen Telefonanruf und die Eingabe einer PIN über die Telefontastatur.

Tutorial: Verwenden von Amazon ML zum Voraussagen der Reaktionen auf ein Marketingangebot

Mit Amazon Machine Learning (Amazon ML) können Sie Vorhersagemodelle erstellen und trainieren und Ihre Anwendungen in einer skalierbaren Cloud-Lösung hosten. In diesem Tutorial zeigen wir Ihnen, wie Sie die Amazon ML-Konsole verwenden, um eine Datenquelle zu erstellen, ein Modell für maschinelles Lernen (ML) zu erstellen und das Modell zur Generierung von Vorhersagen zu verwenden, die Sie in Ihren Anwendungen verwenden können.

Unsere Beispielübung zeigt, wie potenzielle Kunden für eine gezielte Marketingkampagne identifiziert werden. Sie können aber dieselben Prinzipien anwenden, um eine Vielfalt von ML-Modellen zu erstellen und zu verwenden. Für die Beispielübung verwenden Sie öffentlich verfügbare Banking- und Marketingdatensätze aus dem [University of California at Irvine \(UCI\) Machine Learning Repository](#). Diese Datensätze enthalten allgemeine Informationen über Kunden sowie deren Reaktion auf vorherige Marketingkontakte. Sie werden diese Daten verwenden, um zu ermitteln, welche Kunden mit der größten Wahrscheinlichkeit Ihr neues Produkt, eine Banktermineinlage, auch bekannt als Einlagenzertifikat, abonnieren werden.

Warning

Dieses Tutorial ist nicht im kostenlosen AWS-Kontingent enthalten. Weitere Informationen zu den Amazon ML-Preisen finden Sie unter [Amazon Machine Learning Learning-Preise](#).

Voraussetzung

Für das Tutorial benötigen Sie ein AWS-Konto. Wenn Sie noch kein AWS-Konto haben, informieren Sie sich unter [Einrichten von Amazon Machine Learning](#).

Schritte

- [Schritt 1: Vorbereitung Ihrer Daten](#)
- [Schritt 2: Erstellen einer Schulungsdatenquelle](#)
- [Schritt 3: Erstellen eines ML-Modells](#)
- [Schritt 4: Überprüfen der Voraussageleistung des ML-Modells und Festlegen eines Punktzahlschwellenwerts](#)

- [Schritt 5: Verwenden des ML-Modells zum Generieren von Voraussagen](#)
- [Schritt 6: Aufräumen](#)

Schritt 1: Vorbereitung Ihrer Daten

Beim Machine Learning erhalten Sie in der Regel die Daten und stellen sicher, dass sie richtig formatiert sind, bevor Sie mit dem Schulungsprozess beginnen. Für dieses Tutorial haben wir einen Beispieldatensatz aus dem [UCI Machine Learning Repository](#) abgerufen, ihn so formatiert, dass er den Amazon ML-Richtlinien entspricht, und ihn Ihnen zum Herunterladen zur Verfügung gestellt. Laden Sie den Datensatz von unserem Amazon Simple Storage Service (Amazon S3) -Speicherort herunter und laden Sie ihn in Ihren eigenen S3-Bucket hoch, indem Sie die Verfahren in diesem Thema befolgen.


Informationen zu den Formatierungsanforderungen von Amazon ML finden Sie unter [Das Datenformat für Amazon ML verstehen](#).

Vorgehensweise zum Herunterladen der Datensätze


1. Laden Sie die Datei mit den Verlaufsdaten für Kunden herunter, die Produkte ähnlich Ihrer Banktermineinlage gekauft haben, indem Sie auf [banking.zip](#) klicken. Entpacken Sie den Ordner und speichern Sie die Datei banking.csv-Datei auf Ihrem Computer.
2. Sie laden die Datei, mit der Sie vorhersagen können, ob potenzielle Kunden auf Ihr Angebot reagieren, durch Klicken auf [banking-batch.zip](#) herunter. Entpacken Sie den Ordner und speichern Sie die Datei banking-batch.csv auf Ihrem Computer.
3. Öffnen Sie `banking.csv`. Sie sehen Zeilen und Spalten mit Daten. Die Kopfzeile enthält die Attributnamen für jede Spalte. Ein Attribut ist eine eindeutige, benannte Eigenschaft, die ein bestimmtes Merkmal der einzelnen Kunden beschreibt. So gibt `nr_employed` beispielsweise den Anstellungsstatus des Kunden an. Jede Zeile stellt die Sammlung von Beobachtungen zu einem einzelnen Kunden dar.

banking.csv

euribor3m	nr_employed	y
4.857	5191	0
4.857	5191	0
4.857	5191	0
4.857	5191	0




Sie möchten, dass Ihr ML-Modell die Frage "Wird dieser Kunde mein neues Produkt abonnieren?" beantwortet. Im `banking.csv`-Datensatz ist die Antwort auf diese Frage das Attribut `y`, welches einen Wert von 1 (für "Ja") oder 0 (für "Nein") enthält. Das Attribut, dessen Vorhersage Amazon ML lernen soll, wird als Zielattribut bezeichnet.

 Note

Das Attribut `y` ist ein binäres Attribut. Es kann nur einen von zwei Werten enthalten, in diesem Fall 0 oder 1. Im ursprünglichen UCI-Datensatz ist das `y`-Attribut entweder "Yes" (Ja) oder "No" (Nein). Wir haben den ursprünglichen Datensatz für Sie bearbeitet. Alle Werte des Attributs `y`, die für "Ja" stehen, sind jetzt 1, und alle Werte, die für "Nein" stehen, sind jetzt 0. Wenn Sie Ihre eigenen Daten verwenden, können Sie andere Werte für ein binäres Attribut verwenden. Weitere Informationen zu gültigen Werten finden Sie unter [Verwenden des Felds AttributeType](#).

Die folgenden Beispiele zeigen die Daten bevor und nachdem wir die Werte in Attribut `y` in die binären Attribute 0 und 1 geändert haben.


Before transformation



banking.csv			y
euribor3m	nr_employed		
4.857	5191		no
4.857	5191		no
4.857	5191		yes
4.857	5191		yes
4.857	5191		no

After transformation

banking.csv



euribor3m	nr_employed	y
4.857	5191	0
4.857	5191	0
4.857	5191	1
4.857	5191	1
4.857	5191	0

Die `banking-batch.csv`-Datei enthält das `y`-Attribut nicht. Nachdem Sie ein ML-Modell erstellt haben, werden Sie das Modell zur Voraussage von `y` für jeden Datensatz in dieser Datei verwenden.

Laden Sie als Nächstes die `banking-batch.csv` Dateien `banking.csv` und auf Amazon S3 hoch.

Um die Dateien an einen Amazon S3 S3-Speicherort hochzuladen

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Erstellen Sie in der Liste All Buckets (Alle Buckets) einen Bucket oder wählen Sie den Speicherort aus, an dem Sie die Dateien hochladen möchten.
3. Wählen Sie in der Navigationsleiste die Option Hochladen aus.
4. Wählen Sie Add Files (Dateien hinzufügen) aus.
5. Navigieren Sie im Dialogfeld zu Ihrem Desktop, wählen Sie `banking.csv` und `banking-batch.csv` aus und klicken Sie dann auf Öffnen.

Jetzt können Sie Ihre [Schulungsdatenquelle erstellen](#).

Schritt 2: Erstellen einer Schulungsdatenquelle

Nachdem Sie den `banking.csv` Datensatz an Ihren Amazon Simple Storage Service (Amazon S3) -Standort hochgeladen haben, verwenden Sie ihn, um eine Trainingsdatenquelle zu erstellen. Eine Datenquelle ist ein Amazon Machine Learning-Objekt (Amazon ML), das den Speicherort Ihrer Eingabedaten und wichtige Metadaten zu Ihren Eingabedaten enthält. Amazon ML verwendet die Datenquelle für Operationen wie das Training und die Evaluierung von ML-Modellen.

Geben Sie Folgendes an, um eine Datenquelle zu erstellen:

- Der Amazon S3 S3-Speicherort Ihrer Daten und die Erlaubnis, auf die Daten zuzugreifen
- Das Schema, das die Namen der Attribute in den Daten und den Typ der einzelnen Attribute (numerisch, Text, kategorisch oder Binary) enthält
- Der Name des Attributs, das die Antwort enthält, deren Vorhersage Amazon ML lernen soll, das Zielattribut

Note

Die Datenquelle speichert Ihre Daten nicht, sondern verweist nur darauf. Vermeiden Sie es, die in Amazon S3 gespeicherten Dateien zu verschieben oder zu ändern. Wenn Sie sie verschieben oder ändern, kann Amazon ML nicht auf sie zugreifen, um ein ML-Modell zu erstellen, Bewertungen zu generieren oder Prognosen zu generieren.


Vorgehensweise zum Erstellen der Schulungsdatenquelle

1. Öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie Erste Schritte.


Note

In diesem Tutorial wird davon ausgegangen, dass Sie Amazon ML zum ersten Mal verwenden. Wenn Sie Amazon ML schon einmal verwendet haben, können Sie die Option Neues erstellen... verwenden. Drop-down-Liste im Amazon ML-Dashboard, um eine neue Datenquelle zu erstellen.

3. Wählen Sie auf der Seite Erste Schritte mit Amazon Machine Learning die Option Launch aus.




Get started with Amazon Machine Learning



Standard setup

Start creating your first ML model. If you don't have your data ready, you can use our sample dataset.
[Amazon Machine Learning Tutorial](#)

Launch



Dashboard

Skip straight to the Amazon Machine Learning dashboard.

View Dashboard

4. Stellen Sie auf der Seite Eingabedaten sicher, dass bei Where is your data located? (Wo befinden sich Ihre Daten?) die Option S3 ausgewählt ist.


Where is your data located? S3 Redshift

5. Geben Sie bei S3 Location (S3-Speicherort) den vollständigen Pfad zur `banking.csv`-Datei aus Schritt 1 "Vorbereitung Ihrer Daten" ein. Beispiel: `your-bucket/banking.csv`. Amazon ML stellt Ihrem Bucket-Namen für Sie `s3://` voran.
6. Geben Sie bei Datenquellenname den Wert **Banking Data 1** ein.

S3 location *

s3:// aml-sample-data/banking.csv

Enter the path to a single file or folder in Amazon S3. You need to grant Amazon ML permission to read this data. [Learn more](#).


If you already have a schema for this data, provide it in a file at `s3://<path-of-input-data>.schema`. If you don't have a schema, Amazon ML will help you create one on the next page. 

Datasource name

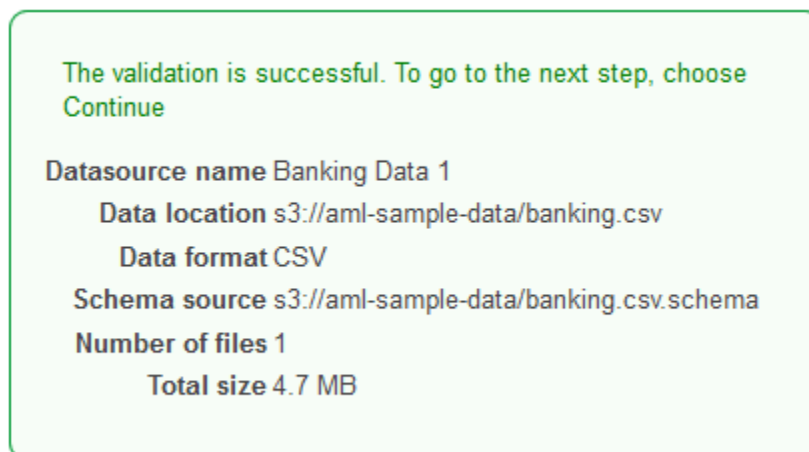
Banking Data 1

7. Wählen Sie Überprüfen.

- Klicken Sie im Dialogfeld S3 permissions (S3-Berechtigungen) auf Ja.



- Wenn Amazon ML auf die Datendatei am S3-Standort zugreifen und sie lesen kann, wird eine Seite ähnlich der folgenden angezeigt. Überprüfen Sie die Eigenschaften und wählen Sie dann Weiter aus.



Als Nächstes erstellen Sie ein Schema. Ein Schema ist die Information, die Amazon ML benötigt, um die Eingabedaten für ein ML-Modell zu interpretieren, einschließlich der Attributnamen und der ihnen zugewiesenen Datentypen sowie der Namen spezieller Attribute. Es gibt zwei Möglichkeiten, Amazon ML ein Schema zur Verfügung zu stellen:

- Geben Sie eine separate Schemadatei an, wenn Sie Ihre Amazon S3 S3-Daten hochladen.
- Erlauben Sie Amazon ML, die Attributtypen abzuleiten und ein Schema für Sie zu erstellen.

In diesem Tutorial bitten wir Amazon ML, das Schema abzuleiten.

Weitere Informationen zum Erstellen einer separaten Schemadatei finden Sie unter [Erstellen eines Datenschemas für Amazon ML](#).

Damit Amazon ML das Schema ableiten kann

1. Auf der Schemaseite zeigt Ihnen Amazon ML das Schema, das es abgeleitet hat. Überprüfen Sie die Datentypen, die Amazon ML für die Attribute abgeleitet hat. Es ist wichtig, dass den Attributen der richtige Datentyp zugewiesen wird, damit Amazon ML die Daten korrekt aufnehmen kann und die korrekte Feature-Verarbeitung der Attribute ermöglicht wird.
 - Attribute, für die es nur zwei mögliche Status gibt wie "Ja" oder "Nein", sollten als Binary markiert werden.
 - Attribute, die Zahlen oder Zeichenfolgen zur Kennzeichnung einer Kategorie sind, sollten als Categorical markiert werden.
 - Attribute, die numerischen Mengen sind und bei denen die Reihenfolge wichtig ist, sollten als Numeric markiert werden.
 - Attribute, die Zeichenfolgen sind und als durch Leerzeichen getrennte Wörter gehandhabt werden sollen, sollten als Text markiert werden.

<input type="checkbox"/>	Name	Data Type	Sample Field Value 1
<input type="checkbox"/>	age	Numeric	56
<input type="checkbox"/>	campaign	Numeric	1
<input type="checkbox"/>	cons_conf_idx	Numeric	-36.4
<input type="checkbox"/>	cons_price_idx	Numeric	93.994
<input type="checkbox"/>	contact	Categorical	telephone
<input type="checkbox"/>	day_of_week	Categorical	mon
<input type="checkbox"/>	default	Categorical	no
<input type="checkbox"/>	duration	Numeric	261
<input type="checkbox"/>	education	Categorical	basic.4y
<input type="checkbox"/>	emp_var_rate	Numeric	1.1

- In diesem Tutorial hat Amazon ML die Datentypen für alle Attribute korrekt identifiziert. Wählen Sie also Weiter.

Wählen Sie als Nächstes ein Zielattribut aus.


Denken Sie daran, dass das Zielattribut das Attribut ist, dessen Voraussage das ML-Modell lernen soll. Attribut y gibt an, ob eine Person in der Vergangenheit eine Kampagne abonniert hat: 1 (Ja) oder 0 (Nein).

Note

Wählen Sie ein Zielattribut nur aus, wenn Sie die Datenquelle für die Schulung und Evaluierung von ML-Modellen verwenden werden.

Vorgehensweise zum Auswählen von y als Zielattribut

- Klicken Sie unten rechts in der Tabelle auf den einzelnen Pfeil, um zur letzten Seite der Tabelle zu gelangen, auf der das Attribut y angezeigt wird.



- Wählen Sie in der Spalte Ziel den Wert y aus.



Amazon ML bestätigt, dass y als Ihr Ziel ausgewählt ist.

- Klicken Sie auf Weiter.

4. Vergewissern Sie sich, dass auf der Seite Zeilen-ID bei Does your data contain an identifier? (Enthalten Ihre Daten eine ID?) die Standardeinstellung Nein ausgewählt ist.
5. Klicken Sie auf Review und dann auf Continue.

Nun, da Sie eine Schulungsdatenquelle haben, können Sie [Ihr Modell erstellen](#).

Schritt 3: Erstellen eines ML-Modells

Nachdem Sie die Schulungsdatenquelle erstellt haben, können Sie diese verwenden, um ein ML-Modell zu erstellen, das Modell zu schulen und die Ergebnisse auszuwerten. Das ML-Modell ist eine Sammlung von Mustern, die Amazon ML während des Trainings in Ihren Daten findet. Sie verwenden das Modell, um Voraussagen zu erstellen.

Erstellen eines ML-Modells

1. Da der Assistent „Erste Schritte“ sowohl eine Trainingsdatenquelle als auch ein Modell erstellt, verwendet Amazon Machine Learning (Amazon ML) automatisch die Trainingsdatenquelle, die Sie gerade erstellt haben, und leitet Sie direkt zur Seite mit den ML-Modelleinstellungen weiter. Stellen Sie auf der Seite ML-Modelleinstellungen sicher, dass für ML-Modellname der Standardname **ML model: Banking Data 1** angezeigt wird.


Verwenden Sie einen benutzerfreundlichen Namen, wie z. B. den Standardnamen, damit Sie das ML-Modell leicht identifizieren und verwalten können.

2. Stellen Sie sicher, dass in den Schulungs- und Auswertungseinstellungen der Wert Standard ausgewählt ist.

Select training and evaluation settings

Recipes and training parameters control the ML model training process. You can select these settings for your ML model or use the defaults provided by Amazon ML. In either case, you can choose to have Amazon ML reserve a portion of the input data for evaluation. [Learn more.](#)

Default (Recommended)

Choose this option if you want to use Amazon ML's recommended recipe, training parameters, and evaluation settings. 

Name this evaluation (Optional)

Evaluation: ML model: Banking Data 1

3. Bestätigen Sie für Diese Auswertung benennen die Standardeinstellung **Evaluation: ML model: Banking Data 1**.
4. Wählen Sie Prüfen, überprüfen Sie die Einstellungen und klicken Sie dann auf Beenden.

Nachdem Sie „Fertig stellen“ ausgewählt haben, fügt Amazon ML Ihr Modell der Verarbeitungswarteschlange hinzu. Wenn Amazon ML Ihr Modell erstellt, wendet es die Standardeinstellungen an und führt die folgenden Aktionen aus:

- Die Schulungsdatenquelle wird in zwei Abschnitte aufgeteilt, von denen einer 70 % der Daten und der andere die verbleibenden 30 % enthält.
- Schult das ML-Modell im Abschnitt, der 70 % der Eingabedaten enthält
- Wertet das Modell mit den verbleibenden 30 % der Eingabedaten aus

Solange sich Ihr Modell in der Warteschlange befindet, meldet Amazon ML den Status als Ausstehend. Während Amazon ML Ihr Modell erstellt, meldet es den Status „In Bearbeitung“. Wenn alle Aktionen abgeschlossen wurden, meldet es den Status als Abgeschlossen. Warten Sie, bis die Auswertung abgeschlossen wurde, bevor Sie fortfahren.

Sie können jetzt [die Leistung Ihres Modells überprüfen und eine Grenzwertpunktzahl festlegen](#).

Weitere Informationen zu Schulungs- und Auswertungsmodellen finden Sie unter [Schulung von ML-Modellen](#) und [evaluate an ML model](#).

Schritt 4: Überprüfen der Voraussageleistung des ML-Modells und Festlegen eines Punktzahlschwellenwerts

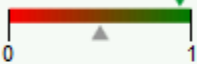
Nachdem Sie Ihr ML-Modell erstellt haben und Amazon Machine Learning (Amazon ML) es bewertet hat, wollen wir sehen, ob es gut genug ist, um es zu verwenden. Während der Evaluierung berechnete Amazon ML eine branchenübliche Qualitätsmetrik, die sogenannte Area Under a Curve (AUC) -Metrik, die die Leistungsqualität Ihres ML-Modells ausdrückt. Amazon ML interpretiert auch die AUC-Metrik, um Ihnen mitzuteilen, ob die Qualität des ML-Modells für die meisten Machine-Learning-Anwendungen ausreichend ist. (Weitere Informationen zur AUC finden Sie unter [Messung der ML-Modellgenauigkeit](#).) Betrachten wir nun die AUC-Metrik näher, und passen wir den Grenzwert an, um die Voraussageleistung Ihres Modells zu optimieren.

So überprüfen Sie die AUC-Metrik Ihres ML-Modells

1. Wählen Sie auf der Seite ML-Modell-Übersicht im Navigationsfenster ML-Modell-Bericht die Option Auswertungen und anschließend die Optionen Evaluation: ML-Modell: Banking-Modell 1 und Zusammenfassung.
2. Prüfen Sie auf der Seite Auswertungszusammenfassung die Auswertungszusammenfassung einschließlich der AUC-Leistungsmetrik des Modells.

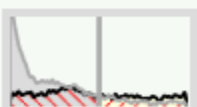
ML model performance metric

On your most recent evaluation, **ev-3fF6uP2W5VL**, the ML model's quality score is considered **extremely good** for most machine learning applications. ⓘ



AUC: 0.94
Baseline AUC: 0.50
Difference: 0.44

Next step: If you want to use this ML model to generate predictions, explore trade-offs to optimize the performance of your ML model first. ⓘ



Score threshold: 0.5



[Adjust score threshold](#)

Das ML-Modell erzeugt für jeden Datensatz in einer Voraussagedatenquelle eine numerische Voraussage und wendet dann einen Grenzwert an, um diese Punktzahlen in binäre Kennzeichnungen von 0 (für Nein) und 1 (für Ja) zu konvertieren. Durch das Ändern des Punktzahlgrenzwerts können Sie anpassen, wie das ML-Modell diese Kennzeichnungen zuweist. Legen Sie nun den Punktzahlgrenzwert fest.

So legen Sie einen Punktzahlgrenzwert für Ihr ML-Modell fest


1. Wählen Sie auf der Seite Auswertungszusammenfassung die Option Punktzahlgrenzwert anpassen.

ML model performance

This chart shows the distributions of your predicted answers for the actual "1" and "0" records in your evaluation data. Any overlap of the actual "1"  & "0"  is where your ML model guesses wrong. [Learn more](#).

Adjust the slider to indicate how much error you can tolerate from your ML model based on your needs. Moving the score threshold to the right decreases the number of false positives and increases the number of false negatives.

[Explain this chart](#)



Trade-off based on score threshold

[Reset score threshold \(0.5\)](#)

- **91% are correct**
500 true positive
10,766 true negative
- **9% are errors**
226 false positive
863 false negative

- 6% of the records are predicted as "1"
- 94% of the records are predicted as "0"

[Save score threshold at 0.50](#)

Advanced metrics



Accuracy 0.9119	0	<input type="range"/>	1
False positive rate 0.0206	0	<input type="range"/>	1
Precision 0.6887	0	<input type="range"/>	1
Recall 0.3668	0	<input type="range"/>	1

Sie können die Leistungsmetriken Ihres ML-Modells einstellen, indem Sie den Punktzahlgrenzwert anpassen. Durch die Anpassung dieses Wertes ändert sich das Vertrauen, dass das Modell in eine Voraussage haben muss, bevor es die Voraussage als positiv erachtet. Außerdem ändert sich, wie viele Falschmeldungen Sie in Ihren Voraussagen tolerieren.

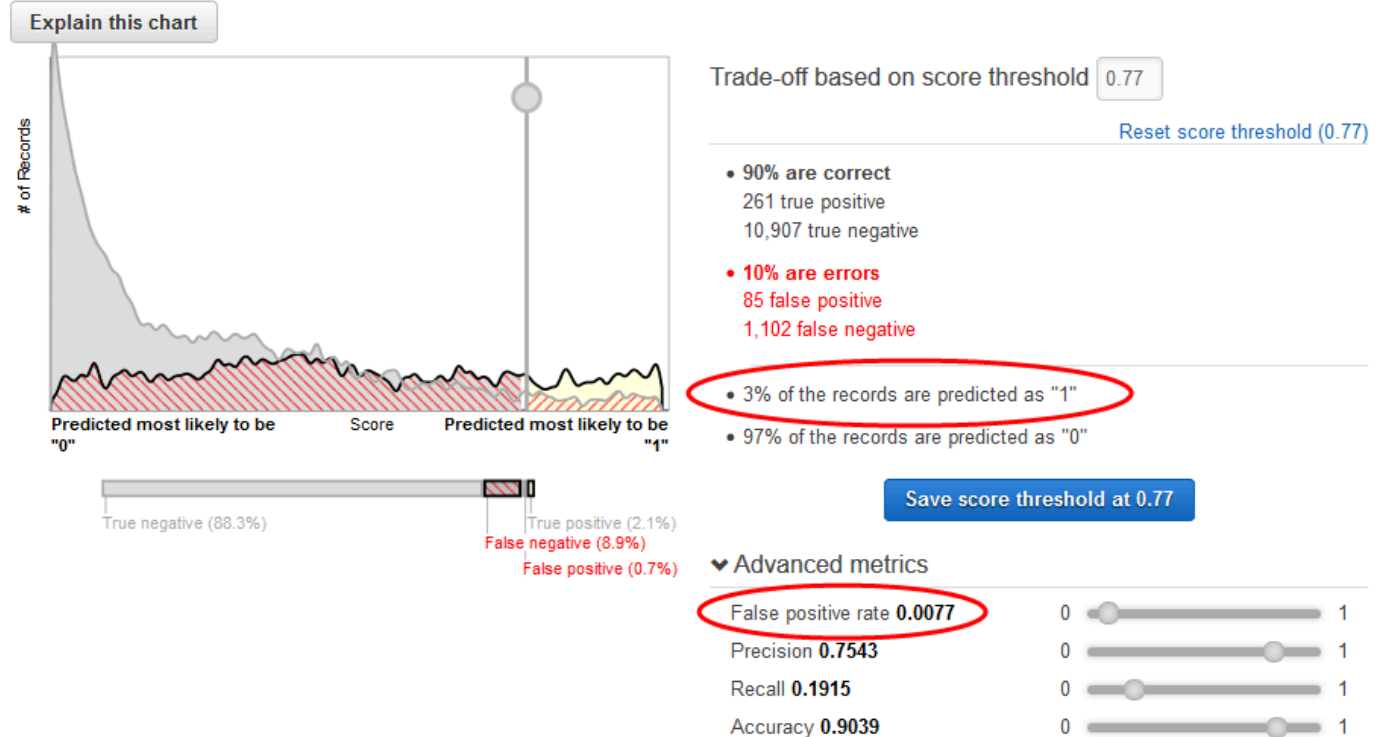
Sie können den Grenzwert für eine positive Voraussage kontrollieren, indem Sie den Punktzahlgrenzwert erhöhen, bis nur die Voraussagen als positiv erachtet werden, die am wahrscheinlichsten echte positive Voraussagen sind. Sie können den Punktzahlgrenzwert auch so weit reduzieren, bis keine negativen Falschmeldungen mehr auftreten. Wählen Sie Ihren Grenzwert entsprechend Ihren betrieblichen Anforderungen. Für dieses Tutorial kostet jede positive Falschmeldung das Unternehmen Geld; wir möchten also ein möglichst hohes Verhältnis von positiven zu negativen Falschmeldungen.

2. Angenommen, Sie möchten die obersten 3 % der Kunden berücksichtigen, die das Produkt abonnieren werden. Verschieben Sie den vertikalen Selektor so, dass der Wert des Punktzahlgrenzwerts 3 % der als "1" vorhergesagten Datensätze entspricht.

ML model performance

This chart shows the distributions of your predicted answers for the actual "1" and "0" records in your evaluation data. Any overlap of the actual "1"  & "0"  is where your ML model guesses wrong. [Learn more](#).

Adjust the slider to indicate how much error you can tolerate from your ML model based on your needs. Moving the score threshold to the right decreases the number of false positives and increases the number of false negatives.



Beachten Sie die Auswirkungen dieses Punktzahlgrenzwerts auf die Leistung des ML-Modells: Die Rate der positiven Falschmeldungen beträgt 0,007. Angenommen, diese Rate ist akzeptabel.

3. Wählen Sie Punktzahlgrenzwert bei 0,77 speichern.

Jedes Mal, wenn Sie dieses ML-Modell nutzen, um Voraussagen zu machen, werden Datensätze mit Punktzahlen über 0,77 als "1" und der Rest der Datensätze als "0" gekennzeichnet.

Weitere Informationen zum Punktzahlgrenzwert finden Sie unter [Binäre Klassifikation](#).

Jetzt können Sie [Mit dem Modell Voraussagen erstellen](#).

Schritt 5: Verwenden des ML-Modells zum Generieren von Voraussagen

Amazon Machine Learning (Amazon ML) kann zwei Arten von Vorhersagen generieren: Batch- und Echtzeitvorhersagen.

Eine Echtzeitprognose ist eine Vorhersage für eine einzelne Beobachtung, die Amazon ML bei Bedarf generiert. Echtzeitvoraussagen sind ideal für mobile Apps, Websites und andere Anwendungen, die Ergebnisse interaktiv verwenden sollen.

Eine Batch-Vorhersage ist eine Reihe von Vorhersagen für eine Gruppe von Beobachtungen. Amazon ML verarbeitet die Datensätze in einer Batch-Vorhersage zusammen, sodass die Verarbeitung einige Zeit in Anspruch nehmen kann. Verwenden Sie Stapelvoraussagen für Anwendungen, die Voraussagen für Gruppen von Beobachtungen benötigen oder Voraussagen, die Ergebnisse nicht interaktiv verwenden.

Für dieses Tutorial generieren Sie eine Echtzeit-Voraussage, die vorhersagt, ob ein potenzieller Kunde das neue Produkt abonnieren wird. Zudem können Sie Voraussagen für einen großen Batch potenzieller Kunden generieren. Für die Stapelvoraussage verwenden Sie die Datei `banking-batch.csv`, die Sie in [Schritt 1: Vorbereitung Ihrer Daten](#) hochgeladen haben.


Lassen Sie uns mit einer Echtzeitvoraussage beginnen.

Note

Für Anwendungen, die Echtzeitvoraussagen erfordern, müssen Sie einen Echtzeit-Endpoint für das ML-Modell erstellen. Es fallen Kosten für Sie an, während ein Echtzeit-Endpoint verfügbar ist. Bevor Sie Echtzeitvoraussagen tatsächlich nutzen und dabei Kosten anfallen, können Sie die Echtzeitvoraussage-Funktion testweise in Ihrem Web-Browser verwenden, ohne Echtzeit-Endpoint. Das reicht für dieses Tutorial aus.

So testen Sie eine Echtzeitvoraussage

1. Klicken Sie im Navigationsbereich ML model report auf Try real-time predictions.



ML model report

Summary

Settings

Monitoring

Tools

Try real-time predictions

2. Wählen Sie Paste a record aus.

Try real-time predictions

Try generating real-time predictions for free using the web browser on this page. To request a real-time prediction, complete the following form or provide a single data record in CSV format. To provide a data record, choose the **Paste a record** button.

Paste a record

Q Attribute name	Items per page: 10 -	« < 1 - 10 of 21 > »
Name	Type	Value

3. Fügen Sie im Dialogfeld Paste a record die folgende Beobachtung ein:

32, services, divorced, basic.9y, no, unknown, yes, cellular, dec, mon, 110, 1, 11, 0, nonexistent, -1.8, 9

4. Wählen Sie im Dialogfeld Datensatz einfügen die Option Senden aus, um zu bestätigen, dass Sie eine Vorhersage für diese Beobachtung generieren möchten. Amazon ML füllt die Werte in das Echtzeit-Prognoseformular ein.

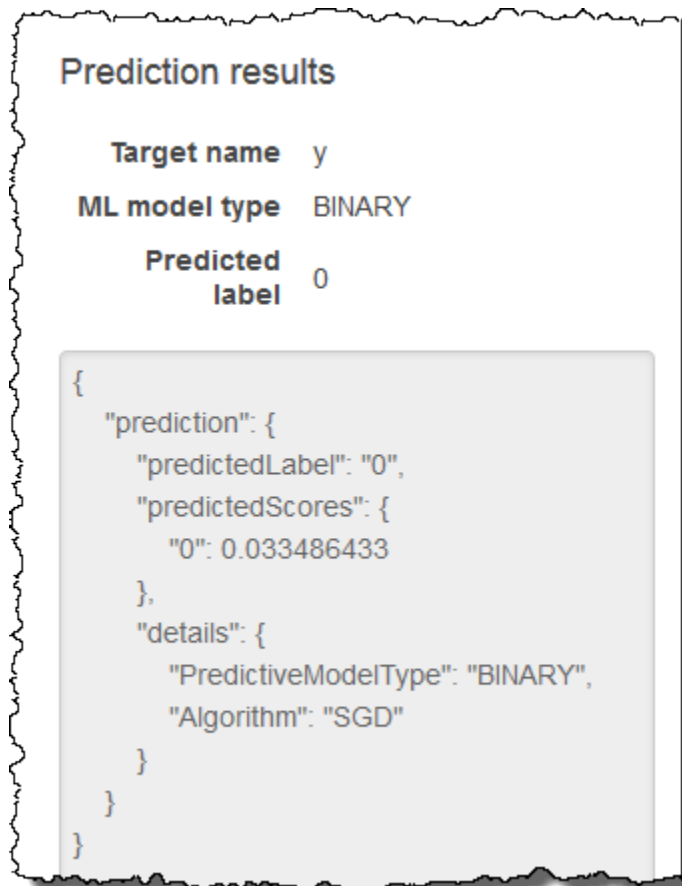
Q Attribute name	Items per page: 10 -	« < 1 - 10 of 21 > »	
Name	Type	Value	
1	age	Numeric	32.0

Note

Sie können auch die Wert-Felder auffüllen, indem Sie einzelne Werte eingeben. Unabhängig von der Methode, die Sie auswählen, sollten Sie eine Beobachtung bereitstellen, die nicht zur Modellschulung verwendet wurde.

5. Klicken Sie unten auf der Seite auf Create prediction.

Die Voraussage wird im Bereich Prediction results auf der rechten Seite angezeigt. Diese Voraussage hat eine Predicted (Voraussage)-Kennung von 0, was bedeutet, dass diese potenziellen Kunden wahrscheinlich nicht auf die Kampagne antworten. Eine Predicted (Voraussage)-Kennung von 1 würde bedeuten, dass der Kunde wahrscheinlich auf die Kampagne antwortet.




Erstellen Sie nun eine Stapelvoraussage. Sie geben Amazon ML den Namen des von Ihnen verwendeten ML-Modells, den Amazon Simple Storage Service (Amazon S3) -Speicherort der

Eingabedaten, für die Sie Prognosen generieren möchten (Amazon ML erstellt aus diesen Daten eine Batch-Prognose-Datenquelle) und den Amazon S3-Speicherort zum Speichern der Ergebnisse.

So erstellen Sie eine Stapelvoraussage

1. Wählen Sie Amazon Machine Learning und dann Stapelvoraussagen aus.



2. Wählen Sie Create new batch prediction.
3. Klicken Sie auf der Seite ML model for batch predictions (ML-Modell für Stapelvoraussagen) auf ML model: Banking Data 1.

Amazon ML zeigt den ML-Modellnamen, die ID, die Erstellungszeit und die zugehörige Datenquellen-ID an.

4. Klicken Sie auf Weiter.
5. Um Prognosen zu generieren, müssen Sie Amazon ML die Daten bereitstellen, für die Sie Prognosen benötigen. Diese werden als Eingabedaten bezeichnet. Fügen Sie zunächst die Eingabedaten in eine Datenquelle ein, damit Amazon ML darauf zugreifen kann.

Wählen Sie unter Locate the input data (Eingabedaten lokalisieren) die Option My data is in S3, and I need to create a datasource (Meine Daten befinden sich in S3 und ich muss eine Datenquelle erstellen).

Locate the input data I already created a datasource pointing to my S3 data
 My data is in S3, and I need to create a datasource

6. Geben Sie bei Datenquellenname den Wert **Banking Data 2** ein.
7. Geben Sie für S3 Location den vollständigen Speicherort der `banking-batch.csv` Datei ein:
your-bucket /**banking-batch.csv**

8. Legen Sie für Does the first line in your CSV contain the column names? (Enthält die erste Zeile Ihrer CSV-Datei die Spaltennamen?) den Wert Ja fest.
9. Wählen Sie Überprüfen.

Amazon ML validiert den Speicherort Ihrer Daten.
10. Klicken Sie auf Weiter.
11. Geben Sie als S3-Ziel den Namen des Amazon S3 S3-Speicherorts ein, in den Sie die Dateien in Schritt 1: Vorbereiten Ihrer Daten hochgeladen haben. Amazon ML lädt die Prognoseergebnisse dort hoch.
12. Akzeptieren Sie für den Namen der Batch-Vorhersage die Standardeinstellung **Batch prediction: ML model: Banking Data 1**. Amazon ML wählt den Standardnamen auf der Grundlage des Modells, das für die Erstellung von Prognosen verwendet wird. In diesem Tutorial wird das Modell sowie die Voraussagen nach dem Namen Schulungsdatenquelle benannt: Banking Data 1.
13. Wählen Sie Überprüfen aus.
14. Klicken Sie im Dialogfeld S3 permissions (S3-Berechtigungen) auf Ja.

S3 permissions

Amazon Machine Learning requires write permission on this S3 location to write output.
Would you like to grant Amazon Machine Learning write permission on this S3 location?

No

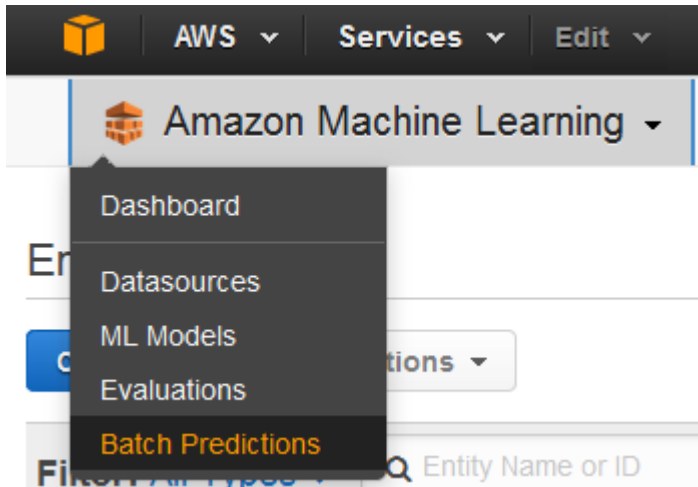
Yes

15. Klicken Sie auf der Seite Prüfen auf Beenden.


Die Anfrage zur Batch-Vorhersage wird an Amazon ML gesendet und in eine Warteschlange aufgenommen. Die Zeit, die Amazon ML benötigt, um eine Batch-Vorhersage zu verarbeiten, hängt von der Größe Ihrer Datenquelle und der Komplexität Ihres ML-Modells ab. Während Amazon ML die Anfrage bearbeitet, meldet es den Status In Bearbeitung. Nachdem die Stapelvorhersage abgeschlossen ist, ändert sich der Status der Anforderung in Abgeschlossen. Jetzt können Sie die Ergebnisse anzeigen.

So zeigen Sie die Voraussagen an

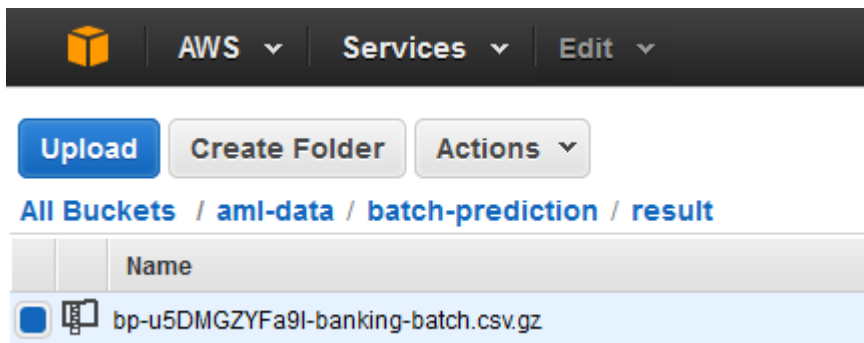
1. Wählen Sie Amazon Machine Learning und dann Stapelvoraussagen aus.



2. Wählen Sie in der Liste der Voraussagen Batch prediction: ML model: Banking Data 1. Die Seite Batch prediction info (Informationen zur Stapelvoraussage) wird angezeigt.

Name	Subscription propensity Predictions 
ID	bp-u5DMGZYFa9l
Creation Time	Mar 5, 2015 3:28:33 PM
Status	Completed
Log	Download Log
Datasource ID	ds-33Rqgz9w3ee
ML Model ID	ml-u7ljoShX2kX
Input S3 URL	s3://aml-data/banking-batch.csv
Output S3 URL	s3://aml-data/

3. Um die Ergebnisse der Batch-Vorhersage einzusehen, gehen Sie zur Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/> und navigieren Sie zu dem Amazon S3 S3-Speicherort, auf den im Feld Output S3-URL verwiesen wird. Von dort navigieren Sie zum Ergebnisordner, der etwa folgenden Namen hat: s3://aml-data/batch-prediction/result.



Die Voraussage Schlüssel wird in einer komprimierten gzip-Datei mit der Erweiterung .gz gespeichert.

- Laden Sie die Voraussagedatei auf Ihren Desktop herunter, wo Sie sie entpacken und öffnen können.

bestAnswer	score
0	0.06046
0	0.00507
0	0.01410
0	0.00170
0	0.00184
0	0.07133
0	0.30811

Die Datei verfügt über zwei Spalten: bestAnswer und score, sowie eine Zeile für jede Beobachtung in der Datenquelle. Die Ergebnisse in der Spalte bestAnswer basieren auf dem Punktzahlgrenzwert von 0,77, den Sie in [Schritt 4: Überprüfen der Voraussageleistung des ML-Modells und Festlegen eines Punktzahlschwellenwerts](#) festgelegt haben. Eine Punktzahl größer als 0,77 führt zu einer bestAnswer von 1. Dabei handelt es sich um eine positive Antwort oder Voraussage. Eine Punktzahl von weniger als 0,77 ergibt als bestAnswer 0. Dabei handelt es sich um eine negative Antwort oder Voraussage.

Die folgenden Beispiele zeigen positive und negative Voraussagen basierend auf den Schwellenwert von 0,77.

Positive Voraussage:

bestAnswer	score
1	0.8228876

In diesem Beispiel beträgt der Wert für `bestAnswer` 1 und die Punktzahl ist 0,8228876. Der Wert für `bestAnswer` ist 1, da die Punktzahl größer als der Schwellenwert von 0,77 ist. Eine `bestAnswer` von 1 gibt an, dass der Kunde Ihr Produkt wahrscheinlich kaufen wird, und ist somit eine positive Voraussage.

Negative Voraussage:

<code>bestAnswer</code>	<code>score</code>
0	0.7695356

In diesem Beispiel ist der Wert von `bestAnswer` 0, da die Punktzahl 0,7695356 ist und somit unter dem Schwellenwert von 0,77 liegt. Die `bestAnswer` 0 gibt an, dass der Kunden Ihr Produkt wahrscheinlich nicht kaufen wird, und ist somit eine negative Voraussage.

Jede Zeile des Stapelergebnisses entspricht einer Zeile in Ihrer Stapeleingabe (einer Beobachtung in Ihrer Datenquelle).

Nach der Analyse der Voraussagen können Sie die gewünschte Marketing-Kampagne durchführen, indem Sie z. B. allen mit einer vorausgesagten Punktzahl von 1 einen Flyer schicken.

Nachdem Sie Ihr Modell erstellt, geprüft und verwendet haben, [bereinigen Sie die erstellten Daten und AWS-Ressourcen](#), um zu vermeiden, dass hierfür unnötige Gebühren anfallen, und damit Ihr Arbeitsbereich übersichtlich bleibt.

Schritt 6: Aufräumen

Um zu vermeiden, dass zusätzliche Gebühren für Amazon Simple Storage Service (Amazon S3) anfallen, löschen Sie die in Amazon S3 gespeicherten Daten. Andere ungenutzte Amazon ML-Ressourcen werden Ihnen nicht in Rechnung gestellt. Wir empfehlen Ihnen jedoch, diese zu löschen, um Ihren Workspace sauber zu halten.

Um die in Amazon S3 gespeicherten Eingabedaten zu löschen

1. Öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Navigieren Sie zu dem Amazon S3 S3-Speicherort, an dem Sie die `banking-batch.csv` Dateien `banking.csv` und gespeichert haben.
3. Wählen Sie die `banking.csv`-, `banking-batch.csv`- und `.writePermissionCheck.tmp`-Dateien aus.
4. Wählen Sie Aktionen und anschließend Löschen aus.

5. Wenn Sie zur Bestätigung aufgefordert werden, klicken Sie auf OK.

Es wird Ihnen zwar nicht in Rechnung gestellt, die Aufzeichnung der von Amazon ML ausgeführten Batch-Vorhersage oder der Datenquellen, des Modells und der Auswertung, die Sie während des Tutorials erstellt haben, zu führen, aber wir empfehlen Ihnen, diese zu löschen, um zu verhindern, dass Ihr Workspace überladen wird.

Vorgehensweise zum Löschen von Stapelvoraussagen

1. Navigieren Sie zu dem Amazon S3 S3-Speicherort, an dem Sie die Ausgabe der Batch-Vorhersage gespeichert haben.
2. Wählen Sie den Ordner `batch-prediction` aus.
3. Wählen Sie Aktionen und anschließend Löschen aus.
4. Wenn Sie zur Bestätigung aufgefordert werden, klicken Sie auf OK.

Um die Amazon ML-Ressourcen zu löschen

1. Wählen Sie im Amazon ML-Dashboard die folgenden Ressourcen aus.
 - Die Banking Data 1-Datenquelle
 - Die Banking Data 1_[percentBegin=0, percentEnd=70, strategy=sequential]-Datenquelle
 - Die Banking Data 1_[percentBegin=70, percentEnd=100, strategy=sequential]-Datenquelle
 - Die Banking Data 2-Datenquelle
 - Das ML model: Banking Data 1-ML-Modell
 - Die Evaluation: ML model: Banking Data 1-Evaluierung
2. Wählen Sie Aktionen und anschließend Löschen aus.
3. Klicken Sie im Dialogfeld auf Delete, um alle ausgewählten Ressourcen zu löschen.

Sie haben das Tutorial jetzt erfolgreich abgeschlossen. Informationen zur weiteren Verwendung der Konsole zur Erstellung von Datenquellen, Modellen und Prognosen finden Sie im [Amazon Machine Learning Developer Guide](#). Weitere Informationen zur Verwendung der API finden Sie in der [Amazon Machine Learning-API-Referenz](#).

Erstellen und Verwenden von Datenquellen

Sie können Amazon ML-Datenquellen verwenden, um ein ML-Modell zu trainieren, ein ML-Modell auszuwerten und Batch-Vorhersagen mithilfe eines ML-Modells zu generieren. Datenquellenobjekte enthalten Metadaten über Ihre Eingabedaten. Wenn Sie eine Datenquelle erstellen, liest Amazon ML Ihre Eingabedaten, berechnet beschreibende Statistiken zu ihren Attributen und speichert die Statistiken, ein Schema und andere Informationen als Teil des Datenquellenobjekts. Nachdem Sie eine Datenquelle erstellt haben, können Sie [Amazon ML Data Insights](#) verwenden, um die statistischen Eigenschaften Ihrer Eingabedaten zu untersuchen, und Sie können die Datenquelle verwenden, um ein ML-Modell zu [trainieren](#).

Note

In diesem Abschnitt wird davon ausgegangen, dass Sie mit den [Konzepten von Amazon Machine Learning](#) vertraut sind.


Themen

- [Das Datenformat für Amazon ML verstehen](#)
- [Erstellen eines Datenschemas für Amazon ML](#)
- [Aufteilen Ihrer Daten](#)
- [Dateneinblicke](#)
- [Amazon S3 mit Amazon ML verwenden](#)
- [Erstellen einer Amazon ML-Datenquelle aus Daten in Amazon Redshift](#)
- [Verwenden von Daten aus einer Amazon RDS-Datenbank zur Erstellung einer Amazon ML-Datenquelle](#)

Das Datenformat für Amazon ML verstehen

Eingabedaten sind die Daten, die Sie zur Erstellung einer Datenquelle verwenden. Speichern Sie Ihre Eingabedaten als durch Kommas getrennte Werte (CSV). Jede Zeile in der CSV-Datei ist ein einzelner Datensatz bzw. eine Beobachtung. Jede Spalte in der CSV-Datei enthält ein Attribut der Beobachtung. Die folgende Abbildung zeigt den Inhalt einer CSV-Datei, die vier Beobachtungen enthält, die jeweils in einer eigenen Zeile stehen. Jede Beobachtung enthält acht Attribute, die durch ein Komma getrennt sind. Die Attribute stellen die folgenden Informationen zu jeder Person dar,

die durch eine Beobachtung repräsentiert wird: customerId, jobId, Bildung, Wohnen, Darlehen, Kampagne, Dauer, Kampagne. willRespondTo



Attribute

Amazon ML benötigt Namen für jedes Attribut. Sie können Attributnamen wie folgt angeben:

- Einbeziehen der Attributnamen in der ersten Zeile der CSV-Datei (auch als Kopfzeile bezeichnet), die Sie für Eingabedaten verwenden
- Einbeziehen der Attributnamen in einer separaten Schemadatei im selben S3-Bucket wie die Eingabedaten

Weitere Informationen zur Verwendung von Schemadateien finden Sie unter [Erstellen eines Datenschemas](#).

Im folgenden Beispiel für eine CSV-Datei sind die Namen der Attribute in der Kopfzeile enthalten.

```
customerId,jobId,education,housing,loan,campaign,duration,willRespondToCampaign
1,3,basic.4y,no,no,1,261,0
2,1,high.school,no,no,22,149,0
3,1,high.school,yes,no,65,226,1
4,2,basic.6y,no,no,1,151,0
```

Anforderungen an das Eingabedateiformat

Die CSV-Datei, die Ihre Eingabedaten enthält, muss die folgenden Anforderungen erfüllen:

- Muss reiner Text mit einem Zeichensatz wie z. B. ASCII, Unicode oder EBCDIC sein.
- Besteht aus Beobachtungen, eine Beobachtung pro Zeile.
- Für jede Beobachtung müssen die Attributwerte durch Komma getrennt werden.
- Wenn ein Attributwert ein Komma enthält (das Trennzeichen), muss der gesamte Attributwert in Anführungszeichen gesetzt werden.
- Jede Beobachtung muss mit einem end-of-line Zeichen abgeschlossen werden, bei dem es sich um ein Sonderzeichen oder eine Zeichenfolge handelt, die das Ende einer Zeile angibt.
- Attributwerte dürfen keine end-of-line Zeichen enthalten, auch wenn der Attributwert in doppelte Anführungszeichen eingeschlossen ist.
- Jede Beobachtung muss die gleiche Anzahl von Attributen und Folge von Attributen aufweisen.
- Jede Beobachtung darf nicht größer als 100 KB sein. Amazon ML lehnt während der Verarbeitung alle Beobachtungen ab, die größer als 100 KB sind. Wenn Amazon ML mehr als 10.000 Beobachtungen zurückweist, lehnt es die gesamte CSV-Datei ab.

Verwenden mehrerer Dateien als Dateneingabe für Amazon ML

Sie können Ihre Eingabe in Amazon ML als einzelne Datei oder als Sammlung von Dateien bereitstellen. Sammlungen müssen folgende Bedingungen erfüllen:

- Alle Dateien müssen dasselbe Datenschema haben.
- Alle Dateien müssen sich im selben Amazon Simple Storage Service (Amazon S3) -Präfix befinden, und der Pfad, den Sie für die Sammlung angeben, muss mit einem Schrägstrich ('/') enden.

Wenn Ihre Datendateien zum Beispiel `input1.csv`, `input2.csv` und `input3.csv` heißen und Ihr S3-Bucket-Name `"s3://examplebucket"` lautet, könnten Ihre Dateipfade wie folgt aussehen:

```
s3://1.csv examplebucket/path/to/data/input
```

```
s3://examplebucket/path/to/data/input2.csv
```

```
s3://examplebucket/path/to/data/input3.csv
```

Sie würden den folgenden S3-Speicherort als Eingabe für Amazon ML angeben:

```
's3://examplebucket/path/to/data/'
```


End-of-Line Zeichen im CSV-Format

Wenn Sie Ihre CSV-Datei erstellen, wird jede Beobachtung durch ein end-of-line Sonderzeichen abgeschlossen. Dieses Zeichen ist nicht sichtbar, wird aber automatisch am Ende jeder Beobachtung eingefügt, wenn Sie die Eingabetaste oder die Enter-Taste drücken. Das Sonderzeichen, das für steht, end-of-line hängt von Ihrem Betriebssystem ab. Unix-Systeme, wie z. B. Linux oder OS X, verwenden ein Zeilenvorschubzeichen, das durch "\n" (ASCII-Code 10 in Dezimalcode oder 0x0a in Hexadezimalcode) dargestellt wird. Microsoft Windows verwendet zwei Zeichen namens Wagenrücklauf und Zeilenvorschub, die mit "\r\n" (ASCII-Codes 13 und 10 in Dezimalcode oder 0x0d und 0x0a in Hexadezimalcode) dargestellt werden.

Wenn Sie OS X und Microsoft Excel zum Erstellen der CSV-Datei verwenden möchten, führen Sie die im Folgenden beschriebene Vorgangsweise aus. Stellen Sie sicher, dass Sie das richtige Format wählen.

So speichern Sie eine CSV-Datei, wenn Sie OS X und Excel verwenden

1. Beim Speichern der CSV-Datei wählen Sie Format und dann Windows Comma Separated (.csv).
2. Wählen Sie Speichern.



⚠ Important

Speichern Sie die CSV-Datei nicht in den Formaten Comma Separated Values (.csv) oder MS-DOS Comma Separated (.csv), da Amazon ML sie nicht lesen kann.

Erstellen eines Datenschemas für Amazon ML

Ein Schema umfasst alle Attribute der Eingabedaten und die entsprechenden Datentypen. Es ermöglicht Amazon ML, die Daten in der Datenquelle zu verstehen. Amazon ML verwendet die Informationen im Schema, um die Eingabedaten zu lesen und zu interpretieren, Statistiken zu berechnen, die richtigen Attributtransformationen anzuwenden und seine Lernalgorithmen zu optimieren. Wenn Sie kein Schema angeben, leitet Amazon ML eines aus den Daten ab.

Beispielschema

Damit Amazon ML die Eingabedaten korrekt lesen und genaue Prognosen erstellen kann, muss jedem Attribut der richtige Datentyp zugewiesen werden. Im Folgenden finden Sie ein Beispiel für die Zuweisung von Datentypen zu Attributen und die Berücksichtigung von Attributen und Datentypen in einem Schema. Wir nennen unser Beispiel "Kundenkampagne", da wir voraussagen möchten, welche Kunden auf unsere E-Mail-Kampagne reagieren werden. Unsere Eingabedatei ist eine CSV-Datei mit neun Spalten:

```
1,3,web developer,basic.4y,no,no,1,261,0
2,1,car repair,high.school,no,no,22,149,0
3,1,car mechanic,high.school,yes,no,65,226,1
4,2,software developer,basic.6y,no,no,1,151,0
```

Dies ist das Schema für diese Daten:

```
{
  "version": "1.0",
  "rowId": "customerId",
  "targetAttributeName": "willRespondToCampaign",
  "dataFormat": "CSV",
  "dataFileContainsHeader": false,
  "attributes": [
    {
      "attributeName": "customerId",
      "attributeType": "CATEGORICAL"
    },
    {
      "attributeName": "jobId",
```

```
    "attributeType": "CATEGORICAL"
  },
  {
    "attributeName": "jobDescription",
    "attributeType": "TEXT"
  },
  {
    "attributeName": "education",
    "attributeType": "CATEGORICAL"
  },
  {
    "attributeName": "housing",
    "attributeType": "CATEGORICAL"
  },
  {
    "attributeName": "loan",
    "attributeType": "CATEGORICAL"
  },
  {
    "attributeName": "campaign",
    "attributeType": "NUMERIC"
  },
  {
    "attributeName": "duration",
    "attributeType": "NUMERIC"
  },
  {
    "attributeName": "willRespondToCampaign",
    "attributeType": "BINARY"
  }
]
}
```

In der Schemadatei für dieses Beispiel hat `rowId` den Wert `customerId`:

```
"rowId": "customerId",
```

Das Attribut `willRespondToCampaign` ist als Zielattribut festgelegt:

```
"targetAttributeName": "willRespondToCampaign ",
```

Das Attribut `customerId` und der Datentyp `CATEGORICAL` sind der ersten Spalte zugewiesen, das Attribut `jobId` und der Datentyp `CATEGORICAL` sind der zweiten Spalte zugewiesen, das Attribut `jobDescription` und der Datentyp `TEXT` sind der dritten Spalte zugewiesen, das Attribut `education` und der Datentyp `CATEGORICAL` sind der vierten Spalte zugewiesen usw. Die neunte Spalte ist dem Attribut `willRespondToCampaign` und dem Datentyp `BINARY` zugewiesen, und dieses Attribut ist auch als Zielattribut festgelegt.

Das `targetAttributeName` Feld verwenden

Der Wert `targetAttributeName` ist der Name des Attributs, das Sie voraussagen möchten. Sie müssen `targetAttributeName` bei der Erstellung oder der Bewertung eines Modells zuweisen.

Wenn Sie ein ML-Modell trainieren oder auswerten, identifiziert `targetAttributeName` das den Namen des Attributs in den Eingabedaten, das die „richtigen“ Antworten für das Zielattribut enthält. Amazon ML verwendet das Ziel, das die richtigen Antworten enthält, um Muster zu erkennen und ein ML-Modell zu generieren.

Wenn Sie Ihr Modell auswerten, verwendet Amazon ML das Ziel, um die Richtigkeit Ihrer Prognosen zu überprüfen. Nachdem Sie das ML-Modell erstellt und bewertet haben, können Sie Daten ohne zugewiesenen `targetAttributeName` verwenden, um Voraussagen mit Ihrem ML-Modell zu erzeugen.

Sie definieren das Zielattribut in der Amazon ML-Konsole, wenn Sie eine Datenquelle erstellen, oder in einer Schemadatei. Wenn Sie eine eigene Schemadatei erstellen, verwenden Sie die folgende Syntax, um das Zielattribut festzulegen:

```
"targetAttributeName": "exampleAttributeTarget",
```

In diesem Beispiel ist `exampleAttributeTarget` der Name des Attributs in Ihrer Eingabedatei, welches das Zielattribut ist.

Verwenden des Felds `rowID`

Die `row ID` ist ein optionales Flag, das einem Attribut in den Eingabedaten zugewiesen ist. Wenn festgelegt, ist das als `row ID` markierte Attribut im Voraussageergebnis enthalten. Anhand dieses Attributs kann einfacher zugeordnet werden, welche Voraussage welcher Beobachtung entspricht. Ein Beispiel für eine gute `row ID` ist eine Kunden-ID oder ein ähnliches eindeutiges Attribut.

Note

Die Zeilen-ID dient nur zu Referenzzwecken. Amazon ML verwendet es nicht, wenn ein ML-Modell trainiert wird. Wenn ein Attribut als Zeilen-ID festgelegt wird, kann es nicht mehr zur Schulung eines ML-Modells verwendet werden.

Sie definieren das `row ID` in der Amazon ML-Konsole, wenn Sie eine Datenquelle erstellen, oder in einer Schemadatei. Wenn Sie eine eigene Schemadatei erstellen, verwenden Sie die folgende Syntax, um die `row ID` festzulegen:

```
"rowId": "exampleRow",
```

Im voranstehenden Beispiel ist `exampleRow` der Name des Attributs in Ihrer Eingabedatei, welches als Zeilen-ID festgelegt ist.

Beim Generieren von Stapelvoraussagen erhalten Sie möglicherweise folgendes Ergebnis:

```
tag,bestAnswer,score  
55,0,0.46317  
102,1,0.89625
```

In diesem Beispiel stellt `RowID` das Attribut `customerId` dar. Beispiel: `customerId 55` wird auf unsere E-Mail-Kampagne mit geringer Wahrscheinlichkeit (0,46317) reagieren, während `customerId 102` auf unsere E-Mail-Kampagne mit hoher Wahrscheinlichkeit (0,89625) reagieren wird.

Verwenden des Felds `AttributeType`

In Amazon ML gibt es vier Datentypen für Attribute:

Binary

Wählen Sie `BINARY` für ein Attribut, das nur zwei möglichen Status haben kann, z. B. `yes` oder `no`.

So kann beispielsweise das Attribut `isNew`, das nachverfolgt, ob eine Person ein neuer Kunde ist, den Wert `true` aufweisen, um anzuzeigen, dass der Kunde ein Neukunde ist, und den Wert `false`, um anzuzeigen, dass er oder sie kein neuer Kunde ist.

Gültige negative Werte sind `0`, `n`, `no`, `f` und `false`.

Gültige positive Werte sind `1`, `y`, `yes`, `t` und `true`.

Amazon ML ignoriert Groß- und Kleinschreibung bei binären Eingaben und entfernt den umgebenden Leerraum. " FaLSe " ist beispielsweise ein gültiger Binärwert. Sie können die Binärwerte, die Sie in derselben Datenquelle verwenden, mischen, z. B. mit `true`, und `no`. 1
Amazon ML-Ausgaben nur `0` und `1` für binäre Attribute.

Kategorisch

Wählen Sie `CATEGORICAL` für ein Attribut, das eine begrenzte Anzahl eindeutiger Zeichenfolgenwerte aufnimmt. Beispielsweise eine Benutzer-ID, der Monat und eine ZIP-Code sind kategorische Werte. kategorische Attribute werden als einzelne Zeichenfolge behandelt und nicht weiter als Token verwendet.

Numerischer Wert

Wählen Sie `NUMERIC` für ein Attribut, das eine Menge als Wert verwendet.

Beispiel: Temperatur, Gewicht und Klickrate sind numerische Werte.

Nicht alle Attribute mit Zahlen sind numerisch. Kategorische Attribute, wie z. B. die Tage des Monats und IDs, werden häufig als Zahlen dargestellt. Um als numerische Zahl zu gelten, muss eine Zahl mit einer anderen Zahl vergleichbar sein. Die Kunden-ID 664727 enthält beispielsweise keine Informationen zur Kunden-ID 124552, aber eine Gewichtung von 10 informiert Sie darüber, dass das Attribut schwerer gewichtet ist als ein Attribut mit einer Gewichtung von 5. Tage des Monats sind nicht numerischen, da der Erste eines Monats vor oder nach dem Zweiten eines anderen Monat auftreten kann.

Note

Wenn Sie Amazon ML verwenden, um Ihr Schema zu erstellen, weist es allen Attributen, die Zahlen verwenden, den `Numeric` Datentyp zu. Wenn Amazon ML Ihr Schema erstellt, suchen Sie nach falschen Zuweisungen und setzen Sie diese Attribute auf `CATEGORICAL`.

Text

Wählen Sie `TEXT` für ein Attribut, das eine Zeichenfolge von Wörtern ist. Beim Einlesen von Textattributen konvertiert Amazon ML diese in Token, die durch Leerzeichen getrennt sind.

Beispielsweise wird `email subject` zu `email` und `subject` und `email-subject` `here` wird zu `email-subject` und `here`.

Wenn der Datentyp für eine Variable im Trainingsschema nicht mit dem Datentyp für diese Variable im Bewertungsschema übereinstimmt, ändert Amazon ML den Bewertungsdatentyp, sodass er dem Trainingsdatentyp entspricht. Wenn das Trainingsdatenschema der Variablen beispielsweise den Datentyp von TEXT zuweist, das Bewertungsschema jedoch den Datentyp NUMERIC bis zuweist, behandelt Amazon ML die Altersangaben in den Bewertungsdaten als TEXT Variablen statt als Variablen. NUMERIC

Weitere Informationen zu Statistiken zu den einzelnen Datentypen finden Sie unter [Beschreibende Statistiken](#).

Bereitstellung eines Schemas für Amazon ML

Jede Datenquelle braucht ein Schema. Sie können zwischen zwei Möglichkeiten wählen, Amazon ML ein Schema zur Verfügung zu stellen:

- Erlauben Sie Amazon ML, die Datentypen der einzelnen Attribute in der Eingabedatendatei abzuleiten und automatisch ein Schema für Sie zu erstellen.
- Geben Sie eine Schemadatei an, wenn Sie Ihre Amazon Simple Storage Service (Amazon S3) - Daten hochladen.

Erlauben Sie Amazon ML, Ihr Schema zu erstellen

Wenn Sie die Amazon ML-Konsole verwenden, um eine Datenquelle zu erstellen, verwendet Amazon ML einfache Regeln, die auf den Werten Ihrer Variablen basieren, um Ihr Schema zu erstellen. Wir empfehlen Ihnen dringend, das von Amazon ML erstellte Schema zu überprüfen und die Datentypen zu korrigieren, falls sie nicht korrekt sind.

Bereitstellen eines Schemas

Nachdem Sie Ihre Schemadatei erstellt haben, müssen Sie sie für Amazon ML verfügbar machen. Sie haben zwei Optionen:

1. Stellen Sie das Schema mithilfe der Amazon ML-Konsole bereit.

Verwenden Sie die Konsole zum Erstellen Ihrer Datenquelle, und berücksichtigen Sie dabei die Schemadatei, indem Sie die Erweiterung `.schema` an den Namen Ihrer Eingabedatendatei

anhängen. Wenn der Amazon Simple Storage Service (Amazon S3) -URI zu Ihren Eingabedaten beispielsweise `s3://my-bucket-name/data/input.csv`, the URI to your schema will be `s3://my-bucket-name/data/input.csv.schema` lautet. Amazon ML findet automatisch die von Ihnen bereitgestellte Schemadatei, anstatt zu versuchen, das Schema aus Ihren Daten abzuleiten.

Um ein Verzeichnis mit Dateien als Dateneingabe für Amazon ML zu verwenden, hängen Sie die Erweiterung `.schema` an Ihren Verzeichnispfad an. Wenn sich Ihre Datendateien beispielsweise am Speicherort `s3:///schema` befinden. `examplebucket/path/to/data/`, the URI to your schema will be `s3://examplebucket/path/to/data`

2. Stellen Sie das Schema mithilfe der Amazon ML-API bereit.

Wenn Sie die Amazon ML-API aufrufen möchten, um Ihre Datenquelle zu erstellen, können Sie die Schemadatei in Amazon S3 hochladen und dann den URI zu dieser Datei im `DataSchemaLocationS3` API-Attribut angeben. `CreateDataSourceFromS3` [Weitere Informationen finden Sie unter CreateDataSourceFrom S3.](#)

Sie können das Schema direkt in der Payload `CreateDataSource` von* angeben, APIs anstatt es zuerst in Amazon S3 zu speichern. Dazu fügen Sie die vollständige Schemazeichenfolge in das `DataSchema` Attribut `CreateDataSourceFromS3`, `CreateDataSourceFromRDS`, oder `CreateDataSourceFromRedshift` APIs ein. Weitere Informationen finden Sie unter [Amazon Machine Learning API Reference](#).

Aufteilen Ihrer Daten

Das wesentliche Ziel eines ML-Modells ist es, genaue Voraussagen über zukünftige Daten-Instances über die Schulungsmodelle hinaus zu erreichen. Bevor Sie ein ML-Modell verwenden, um Voraussagen zu erstellen, müssen Sie die Leistung der Voraussagen des Modells bewerten. Zur Einschätzung der Qualität eines ML-Modells für Voraussagen mit Daten, die es noch nicht gesehen hat, können wir einen Teil der Daten, für die wir bereits die Antwort kennen, als Vertreter für zukünftige Daten reservieren oder aufteilen und auswerten, wie gut das ML-Modell die richtigen Antworten für diese Daten antizipiert. Teilen Sie die Datenquelle in einen Teil als Schulungsdatenquelle und einen Teil als Auswertungsdatenquelle auf.

Amazon ML bietet drei Optionen für die Aufteilung Ihrer Daten:

- Daten vorab aufteilen — Sie können die Daten in zwei Dateneingabeorte aufteilen, bevor Sie sie auf Amazon Simple Storage Service (Amazon S3) hochladen und damit zwei separate Datenquellen erstellen.

- **Sequentielles Aufteilen von Amazon ML** — Sie können Amazon ML anweisen, Ihre Daten sequentiell aufzuteilen, wenn Sie die Trainings- und Bewertungsdatenquellen erstellen.
- **Amazon ML Random Split** — Sie können Amazon ML anweisen, Ihre Daten mithilfe einer voreingestellten Zufallsmethode aufzuteilen, wenn Sie die Trainings- und Bewertungsdatenquellen erstellen.



Vorabtrennung Ihrer Daten

Wenn Sie explizite Kontrolle über die Daten in den Schulungs- und Auswertungsdatenquellen wünschen, teilen Sie die Daten in separate Datenverzeichnisse auf und erstellen Sie separate Datenquellen für die Eingabe- und Auswertungsverzeichnisse.

Sequenzielle Aufteilung Ihrer Daten

Eine einfache Möglichkeit, Ihre Eingabedaten für Schulung und Auswertung aufzuteilen, ist die Auswahl nicht überlappender Teilmengen Ihrer Daten, wobei die Reihenfolge der Datensätze beibehalten wird. Dieser Ansatz ist nützlich, wenn Sie Ihre ML-Modelle mit Daten von einem bestimmten Datum oder innerhalb eines bestimmten Zeitraums auswerten möchten. Angenommen, Sie haben die Kundenbindungsdaten der letzten fünf Monate, und Sie möchten diese historischen Daten nutzen, um die Kundenbindung für den nächsten Monat vorauszusagen. Mit der Nutzung der Daten aus dem Anfangsbereich für die Schulung und der Daten aus dem Endbereich für die Auswertung erhalten Sie wahrscheinlich eine genauere Einschätzung der Modellqualität als bei Verwendung von Datensätzen aus dem gesamten Datumsbereich.

In der folgenden Abbildung finden Sie Beispiele dafür, wann Sie eine sequenzielle Aufteilungsstrategie statt einer Zufallsmethode verwenden sollten.

Case 1: Sequential split is the **correct** strategyCase 2: Sequential split is the **wrong** strategy


Wenn Sie eine Datenquelle erstellen, können Sie wählen, ob Sie Ihre Datenquelle sequentiell aufteilen möchten. Amazon ML verwendet die ersten 70 Prozent Ihrer Daten für das Training und die restlichen 30 Prozent der Daten für die Auswertung. Dies ist der Standardansatz, wenn Sie die Amazon ML-Konsole verwenden, um Ihre Daten aufzuteilen.

Zufällige Aufteilung Ihrer Daten

Zufälliges Aufteilen der Eingabedaten in Schulungs- und Auswertungsdatenquellen stellt sicher, dass die Verteilung von Daten in der Schulungs- und Auswertungsdatenquelle ähnlich ist. Wählen Sie diese Option, wenn Sie die Reihenfolge der Eingabedaten nicht beibehalten müssen.

Amazon ML verwendet eine vordefinierte Methode zur Generierung von Pseudozufallszahlen, um Ihre Daten aufzuteilen. Der Seed-Startwert basiert teilweise auf einer Eingabezeichenfolge und teilweise auf dem Inhalt der Daten. Standardmäßig verwendet die Amazon ML-Konsole den S3-Speicherort der Eingabedaten als Zeichenfolge. API-Benutzer können eine benutzerdefinierte Zeichenfolge festlegen. Das bedeutet, dass Amazon ML bei demselben S3-Bucket und denselben Daten die Daten jedes Mal auf dieselbe Weise aufteilt. Um zu ändern, wie Amazon ML die Daten aufteilt, können Sie die `CreateDataSourceFromRDS` API `CreateDataSourceFromS3` `CreateDataSourceFromRedshift`, oder verwenden und einen Wert für die Startzeichenfolge angeben. Wenn Sie diese verwenden, APIs um separate Datenquellen für Training und Evaluierung zu erstellen, ist es wichtig, denselben Start-String-Wert für beide

Datenquellen und das Komplement-Flag für eine Datenquelle zu verwenden, um sicherzustellen, dass es keine Überschneidungen zwischen den Trainings- und Bewertungsdaten gibt.



Ein häufiges Problem bei der Entwicklung eines hochwertigen ML-Modells ist die Auswertung der ML-Modells mit Daten, die nicht den Daten für die Schulung entsprechen. Angenommen, Sie verwenden ML, um ein Filmgenre vorauszusagen, und Ihre Schulungsdaten enthalten Filme aus den Segmenten Abenteuer, Komödie und Dokumentation. Ihre Auswertungsdaten enthalten jedoch nur Daten aus dem Genre Liebesfilm und Thriller. In diesem Fall konnte das ML-Modell keine Informationen über die Filmgenre Liebesfilm und Thriller lernen, und die Auswertung konnte nicht feststellen, wie gut das Modell die Muster für Abenteuer, Komödie und Dokumentation gelernt hat. Demzufolge sind die Genre-Informationen nutzlos, und die Qualität der ML-Modellvoraussagen für alle Genres ist beeinträchtigt. Das Modell und die Auswertung sind zu unterschiedlich (extrem unterschiedliche beschreibende Statistiken), als dass sie nützlich wären. Dies kann der Fall sein, wenn die Eingabedaten nach einer der Spalten im Datensatz sortiert werden und dann sequenziell aufgeteilt werden.

Wenn Ihre Schulungs- und Auswertungsdatenquellen unterschiedliche Datenverteilungen haben, sehen Sie eine Auswertungswarnung in der Modellauswertung. Weitere Informationen zu Auswertungswarnungen finden Sie unter [Auswertungswarnungen](#).

Sie müssen die zufällige Aufteilung in Amazon ML nicht verwenden, wenn Sie Ihre Eingabedaten bereits randomisiert haben, z. B. durch zufälliges Mischen Ihrer Eingabedaten in Amazon S3 oder durch die Verwendung einer Amazon Redshift Redshift-SQL-Abfrage oder einer `rand()` MySQL-SQL-Abfragefunktion bei der Erstellung der `rand()` Datenquellen. In diesen Fällen können Sie die sequenzielle Aufteilungsoption zum Erstellen von Schulungs- und Auswertungsdatenquellen mit ähnlichen Verteilungen verwenden.

Dateneinblicke

Amazon ML berechnet deskriptive Statistiken zu Ihren Eingabedaten, anhand derer Sie Ihre Daten verstehen können.

Beschreibende Statistiken

Amazon ML berechnet die folgenden beschreibenden Statistiken für verschiedene Attributtypen:

Numerischer Wert:

- Verteilungshistogramme
- Anzahl ungültiger Werte
- Minimale, mittlere, durchschnittliche und maximale Werte

Binär und kategorisch:

- Anzahl (eindeutige Werte pro Kategorie)
- Wertverteilungshistogramm
- Häufigste Werte
- Anzahl eindeutiger Werte
- Prozentsatz des tatsächlichen Werts (nur binär)
- Bedeutendste Wörter
- Häufigste Wörter

Text:

- Name des Attributs
- Korrelation zum Ziel (wenn ein Ziel festgelegt ist)
- Wörter gesamt
- Eindeutige Wörter
- Umfang der Anzahl der Wörter in einer Zeile
- Umfang der Wortlängen
- Bedeutendste Wörter

Zugreifen auf Data Insights über die Amazon ML-Konsole

In der Amazon ML-Konsole können Sie den Namen oder die ID einer beliebigen Datenquelle auswählen, um deren Data Insights-Seite anzuzeigen. Auf dieser Seite finden Sie Metriken und Visualisierungen, mit deren Hilfe Sie mehr über die Eingabedaten in Verbindung mit der Datenquelle erfahren, einschließlich der folgenden Informationen:

- Datenzusammenfassung
- Zielverteilungen
- Fehlende Werte
- Ungültige Werte
- Zusammenfassende Statistik der Variablen nach Datentyp
- Verteilung der Variablen nach Datentyp

In den folgenden Abschnitten werden die Metriken und Visualisierungen im Detail beschrieben.


Datenzusammenfassung

Der zusammenfassende Datenbericht einer Datenquelle enthält zusammenfassende Informationen, einschließlich der Datenquellen-ID, Name, wo sie abgeschlossen wurde, aktueller Status, Zielattribut, Eingabedateninformationen (S3-Bucket-Speicherort, Datenformat, Anzahl der verarbeiteten Datensätze und Anzahl der fehlerhaften Datensätze während der Verarbeitung) sowie die Anzahl der Variablen nach Datentyp.

Zielverteilungen

Der Zielverteilungsbericht zeigt die Verteilung von Zielattributen der Datenquelle. Im folgenden Beispiel gibt es 39.922 Beobachtungen, bei denen das willRespondTo Kampagnen-Zielattribut 0 entspricht. Dies ist die Anzahl der Kunden, die nicht auf die E-Mail-Kampagne reagiert haben. Es

gibt 5.289 Beobachtungen, bei denen willRespondTo Campaign gleich 1 ist. Dies ist die Anzahl der Kunden, die auf die E-Mail-Kampagne reagiert haben.



Fehlende Werte

Der Bericht über fehlende Werte listet die Attribute in den Eingabedaten auf, für die Werte fehlen. Nur Attribute mit numerischen Datentypen können fehlende Werte haben. Da fehlende Werte sich auf die Qualität der Schulung eines ML-Modells auswirken können, empfehlen wir, dass fehlende Werte angegeben werden, falls möglich.

Wenn beim ML-Modelltraining das Zielattribut fehlt, lehnt Amazon ML den entsprechenden Datensatz ab. Wenn das Zielattribut im Datensatz vorhanden ist, aber ein Wert für ein anderes numerisches Attribut fehlt, übersieht Amazon ML den fehlenden Wert. In diesem Fall erstellt Amazon ML ein Ersatzattribut und setzt es auf 1, um anzuzeigen, dass dieses Attribut fehlt. Auf diese Weise kann Amazon ML Muster aus dem Auftreten fehlender Werte lernen.

Ungültige Werte

Ungültige Werte können nur bei numerischen und binären Datentypen auftreten. Sie können ungültige Werte suchen, indem Sie die zusammenfassenden Statistiken von Variablen in den

Datentypberichten anzeigen. In den folgenden Beispielen gibt es nur einen ungültigen Wert im numerischen Attribut "Duration" und zwei ungültige Werte im binären Datentyp (einer im Attribut "Housing" und einer im Attribut "Loan").

Numeric Variables

Variables ^	Correlations to Target ⇅	Missing Values ⇅	Invalid Values ⇅	Range ⇅	Mean ⇅	Median ⇅	Preview
duration	0.05165	2 (0%)	1 (0%)	0 - 4918	258.1618	180	

Binary Variables

Variables ^	Correlations to Target ⇅	Percent True ⇅	Invalid Values ⇅	Preview
campaign	NA	100%	27667 (61%)	
housing	0.01842	56%	1 (0%)	
loan	0.00656	16%	1 (0%)	
willRespondToCampaign	NA	12%	0 (0%)	

Korrelation zwischen Variable und Ziel

Nachdem Sie eine Datenquelle erstellt haben, kann Amazon ML die Datenquelle auswerten und die Korrelation oder Auswirkung zwischen Variablen und dem Ziel identifizieren. Beispielsweise ist es möglich, dass der Preis eines Produkts signifikante Auswirkungen darauf hat, ob es ein Bestseller wird, während die Abmessungen des Produkts wahrscheinlich wenig Vorhersagekraft haben.

Eine bewährte Methode ist es, so viele Variablen wie möglich in die Schulungsdaten einzuschließen. Das Datenrauschen durch viele Variablen mit wenig Vorhersagekraft kann jedoch die Qualität und die Richtigkeit Ihres ML-Modells negativ beeinflussen.

Sie können die prädiktive Leistung Ihres Modells verbessern, indem Sie Variablen mit wenig Auswirkungen während der Modellschulung entfernen. Sie können in einem Rezept definieren, welche Variablen dem maschinellen Lernprozess zur Verfügung gestellt werden. Dabei handelt es sich um einen Transformationsmechanismus von Amazon ML. Weitere Informationen zu Rezepten finden Sie unter [Data Transformation for Machine Learning](#).

Zusammenfassende Statistik der Attribute nach Datentyp

Im Bericht zu Dateneinblicken können Sie zusammenfassende Attributstatistiken nach den folgenden Datentypen anzeigen:

- Binär
- Kategorisch
- Numerischer Wert
- Text

Zusammenfassende Statistiken für binären Datentypen zeigen alle binären Attribute. Die Spalte **Correlations to target** zeigt die zwischen der Zielspalte und der Attributspalte gemeinsam genutzten Informationen. Die Spalte **Percent true** zeigt den Prozentsatz der Beobachtungen mit dem Wert "1" an. In der Spalte **Invalid values** wird die Anzahl der ungültigen Werte und der Prozentsatz der ungültigen Werte für jedes Attribut angezeigt. In der Spalte **Preview** finden Sie einen Link zu einer grafischen Verteilung für jedes Attribut.

Binary Variables

Variables	Correlations to Target	Percent True	Invalid Values	Preview
campaign	NA	100%	27667 (61%)	
housing	0.01842	56%	1 (0%)	
loan	0.00656	16%	1 (0%)	
willRespondToCampaign	NA	12%	0 (0%)	

Zusammenfassende Statistiken für den kategorischen Datentyp zeigen aller kategorischen Attribute mit der Anzahl eindeutiger Werte, häufigster Wert und seltenster Wert. In der Spalte **Preview** finden Sie einen Link zu einer grafischen Verteilung für jedes Attribut.

Categorical Variables

Variables	Correlations to Target	Unique Values	Most Frequent	Least Frequent	Preview
campaign	0.00433	49	1	39	
customerid	NA	45211	45211	1	
education	0.00355	5	secondary		
housing	0.01846	4	1		
jobid	0.00671	13	blue-collar		
willRespondToCampaign	NA	3	0		

Zusammenfassende Statistiken für den numerischen Datentyp zeigen alle numerischen Attributen mit der Anzahl fehlender Werte, ungültiger Werte, Wertebereich, durchschnittlicher und mittlerer Wert. In der Spalte Preview finden Sie einen Link zu einer grafischen Verteilung für jedes Attribut.

Numeric Variables

Variables	Correlations to Target	Missing Values	Invalid Values	Range	Mean	Median	Preview
duration	0.05165	2 (0%)	1 (0%)	0 - 4918	258.1618	180	

Zusammenfassende Statistiken für den Datentyp Text zeigen alle Textattribute, die Gesamtanzahl der Wörter in diesem Attribut, die Anzahl der eindeutigen Wörter in diesem Attribut, den Umfang von Wörtern in einem Attribut, den Umfang der Wortlängen und die bedeutendsten Wörter. In der Spalte Preview finden Sie einen Link zu einer grafischen Verteilung für jedes Attribut.

Text attributes

Attributes	Correlations to target *	Total words	Unique words	Words in attribute (range)	Word length (range)	Most prominent words
Phrase	0.07118	751741	12811	0 - 48	1 - 18	enters, trust ...

« < 1 - 1 of 1 Attributes > »

* Correlations to Target is an approximate statistic for text attributes.

Das folgende Beispiel zeigt Statistiken für den Datentyp Text für eine Textvariable mit dem Namen "Review", mit vier Datensätzen.

1. The fox jumped over the fence.
2. This movie is intriguing.
- 3.
4. Fascinating movie.

Die Spalten für dieses Beispiel würden die folgenden Informationen anzeigen.

- Die Spalte **Attributes** zeigt den Namen der Variablen an. In diesem Beispiel heißt die Spalte "Review".
- Die Spalte **Correlations to target** existiert nur, wenn ein Ziel angegeben ist. Korrelationen messen die Menge an Informationen, die dieses Attribut über das Ziel bietet. Je höher die Korrelation, desto mehr erfahren Sie aus diesem Attribut über das Ziel. Korrelation wird in Form von gegenseitigen Informationen zwischen einer vereinfachten Darstellung des Textattributs und des Ziels gemessen.
- Die Spalte **Total words** zeigt die Anzahl der Wörter, die durch Aufgliederung jeden Datensatzes in Token generiert werden, wobei Wörter durch Leerzeichen getrennt werden. In diesem Beispiel enthält die Spalte "12".
- Die Spalte **Unique words** zeigt die Anzahl der eindeutigen Wörter für ein Attribut an. In diesem Beispiel enthält die Spalte "10".
- Die Spalte **Words in attribute (range)** zeigt die Anzahl der Wörter in einer einzigen Zeile im Attribut an. In diesem Beispiel enthält die Spalte "0-6".
- Die Spalte **Word length (range)** zeigt den Umfang an, wie viele Zeichen in den Wörtern enthalten sind. In diesem Beispiel enthält die Spalte "2-11".
- Die Spalte **Most prominent words** zeigt eine Rangliste der Wörter, die im Attribut vorhanden sind. Wenn es ein Zielattribut gibt, werden Wörter anhand ihrer Korrelation zum Ziel sortiert. Das bedeutet, dass die Wörter mit der höchsten Korrelation zuerst aufgelistet werden. Wenn kein Ziel in den Daten vorhanden ist, werden die Wörter anhand ihres mittlerer Informationsgehalts in Rangfolge gebracht.


Erläuterungen zur Verteilung von kategorischen und binären Attributen

Durch Klicken auf den Link **Preview** für das kategorische oder binäre Attribut können Sie die Verteilung des Attributs sowie die Beispieldaten aus der Eingabedatei für jeden kategorischen Wert des Attributs anzeigen.

Die folgende Abbildung zeigt die Verteilung für das kategorische Attribut `jobId`. Die Verteilung zeigt die 10 häufigsten kategorischen Werte, alle anderen Werte sind als "other" gruppiert. Sie stuft jeden der 10 häufigsten kategorischen Werte nach der Anzahl der Beobachtungen in der Eingabedatei ein, die diesen Wert enthält, sowie einem Link zur Anzeige von Beispielbeobachtungen aus der Eingabedatendatei.

Categorical Variables: `jobId`

Top 10 `jobId`



All Categories

Ranking	Category	Count	
1	blue-collar	9732	Sample data
2	management	9458	Sample data
3	technician	7597	Sample data

Erläuterungen zur Verteilung von numerischen Attributen

Um die Verteilung eines numerischen Attributs anzuzeigen, klicken Sie auf den Link `Preview` für das Attribut. Wenn Sie die Verteilung eines numerischen Attributs erstellen, können Sie Bin-Größen von 500, 200, 100, 50 oder 20 festlegen. Die größer die Bin-Größe, um so kleiner die Anzahl der Balkendiagramme, die angezeigt werden. Darüber hinaus wird die Auflösung der Verteilung für


große Bin-Größen recht grob. Im Gegensatz dazu erhöht das Festlegen der Bucket-Größe auf 20 die Auflösung der angezeigten Verteilung.

Die minimalen, mittleren und maximalen Werte werden ebenfalls angezeigt (siehe Abbildung).

Numeric Variables: duration

Select Bin Width:

500 200 100 50 20



Min: 0 Mean: 258.1618 Max: 4918

Erläuterungen zur Verteilung von Textattributen

Um die Verteilung eines Textattributs anzuzeigen, klicken Sie auf den Link Preview für das Attribut. Bei der Anzeige der Verteilung eines Textattributs sehen Sie die folgenden Informationen.

Text attributes: Phrase

Ranking	Token	Word prominence	Count	
1	enters	0.01105	7	0.0%
2	trust	0.00884	28	0.0%
3	bad	0.00735	833	0.2%
4	film	0.00669	4747	1.3%
5	movie	0.00611	4242	1.2%
6	unwieldy	0.00605	11	0.0%
7	good	0.00574	1620	0.5%
8	ashamed	0.00551	7	0.0%
9	funny	0.00550	1078	0.3%
10	wankery	0.00498	9	0.0%

« < 1 - 10 of 11091 > »

Ranking

Texttoken werden anhand der Menge der übermittelten Informationen angeordnet, von am meisten informativen bis zu am wenigsten informativ.

Token

Das Token zeigt das Wort aus dem Eingabetext, auf das sich die Statistikzeile bezieht.

Wortbedeutung

Wenn es ein Zielattribut gibt, werden Wörter anhand ihrer Korrelation zum Ziel sortiert. Das bedeutet, dass die Wörter mit der höchsten Korrelation zuerst aufgelistet werden. Wenn kein Ziel

in den Daten vorhanden ist, werden die Wörter anhand ihrer Entropie in Rangfolge gebracht, d. h. die Menge an Informationen, die sie kommunizieren können.

Anzahl

Die Anzahl zeigt die Anzahl der Eingabedatensätze, in denen das Token vorhanden ist.

Prozentsatz

Der Prozentsatz zeigt den prozentualen Anteil der Eingabedatenzeilen, in denen das Token vorhanden ist.

Amazon S3 mit Amazon ML verwenden

Amazon Simple Storage Service (Amazon S3) ist ein Speicher für das Internet. Mit Amazon S3 können Sie jederzeit beliebige Mengen von Daten von überall aus im Internet speichern und aufrufen. Amazon ML verwendet Amazon S3 als primäres Datenrepository für die folgenden Aufgaben:

- Für den Zugriff auf Ihre Eingabedateien zum Erstellen von Datenquellenobjekten für die Schulung und die Auswertung Ihrer ML-Modelle.
- Für den Zugriff auf Ihre Eingabedateien zum Generieren von Stapelvoraussagen.
- Wenn Sie Stapelvoraussagen mithilfe Ihrer ML-Modelle generieren zum Ausgeben der Voraussagedatei an einen S3-Bucket, den Sie angeben.
- Um Daten, die Sie in Amazon Redshift oder Amazon Relational Database Service (Amazon RDS) gespeichert haben, in eine CSV-Datei zu kopieren und auf Amazon S3 hochzuladen.

Damit Amazon ML diese Aufgaben ausführen kann, müssen Sie Amazon ML Berechtigungen für den Zugriff auf Ihre Amazon S3 S3-Daten erteilen.

Note

Sie können keine Stapelvoraussagedateien in einen S3-Bucket ausgeben, der nur serverseitige verschlüsselte Dateien akzeptiert. Stellen Sie sicher, dass Ihre Bucket-Richtlinie das Hochladen unverschlüsselter Dateien zulässt, in dem Sie bestätigen, dass die Richtlinie keinen Deny-Effekt für die `s3:PutObject`-Aktion umfasst, wenn kein `s3:x-amz-server-side-encryption`-Header in der Anforderung vorhanden ist. Weitere Informationen zu Bucket-Richtlinien für serverseitige S3-Verschlüsselung finden Sie unter [Schützen](#)

[von Daten mithilfe serverseitiger Verschlüsselung im Amazon Simple Storage Service-Benutzerhandbuch.](#)

Ihre Daten auf Amazon S3 hochladen

Sie müssen Ihre Eingabedaten auf Amazon Simple Storage Service (Amazon S3) hochladen, da Amazon ML Daten von Amazon S3-Standorten liest. Sie können Ihre Daten direkt auf Amazon S3 hochladen (z. B. von Ihrem Computer), oder Amazon ML kann Daten, die Sie in Amazon Redshift oder Amazon Relational Database Service (RDS) gespeichert haben, in eine CSV-Datei kopieren und auf Amazon S3 hochladen.

Weitere Informationen über das Kopieren Ihrer Daten von Amazon Redshift oder Amazon RDS finden Sie unter [Using Amazon Redshift with Amazon ML](#) bzw. [Using Amazon RDS with Amazon ML](#).

Im Rest dieses Abschnitts wird beschrieben, wie Sie Ihre Eingabedaten direkt von Ihrem Computer auf Amazon S3 hochladen. Bevor Sie die Verfahren in diesem Abschnitt beginnen, müssen sich Ihre Daten in einer CSV-Datei befinden. Informationen dazu, wie Sie Ihre CSV-Datei korrekt formatieren, sodass Amazon ML sie verwenden kann, finden Sie unter [Grundlegendes zum Datenformat für Amazon ML](#).

Um Ihre Daten von Ihrem Computer auf Amazon S3 hochzuladen

1. Melden Sie sich bei der AWS-Managementkonsole an und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3>.
2. Erstellen Sie einen Bucket, oder wählen Sie einen vorhandenen Bucket aus.
 - a. Wählen Sie die Option Create Bucket aus, um einen Bucket zu erstellen. Benennen Sie Ihren Bucket, wählen Sie eine Region aus (Sie können eine beliebige verfügbare Region auswählen), und wählen Sie dann Create aus. Weitere Informationen dazu erhalten Sie unter [Create a Bucket](#) im Amazon-Handbuch Erste Schritte.
 - b. Um einen vorhandenen Bucket zu verwenden, suchen Sie nach dem Bucket, indem Sie den Bucket in der Liste All Buckets (Alle Buckets) auswählen. Wenn der Bucket-Name angezeigt wird, wählen Sie ihn aus, und klicken Sie dann auf Upload.
3. Klicken Sie im Dialogfeld Upload auf Add Files.
4. Navigieren Sie zu dem Ordner, der die CSV-Eingabedatei enthält, und wählen Sie dann Öffnen aus.

Berechtigungen

Um Amazon ML Zugriff auf einen Ihrer S3-Buckets zu gewähren, müssen Sie die Bucket-Richtlinie bearbeiten.

Informationen dazu, wie Sie Amazon ML-Berechtigungen zum Lesen von Daten aus Ihrem Bucket in Amazon S3 [gewähren, finden Sie unter Amazon ML-Berechtigungen zum Lesen Ihrer Daten aus Amazon S3](#) gewähren.

Informationen darüber, wie Sie Amazon ML-Berechtigungen zur Ausgabe der Batch-Prognoseergebnisse in Ihrem Bucket in Amazon S3 [gewähren, finden Sie unter Amazon ML-Berechtigungen zur Ausgabe von Prognosen für Amazon S3](#) gewähren.

Informationen zur Verwaltung von Zugriffsberechtigungen für Amazon S3-Ressourcen finden Sie im [Amazon S3 Developer Guide](#).

Erstellen einer Amazon ML-Datenquelle aus Daten in Amazon Redshift

Wenn Sie Daten in Amazon Redshift gespeichert haben, können Sie den Assistenten zum Erstellen von Datenquellen in der Amazon Machine Learning (Amazon ML) -Konsole verwenden, um ein Datenquellenobjekt zu erstellen. Wenn Sie eine Datenquelle aus Amazon Redshift Redshift-Daten erstellen, geben Sie den Cluster an, der Ihre Daten und die SQL-Abfrage zum Abrufen Ihrer Daten enthält. Amazon ML führt die Abfrage aus, indem es den Amazon Redshift UnLoad Redshift-Befehl auf dem Cluster aufruft. Amazon ML speichert die Ergebnisse am Amazon Simple Storage Service (Amazon S3) -Speicherort Ihrer Wahl und verwendet dann die in Amazon S3 gespeicherten Daten, um die Datenquelle zu erstellen. Die Datenquelle, der Amazon Redshift Redshift-Cluster und der S3-Bucket müssen sich alle in derselben Region befinden.

Note

Amazon ML unterstützt keine private Erstellung von Datenquellen aus Amazon Redshift Redshift-Clustern. VPCs Der Cluster muss über eine öffentliche IP-Adresse verfügen.

Themen

- [Erforderliche Parameter für den Assistenten Datenquelle erstellen](#)
- [Erstellen einer Datenquelle mit Amazon Redshift Redshift-Daten \(Konsole\)](#)

- [Behebung von Problemen mit Amazon Redshift](#)

Erforderliche Parameter für den Assistenten Datenquelle erstellen

Damit Amazon ML eine Verbindung zu Ihrer Amazon Redshift Redshift-Datenbank herstellen und Daten in Ihrem Namen lesen kann, müssen Sie Folgendes angeben:

- Das Amazon Redshift `ClusterIdentifier`
- Der Name der Amazon Redshift Redshift-Datenbank
- Die Anmeldedaten der Amazon Redshift Redshift-Datenbank (Benutzername und Passwort)
- Die Amazon ML Amazon Redshift AWS Identity and Access Management (IAM) -Rolle
- Die Amazon Redshift SQL-Abfrage
- (Optional) Der Speicherort des Amazon ML-Schemas
- Der Amazon S3 S3-Staging-Speicherort (wo Amazon ML die Daten ablegt, bevor es die Datenquelle erstellt)

Darüber hinaus müssen Sie sicherstellen, dass die IAM-Benutzer oder -Rollen, die Amazon Redshift Redshift-Datenquellen erstellen (sei es über die Konsole oder mithilfe der `CreateDataSourceFromRedshift` Aktion), über die entsprechende Berechtigung verfügen. `iam:PassRole`

Amazon Redshift `ClusterIdentifier`

Verwenden Sie diesen Parameter, bei dem Groß- und Kleinschreibung beachtet wird, damit Amazon ML Ihren Cluster finden und eine Verbindung zu ihm herstellen kann. Sie können die Cluster-ID (Name) von der Amazon Redshift Redshift-Konsole abrufen. Weitere Informationen zu Clustern finden Sie unter [Amazon Redshift Clusters](#).

Name der Amazon Redshift Redshift-Datenbank

Verwenden Sie diesen Parameter, um Amazon ML mitzuteilen, welche Datenbank im Amazon Redshift Redshift-Cluster die Daten enthält, die Sie als Datenquelle verwenden möchten.

Anmeldeinformationen für die Amazon Redshift Redshift-Datenbank

Verwenden Sie diese Parameter, um den Benutzernamen und das Passwort des Amazon Redshift Redshift-Datenbankbenutzers anzugeben, in dessen Kontext die Sicherheitsabfrage ausgeführt wird.

Note

Amazon ML benötigt einen Amazon Redshift Redshift-Benutzernamen und ein Passwort, um eine Verbindung zu Ihrer Amazon Redshift Redshift-Datenbank herzustellen. Nach dem Entladen der Daten auf Amazon S3 verwendet Amazon ML Ihr Passwort nie wieder und speichert es auch nicht.

Amazon ML — Amazon Redshift Redshift-Rolle

Verwenden Sie diesen Parameter, um den Namen der IAM-Rolle anzugeben, die Amazon ML verwenden soll, um die Sicherheitsgruppen für den Amazon Redshift Redshift-Cluster und die Bucket-Richtlinie für den Amazon S3 S3-Staging-Speicherort zu konfigurieren.

Wenn Sie keine IAM-Rolle haben, die auf Amazon Redshift zugreifen kann, kann Amazon ML eine Rolle für Sie erstellen. Wenn Amazon ML eine Rolle erstellt, erstellt es eine vom Kunden verwaltete Richtlinie und fügt sie einer IAM-Rolle hinzu. Die von Amazon ML erstellte Richtlinie gewährt Amazon ML die Erlaubnis, nur auf den von Ihnen angegebenen Cluster zuzugreifen.

Wenn Sie bereits über eine IAM-Rolle für den Zugriff auf Amazon Redshift verfügen, können Sie den ARN der Rolle eingeben oder die Rolle aus der Drop-down-Liste auswählen. IAM-Rollen mit Amazon Redshift Redshift-Zugriff sind oben in der Drop-down-Liste aufgeführt.

Die IAM-Rolle muss den folgenden Inhalt haben:

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": "sts:AssumeRole",
      "Condition": {
        "StringEquals": { "aws:SourceAccount": "123456789012" },
        "ArnLike": { "aws:SourceArn": "arn:aws:machinelearning:us-east-1:123456789012:datasource/*" }
      }
    }
  ]
}
```

```
}]  
}
```

Weitere Informationen zu vom Kunden verwalteten Richtlinien finden Sie unter [Vom Kunden verwaltete Richtlinien](#) im IAM-Benutzerhandbuch.

Amazon Redshift SQL-Abfrage

Verwenden Sie diesen Parameter, um die SQL SELECT-Abfrage anzugeben, die Amazon ML in Ihrer Amazon Redshift Redshift-Datenbank ausführt, um Ihre Daten auszuwählen. Amazon ML verwendet die Amazon Redshift [UNLOAD-Aktion](#), um die Ergebnisse Ihrer Abfrage sicher an einen Amazon S3 S3-Speicherort zu kopieren.

Note

Amazon ML funktioniert am besten, wenn die Eingabedatensätze in zufälliger Reihenfolge (gemischt) sind. Sie können die Ergebnisse Ihrer Amazon Redshift SQL-Abfrage ganz einfach mischen, indem Sie die Amazon Redshift `random()`-Funktion verwenden.

Beispiel: Angenommen, dies ist die ursprüngliche Abfrage:

```
"SELECT col1, col2, ... FROM training_table"
```

Sie können durch Aktualisierung der Abfrage zufällig mischen:

```
"SELECT col1, col2, ... FROM training_table ORDER BY random()"
```

Schemaspeicherort (Optional)

Verwenden Sie diesen Parameter, um den Amazon S3 S3-Pfad zu Ihrem Schema für die Amazon Redshift Redshift-Daten anzugeben, die Amazon ML exportiert.

Wenn Sie kein Schema für Ihre Datenquelle angeben, erstellt die Amazon ML-Konsole automatisch ein Amazon ML-Schema, das auf dem Datenschema der Amazon Redshift SQL-Abfrage basiert. Amazon ML-Schemas haben weniger Datentypen als Amazon Redshift Redshift-Schemas, es handelt sich also nicht um eine Konvertierung. one-to-one Die Amazon ML-Konsole konvertiert Amazon Redshift Redshift-Datentypen mithilfe des folgenden Konvertierungsschemas in Amazon ML-Datentypen.

Amazon Redshift-Datentypen	Amazon Redshift Redshift-Aliase	Amazon ML-Datentyp
SMALLINT	INT2	NUMERIC
INTEGER	GANZZAHL, INT4	NUMERIC
BIGINT	INT8	NUMERIC
DECIMAL	NUMERIC	NUMERIC
REAL	FLOAT4	NUMERIC
DOUBLE PRECISION	FLOAT8, SCHWEBEN	NUMERIC
BOOLEAN	BOOL	BINARY
CHAR	CHARACTER, NCHAR, BPCHAR	CATEGORICAL
VARCHAR	CHARACTER VARYING, NVARCHAR, TEXT	TEXT
DATE		TEXT
TIMESTAMP (ZEITSTEMPEL)	TIMESTAMP WITHOUT TIME ZONE	TEXT

Um in Amazon Binary ML-Datentypen konvertiert zu werden, müssen die Werte der Amazon Redshift Booleans in Ihren Daten Amazon ML-Binärwerte unterstützen. Wenn Ihr boolescher Datentyp Werte enthält, die nicht unterstützt werden, konvertiert Amazon ML diese in den spezifischsten Datentyp, den es gibt. Wenn ein Amazon Redshift Boolean beispielsweise die Werte 0, und 2 hat 1, konvertiert Amazon ML den Booleschen Wert in einen Datentyp. Numeric Weitere Informationen zu unterstützten binären Werten finden Sie unter [Verwenden des Felds AttributeType](#).

Wenn Amazon ML einen Datentyp nicht ermitteln kann, wird standardmäßig der Datentyp verwendet. Text

Nachdem Amazon ML das Schema konvertiert hat, können Sie die zugewiesenen Amazon ML-Datentypen im Assistenten „Datenquelle erstellen“ überprüfen und korrigieren und das Schema überarbeiten, bevor Amazon ML die Datenquelle erstellt.

Amazon S3 S3-Staging-Standort

Verwenden Sie diesen Parameter, um den Namen des Amazon S3 S3-Staging-Speicherorts anzugeben, an dem Amazon ML die Ergebnisse der Amazon Redshift SQL-Abfrage speichert. Nach der Erstellung der Datenquelle verwendet Amazon ML die Daten im Staging-Speicherort, anstatt zu Amazon Redshift zurückzukehren.

Note

Da Amazon ML die durch die Amazon ML-Amazon-Redshift-Rolle definierte IAM-Rolle annimmt, verfügt Amazon ML über Berechtigungen für den Zugriff auf alle Objekte im angegebenen Amazon S3 S3-Staging-Speicherort. Aus diesem Grund empfehlen wir, nur Dateien, die keine vertraulichen Informationen enthalten, im Amazon S3 S3-Staging-Speicherort zu speichern. Wenn Ihr Root-Bucket beispielsweise `s3://mybucket/` ist, empfehlen wir Ihnen, einen Speicherort zu erstellen, in dem nur die Dateien gespeichert werden, auf die Amazon ML zugreifen soll, wie `s3://mybucket/AmazonMLInput/` z.

Erstellen einer Datenquelle mit Amazon Redshift Redshift-Daten (Konsole)

Die Amazon ML-Konsole bietet zwei Möglichkeiten, eine Datenquelle mit Amazon Redshift Redshift-Daten zu erstellen. Sie können eine Datenquelle erstellen, indem Sie den Assistenten zum Erstellen von Datenquellen ausführen, oder, falls Sie bereits eine aus Amazon Redshift Redshift-Daten erstellte Datenquelle haben, können Sie die ursprüngliche Datenquelle kopieren und ihre Einstellungen ändern. Das Kopieren einer Datenquelle ermöglicht Ihnen die einfache Erstellung mehrerer ähnlicher Datenquellen.

Informationen zum Erstellen einer Datenquelle mithilfe der API finden Sie unter

[CreateDataSourceFromRedshift](#)

Weitere Information zu den Parametern der folgenden Verfahren finden Sie unter [Erforderliche Parameter für den Assistenten Datenquelle erstellen](#).

Themen

- [Erstellen einer Datenquelle \(Konsole\)](#)

- [Kopieren einer Datenquelle \(Konsole\)](#)

Erstellen einer Datenquelle (Konsole)

Verwenden Sie den Assistenten „Datenquelle erstellen“, um Daten aus Amazon Redshift in eine Amazon ML-Datenquelle zu entladen.

So erstellen Sie eine Datenquelle aus Daten in Amazon Redshift

1. Öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Amazon ML-Dashboard unter Entitäten die Option Create new... , und wählen Sie dann Datasource.
3. Wählen Sie auf der Seite Eingabedaten Amazon Redshift aus.
4. Geben Sie im Assistenten „Datenquelle erstellen“ unter Cluster-ID den Namen des Clusters ein.
5. Geben Sie unter Datenbankname den Namen der Amazon Redshift Redshift-Datenbank ein.
6. Geben Sie im Feld Datenbank-Benutzername den Benutzernamen für die Datenbank ein.
7. Geben Sie im Feld Datenbankpasswort das Passwort für die Datenbank ein.
8. Wählen Sie unter IAM-Rolle Ihre IAM-Rolle. Wenn Sie noch keine haben, wählen Sie Neue Rolle erstellen aus. Amazon ML erstellt eine IAM-Amazon Redshift-Rolle für Sie.
9. Um Ihre Amazon Redshift Redshift-Einstellungen zu testen, wählen Sie Test Access (neben IAM-Rolle). Wenn Amazon ML mit den bereitgestellten Einstellungen keine Verbindung zu Amazon Redshift herstellen kann, können Sie nicht mit der Erstellung einer Datenquelle fortfahren. Hilfe zur Problembeseitigung finden Sie unter [Fehlersuche](#).
10. Geben Sie unter SQL-Abfrage die SQL-Abfrage ein.
11. Wählen Sie unter Schemaposition aus, ob Amazon ML ein Schema für Sie erstellen soll. Wenn Sie selbst ein Schema erstellt haben, geben Sie den Amazon S3 S3-Pfad zu Ihrer Schemadatei ein.
12. Geben Sie für den Amazon S3 S3-Staging-Speicherort den Amazon S3 S3-Pfad zu dem Bucket ein, in den Amazon ML die aus Amazon Redshift entladenen Daten ablegen soll.
13. (Optional) Geben Sie unter Datenquellename einen Namen für die Datenquelle ein.
14. Wählen Sie Überprüfen. Amazon ML überprüft, ob es eine Verbindung zu Ihrer Amazon Redshift Redshift-Datenbank herstellen kann.

15. Überprüfen Sie auf der Seite Schema die Datentypen für alle Attribute und korrigieren Sie sie falls erforderlich.
16. Klicken Sie auf Weiter.
17. Wenn Sie diese Datenquelle verwenden möchten, um ein ML-Modell zu erstellen oder auszuwerten, wählen Sie für Beabsichtigen Sie, dieses Datenset für die Erstellung oder Auswertung eines ML-Modells zu verwenden? die Antwort Ja. Wenn Sie Ja gewählt haben, wählen Sie die Zeile für die Ziele. Weitere Informationen über Ziele finden Sie unter [Das targetAttributeName Feld verwenden](#).

Wenn Sie diese Datenquelle mit einem Modell verwenden möchten, das Sie bereits erstellt haben, um Voraussagen zu erstellen, wählen Sie Nein.

18. Klicken Sie auf Weiter.
19. Wählen Sie für Enthalten Ihre Daten eine ID? die Antwort Nein, wenn Ihre Daten keine Zeilen-ID enthalten.

Wenn Ihre Daten eine Zeilen-ID enthalten, wählen Sie Ja. Weitere Information zu Zeilen-IDs finden Sie unter [Verwenden des Felds rowID](#).

20. Wählen Sie Überprüfen aus.
21. Prüfen Sie auf der Seite Prüfen Ihre Einstellungen und wählen Sie Fertig.

Nachdem Sie eine Datenquelle erstellt haben, können Sie diese folgendermaßen verwenden: [create an ML model](#). Wenn Sie bereits ein Modell erstellt haben, können Sie mit der Datenquelle [evaluate an ML model](#) oder [generate predictions](#).

Kopieren einer Datenquelle (Konsole)

Wenn Sie eine Datenquelle erstellen möchten, die einer vorhandenen Datenquelle ähnelt, können Sie die Amazon ML-Konsole verwenden, um die ursprüngliche Datenquelle zu kopieren und ihre Einstellungen zu ändern. Sie können sich beispielsweise dafür entscheiden, mit einer vorhandenen Datenquelle zu beginnen und dann das Datenschema so zu ändern, dass es Ihren Daten besser entspricht, die SQL-Abfrage ändern, die zum Entladen von Daten aus Amazon Redshift verwendet wird, oder einen anderen AWS Identity and Access Management (IAM) -Benutzer für den Zugriff auf den Amazon Redshift Redshift-Cluster angeben.

So kopieren und ändern Sie eine Amazon Redshift Redshift-Datenquelle

1. Öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Amazon ML-Dashboard unter Entitäten die Option Create new... , und wählen Sie dann Datasource.
3. Auf der Seite Eingabedaten für Wo sind Ihre Daten? , wählen Sie Amazon Redshift. Wenn Sie bereits eine Datenquelle haben, die aus Amazon Redshift Redshift-Daten erstellt wurde, haben Sie die Möglichkeit, Einstellungen aus einer anderen Datenquelle zu kopieren.

Where is your data?



S3



Amazon Redshift

Do you want to copy the settings from another Amazon Redshift datasource to create a new datasource? To copy settings, choose [Find a datasource](#).

Wenn Sie noch keine Datenquelle haben, die aus Amazon Redshift Redshift-Daten erstellt wurde, wird diese Option nicht angezeigt.

4. Wählen Sie Eine Datenquelle suchen.
5. Wählen Sie die Datenquelle aus, die Sie kopieren möchten, und wählen Sie Einstellungen kopieren. Amazon ML füllt die meisten Datenquelleneinstellungen automatisch mit Einstellungen aus der ursprünglichen Datenquelle aus. Das Passwort für die Datenbank, der Speicherort des Schemas und der Name der Datenquelle werden nicht von der ursprünglichen Datenquelle kopiert.
6. Ändern Sie die automatisch vorgenommenen Einstellungen nach Bedarf. Wenn Sie beispielsweise die Daten ändern möchten, die Amazon ML aus Amazon Redshift entlädt, ändern Sie die SQL-Abfrage.
7. Geben Sie im Feld Datenbankpasswort das Passwort für die Datenbank ein. Amazon ML speichert Ihr Passwort nicht und verwendet es auch nicht wieder, daher müssen Sie es immer angeben.
8. (Optional) Für den Speicherort des Schemas wählt Amazon ML vorab Ich möchte, dass Amazon ML ein empfohlenes Schema für Sie generiert. Wenn Sie bereits ein Schema erstellt haben, wählen Sie Ich möchte das Schema verwenden, das ich in Amazon S3 erstellt und gespeichert habe, und geben Sie den Pfad zu Ihrer Schemadatei in Amazon S3 ein.

9. (Optional) Geben Sie unter Datenquellename einen Namen für die Datenquelle ein. Andernfalls generiert Amazon ML einen neuen Datenquellennamen für Sie.
10. Wählen Sie Überprüfen. Amazon ML überprüft, ob es eine Verbindung zu Ihrer Amazon Redshift Redshift-Datenbank herstellen kann.
11. (Optional) Wenn Amazon ML das Schema für Sie abgeleitet hat, überprüfen Sie auf der Seite Schema die Datentypen für alle Attribute und korrigieren Sie sie gegebenenfalls.
12. Klicken Sie auf Weiter.
13. Wenn Sie diese Datenquelle verwenden möchten, um ein ML-Modell zu erstellen oder auszuwerten, wählen Sie für Beabsichtigen Sie, dieses Datenset für die Erstellung oder Auswertung eines ML-Modells zu verwenden? die Antwort Ja. Wenn Sie Ja gewählt haben, wählen Sie die Zeile für die Ziele. Weitere Informationen über Ziele finden Sie unter [Das targetAttributeName Feld verwenden](#).

Wenn Sie diese Datenquelle mit einem Modell verwenden möchten, das Sie bereits erstellt haben, um Voraussagen zu erstellen, wählen Sie Nein.

14. Klicken Sie auf Weiter.
15. Wählen Sie für Enthalten Ihre Daten eine ID? die Antwort Nein, wenn Ihre Daten keine Zeilen-ID enthalten.

Wenn Ihre Daten eine Zeilen-ID enthalten, wählen Sie Ja und wählen Sie die Zeile aus, die Sie als ID verwenden möchten. Weitere Information zu Zeilen-IDs finden Sie unter [Verwenden des Felds rowID](#).

16. Wählen Sie Überprüfen aus.
17. Überprüfen Sie die Einstellungen und klicken Sie anschließend auf Fertig.

Nachdem Sie eine Datenquelle erstellt haben, können Sie diese folgendermaßen verwenden: [create an ML model](#). Wenn Sie bereits ein Modell erstellt haben, können Sie mit der Datenquelle [evaluate an ML model](#) oder [generate predictions](#).

Behebung von Problemen mit Amazon Redshift

Während Sie Ihre Amazon Redshift Redshift-Datenquelle, ML-Modelle und Evaluierung erstellen, meldet Amazon Machine Learning (Amazon ML) den Status Ihrer Amazon ML-Objekte in der Amazon ML-Konsole. Wenn Amazon ML Fehlermeldungen zurückgibt, verwenden Sie die folgenden Informationen und Ressourcen, um die Probleme zu beheben.

Antworten auf allgemeine Fragen zu Amazon ML finden Sie unter [Amazon Machine Learning FAQs](#). Sie können auch im [Amazon Machine Learning Learning-Forum](#) nach Antworten suchen und Fragen stellen.

Themen

- [Fehlersuche](#)
- [Den AWS-Support kontaktieren](#)

Fehlersuche

Das Format der Rolle ist ungültig. Geben Sie eine gültige IAM-Rolle an. Zum Beispiel `arn:aws:iam::YourAccount:YourRedshiftRole`

Ursache

Das Format des Amazon Resource Name (ARN) der IAM-Rolle ist nicht korrekt.

Lösung

Korrigieren Sie im Assistenten zum Erstellen von Datenquellen den ARN für Ihre Rolle. [Informationen zur Formatierung von Rollen ARNs finden Sie unter IAM im IAM-Benutzerhandbuch. ARNs](#) Die Region ist für die IAM-Rolle optional. ARNs

Die Rolle ist ungültig. Amazon ML kann die `<role ARN>` IAM-Rolle nicht übernehmen. Geben Sie eine gültige IAM-Rolle an und machen Sie sie für Amazon ML zugänglich.

Ursache

Ihre Rolle ist nicht so eingerichtet, dass Amazon ML sie übernehmen kann.

Lösung

Bearbeiten Sie in der [IAM-Konsole](#) Ihre Rolle so, dass sie über eine Vertrauensrichtlinie verfügt, die es Amazon ML ermöglicht, die ihr zugewiesene Rolle zu übernehmen.

Der Benutzer `<Benutzer-ARN>` ist nicht berechtigt, die IAM-Rolle `<Rollen-ARN>` weiterzugeben.

Ursache

Ihr IAM-Benutzer hat keine Berechtigungsrichtlinie, die es ihm ermöglicht, eine Rolle an Amazon ML zu übergeben.

Lösung

Fügen Sie Ihrem IAM-Benutzer eine Berechtigungsrichtlinie hinzu, die es Ihnen ermöglicht, Rollen an Amazon ML zu übergeben. Sie können Ihrem IAM-Benutzer in der [IAM-Konsole](#) eine Berechtigungsrichtlinie zuordnen.

Das Übergeben einer IAM-Rolle über Konten ist nicht zulässig. Die IAM-Rolle muss zu diesem Konto gehören.

Ursache

Sie können keine Rolle übergeben, die zu einem anderen IAM-Konto gehört.

Lösung

Melden Sie sich bei dem AWS-Konto, das Sie verwendet haben, um die Rolle zu erstellen. Ihre IAM-Rollen finden Sie in Ihrer [IAM-Konsole](#).

Die angegebene Rolle ist nicht berechtigt, die Operation durchzuführen. Geben Sie eine Rolle mit einer Richtlinie an, die Amazon ML die erforderlichen Berechtigungen gewährt.

Ursache

Ihre IAM-Rolle ist nicht berechtigt, die gewünschte Operation durchzuführen.

Lösung

Ändern Sie die Ihrer Rolle zugewiesene Berechtigungsrichtlinie in der [IAM-Konsole](#) dahingehend ab, dass die erforderlichen Berechtigungen zur Verfügung stehen.

Amazon ML kann keine Sicherheitsgruppe auf diesem Amazon Redshift Redshift-Cluster mit der angegebenen IAM-Rolle konfigurieren.

Ursache

Ihre IAM-Rolle verfügt nicht über die erforderlichen Berechtigungen, um einen Amazon Redshift Redshift-Sicherheitscluster zu konfigurieren.

Lösung

Ändern Sie die Ihrer Rolle zugewiesene Berechtigungsrichtlinie in der [IAM-Konsole](#) dahingehend ab, dass die erforderlichen Berechtigungen zur Verfügung stehen.

Beim Versuch von Amazon ML, eine Sicherheitsgruppe auf Ihrem Cluster zu konfigurieren, ist ein Fehler aufgetreten. Bitte versuchen Sie es später erneut.

Ursache

Als Amazon ML versuchte, eine Verbindung zu Ihrem Amazon Redshift Redshift-Cluster herzustellen, ist ein Problem aufgetreten.

Lösung

Überprüfen Sie, ob die IAM-Rolle, die Sie im Assistenten Datenquelle erstellen angegeben haben, über alle erforderlichen Berechtigungen verfügt.

Das Format der Cluster-ID ist ungültig. IDs Der Cluster muss mit einem Buchstaben beginnen und darf nur alphanumerische Zeichen und Bindestriche enthalten. Sie dürfen nicht zwei aufeinanderfolgende Bindestriche enthalten oder mit einem Bindestrich enden.

Ursache

Ihr Amazon Redshift Redshift-Cluster-ID-Format ist falsch.

Lösung

Korrigieren Sie im Assistenten Datenquelle erstellen Ihre Cluster-ID, sodass nur alphanumerische Zeichen und Bindestriche und keine zwei aufeinander folgenden Bindestriche enthalten sind und die Cluster-ID nicht mit einem Bindestrich endet.

Es gibt keinen <Amazon Redshift cluster name>Cluster, oder der Cluster befindet sich nicht in derselben Region wie Ihr Amazon ML-Service. Geben Sie einen Cluster in derselben Region wie dieses Amazon ML an.

Ursache

Amazon ML kann Ihren Amazon Redshift Redshift-Cluster nicht finden, da er sich nicht in der Region befindet, in der Sie eine Amazon ML-Datenquelle erstellen.

Lösung

[Vergewissern Sie sich, dass Ihr Cluster auf der Clusterseite der Amazon Redshift Redshift-Konsole vorhanden ist, dass Sie eine Datenquelle in derselben Region erstellen, in der sich Ihr Amazon](#)

Redshift Redshift-Cluster befindet, und dass die im Assistenten zum Erstellen von Datenquellen angegebene Cluster-ID korrekt ist.

Amazon ML kann die Daten in Ihrem Amazon Redshift Redshift-Cluster nicht lesen. Geben Sie die richtige Amazon Redshift Redshift-Cluster-ID ein.

Ursache

Amazon ML kann die Daten im Amazon Redshift Redshift-Cluster, den Sie angegeben haben, nicht lesen.

Lösung

Geben Sie im Assistenten „Datenquelle erstellen“ die richtige Amazon Redshift Redshift-Cluster-ID an, stellen Sie sicher, dass Sie eine Datenquelle in derselben Region erstellen, in der sich Ihr Amazon Redshift Redshift-Cluster befindet, und dass Ihr Cluster auf der Seite Amazon Redshift Redshift-Cluster aufgeführt ist.

Der <Amazon Redshift cluster name>Cluster ist nicht öffentlich zugänglich.

Ursache

Amazon ML kann nicht auf Ihren Cluster zugreifen, da der Cluster nicht öffentlich zugänglich ist und keine öffentliche IP-Adresse hat.

Lösung

Machen Sie den Cluster öffentlich zugänglich und geben Sie eine öffentliche IP-Adresse ein. Informationen darüber, wie Sie Cluster öffentlich zugänglich machen, finden Sie unter [Modifizieren eines Clusters](#) im Amazon Redshift Management Guide.

Der <Redshift>Cluster-Status ist für Amazon ML nicht verfügbar. Verwenden Sie die Amazon Redshift Redshift-Konsole, um dieses Clusterstatusproblem anzuzeigen und zu lösen. Der Cluster-Status muss "available" lauten.

Ursache

Amazon ML kann den Cluster-Status nicht sehen.

Lösung

Stellen Sie sicher, dass Ihr Cluster verfügbar ist. Informationen zur Überprüfung des Status Ihres Clusters finden Sie unter [Getting an Overview of Cluster Status](#) im Amazon Redshift Management

Guide. Informationen zum Neustarten des Clusters, sodass er verfügbar ist, finden Sie unter [Einen Cluster neu starten](#) im Amazon Redshift Management Guide.

In diesem Cluster ist keine Datenbank <Datenbankname> vorhanden. Überprüfen Sie, ob der Datenbanknamen korrekt ist oder geben Sie einen anderen Cluster bzw. eine andere Datenbank an.

Ursache

Amazon ML kann die angegebene Datenbank im angegebenen Cluster nicht finden.

Lösung

Überprüfen Sie, ob der im Assistenten Datenbank erstellen angegebene Datenbankname korrekt ist, oder geben Sie den richtigen Cluster- und Datenbanknamen an.

Amazon ML konnte nicht auf Ihre Datenbank zugreifen. Geben Sie eine gültiges Passwort für den Datenbankbenutzer <Benutzername> ein.

Ursache

Das Passwort, das Sie im Assistenten zum Erstellen einer Datenquelle angegeben haben, um Amazon ML den Zugriff auf Ihre Amazon Redshift Redshift-Datenbank zu ermöglichen, ist falsch.

Lösung

Geben Sie das richtige Passwort für Ihren Amazon Redshift Redshift-Datenbankbenutzer ein.

Beim Versuch von Amazon ML, die Abfrage zu validieren, ist ein Fehler aufgetreten.

Ursache

Es besteht ein Problem mit Ihrer SQL-Abfrage.

Lösung

Überprüfen Sie, ob Ihre SQL-Abfrage gültig ist.

Beim Ausführen der SQL-Abfrage ist ein Fehler aufgetreten. Überprüfen Sie den Datenbanknamen und die angegebene Abfrage. Fehlerursache: {serverMessage}.

Ursache

Amazon Redshift konnte Ihre Abfrage nicht ausführen.

Lösung

Überprüfen Sie, ob Sie den richtigen Datenbanknamen im Assistenten Datenquelle erstellen angegeben haben und dass Ihre SQL-Abfrage gültig ist.

Beim Ausführen der SQL-Abfrage ist ein Fehler aufgetreten. Fehlerursache: {serverMessage}.

Ursache

Amazon Redshift konnte die angegebene Tabelle nicht finden.

Lösung

Vergewissern Sie sich, dass die Tabelle, die Sie im Assistenten zum Erstellen einer Datenquelle angegeben haben, in Ihrer Amazon Redshift Redshift-Cluster-Datenbank vorhanden ist und dass Sie die richtige Cluster-ID, den Datenbanknamen und die richtige SQL-Abfrage eingegeben haben.

Den AWS-Support kontaktieren

Wenn Sie AWS Premium Support haben, können Sie einen technischen Support-Fall unter [AWS Support Center](#) eröffnen.

Verwenden von Daten aus einer Amazon RDS-Datenbank zur Erstellung einer Amazon ML-Datenquelle

Mit Amazon ML können Sie ein Datenquellenobjekt aus Daten erstellen, die in einer MySQL-Datenbank in Amazon Relational Database Service (Amazon RDS) gespeichert sind. Wenn Sie diese Aktion ausführen, erstellt Amazon ML ein AWS Data Pipeline Pipeline-Objekt, das die von Ihnen angegebene SQL-Abfrage ausführt, und platziert die Ausgabe in einem S3-Bucket Ihrer Wahl. Amazon ML verwendet diese Daten, um die Datenquelle zu erstellen.

Note

Amazon ML unterstützt nur MySQL-Datenbanken in VPCs.

Bevor Amazon ML Ihre Eingabedaten lesen kann, müssen Sie diese Daten nach Amazon Simple Storage Service (Amazon S3) exportieren. Sie können Amazon ML mithilfe der API so einrichten,

dass es den Export für Sie durchführt. (RDS ist auf die API beschränkt und nicht von der Konsole aus verfügbar.)

Damit Amazon ML eine Verbindung zu Ihrer MySQL-Datenbank in Amazon RDS herstellen und Daten in Ihrem Namen lesen kann, müssen Sie Folgendes angeben:

- RDS DB-Instance-Kennung
- Name der MySQL-Datenbank
- Die AWS Identity and Access Management (IAM-) Rolle, die zum Erstellen, Aktivieren und Ausführen der Datenpipeline verwendet wird
- Benutzeranmeldeinformationen für die Datenbank:
 - Benutzername
 - Passwort
- Sicherheitsinformationen zur AWS Data Pipeline:
 - Die IAM-Ressourcenrolle
 - Die IAM-Servicerolle
- Die Amazon RDS-Sicherheitsinformationen:
 - Die Subnetz-ID
 - Die Sicherheitsgruppe IDs
- Die SQL-Abfrage, welche die Daten angibt, die Sie verwenden möchten, um die Datenquelle zu erstellen
- Der S3-Ausgabespeicherort (Bucket) zum Speichern der Ergebnisse der Abfrage
- (Optional) Der Speicherort der Datenschemadatei

Darüber hinaus müssen Sie sicherstellen, dass die IAM-Benutzer oder -Rollen, die Amazon RDS-Datenquellen mithilfe des RDS-Vorgangs erstellen, über die [CreateDataSourceFromentsprechende](#) Berechtigung verfügen. `iam:PassRole` Weitere Informationen finden Sie unter [Steuern des Zugriffs auf Amazon ML-Ressourcen – mit IAM](#).

Themen

- [RDS-Datenbank-Instance-Kennung](#)
- [MySQL-Datenbankname](#)
- [Benutzeranmeldeinformationen für die Datenbank](#)
- [Sicherheitsinformationen zur AWS Data Pipeline](#)
- [Amazon RDS-Sicherheitsinformationen](#)

- [MySQL-SQL-Abfragen](#)
- [S3-Ausgabespeicherort](#)

RDS-Datenbank-Instance-Kennung

Die RDS-DB-Instance-ID ist ein eindeutiger Name, den Sie angeben und der die Datenbank-Instance identifiziert, die Amazon ML bei der Interaktion mit Amazon RDS verwenden soll. Sie finden die ID der RDS-DB-Instance in der Amazon RDS-Konsole.

MySQL-Datenbankname

Der MySQL-Datenbankname gibt den Namen der MySQL-Datenbank in der RDS-DB-Instance an.

Benutzeranmeldeinformationen für die Datenbank

Zum Herstellen einer Verbindung mit der RDS-DB-Instance müssen Sie den Benutzernamen und das Kennwort des Datenbankbenutzers angeben, der über die erforderlichen Berechtigungen zum Ausführen der SQL-Abfrage verfügt, die Sie bereitgestellt haben.

Sicherheitsinformationen zur AWS Data Pipeline

Um den sicheren Zugriff auf AWS Data Pipeline zu ermöglichen, müssen Sie die Namen der IAM-Ressourcenrolle und der IAM-Servicerolle angeben.

Eine EC2-Instance übernimmt die Ressourcenrolle, um Daten von Amazon RDS nach Amazon S3 zu kopieren. Die einfachste Möglichkeit zum Erstellen dieser Ressourcenrolle ist mithilfe der `DataPipelineDefaultResourceRole`-Vorlage und Auflisten von **machinelearning.aws.com** als vertrauenswürdiger Service. Weitere Informationen zur Vorlage finden Sie unter [Einrichten von IAM-Rollen](#) im AWS Data Pipeline-Entwicklerhandbuch.

Wenn Sie Ihre eigene Rolle erstellen, muss diese den folgenden Inhalt haben:

JSON

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

```
"Effect": "Allow",
"Principal": {
  "Service": "machinelearning.amazonaws.com"
},
"Action": "sts:AssumeRole",
"Condition": {
  "StringEquals": { "aws:SourceAccount": "123456789012" },
  "ArnLike": { "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:datasource/*" }
}
}]
}
```

AWS Data Pipeline übernimmt die Service-Rolle zur Überwachung des Fortschritts beim Kopieren von Daten von Amazon RDS nach Amazon S3. Die einfachste Möglichkeit zum Erstellen dieser Ressourcenrolle ist mithilfe der `DataPipelineDefaultRole`-Vorlage und Auflisten von `machinelearning.amazonaws.com` als vertrauenswürdiger Service. Weitere Informationen zur Vorlage finden Sie unter [Einrichten von IAM-Rollen](#) im AWS Data Pipeline-Entwicklerhandbuch.

Amazon RDS-Sicherheitsinformationen

Um den sicheren Amazon RDS-Zugriff zu aktivieren, müssen Sie den VPC Subnet ID und angebenRDS Security Group IDs. Darüber hinaus müssen Sie geeignete Eingangsregeln für das VPC-Subnetz einrichten, auf das vom Parameter Subnet ID verwiesen wird, und die ID der Sicherheitsgruppe angeben, die über diese Berechtigung verfügt.

MySQL-SQL-Abfragen

Der Parameter `MySQL SQL Query` gibt die SQL SELECT-Abfrage an, die Sie für die MySQL-Datenbank ausführen möchten. Die Ergebnisse der Abfrage werden an den S3-Ausgabespeicherort (Bucket) kopiert, den Sie angeben.

Note

Machine Learning-Technologie eignet sich besonders dann, wenn Eingabedatensätze in zufälliger Reihenfolge (gemischt) bereitgestellt werden. Sie können problemlos die Ergebnisse Ihrer MySQL-SQL-Abfrage mischen, indem Sie die Funktion `rand()` verwenden. Beispiel: Angenommen, dies ist die ursprüngliche Abfrage:
"SELECT col1, col2, ... FROM training_table"

Sie können durch Aktualisierung der Abfrage zufällig mischen:
"SELECT col1, col2, ... FROM training_table ORDER BY rand()"

S3-Ausgabespeicherort

Der `S3 Output Location` Parameter gibt den Namen des Amazon S3 S3-Speicherorts „Staging“ an, an dem die Ergebnisse der MySQL-SQL-Abfrage ausgegeben werden.

Note

Sie müssen sicherstellen, dass Amazon ML berechtigt ist, Daten von diesem Speicherort zu lesen, sobald die Daten aus Amazon RDS exportiert wurden. Informationen zur Einrichtung dieser Berechtigungen finden Sie unter "Gewähren von Amazon ML-Berechtigungen zum Lesen von Daten aus Amazon S3".

Schulung von ML-Modellen

Für die Schulung eines ML-Modells muss ein ML-Algorithmus (der Lernalgorithmus) mit Schulungsdaten bereitgestellt werden. Der Begriff ML-Modell bezeichnet das Modell-Artefakt, das durch den Schulungsprozess erstellt wird.

Die Schulungsdaten müssen die richtige Antwort enthalten, die als Zeil oder Zielattribut bezeichnet wird. Der Lernalgorithmus findet Muster in den Schulungsdaten, die die Attribute der Input-Daten dem Ziel (die Antwort, die Sie voraussagen möchten) zuordnen, und gibt ein ML-Modell aus, in dem diese Muster erfasst sind.

Sie können das ML-Modell verwenden, um Voraussagen für neue Daten zu erhalten, bei denen Sie das Ziel nicht kennen. Nehmen wir beispielsweise an, dass Sie ein ML-Modell schulen möchten, damit es voraussagt, ob eine E-Mail Spam ist oder nicht. Sie würden Amazon ML Trainingsdaten zur Verfügung stellen, die E-Mails enthalten, deren Ziel Sie kennen (d. h. ein Etikett, das angibt, ob es sich bei einer E-Mail um Spam handelt oder nicht). Amazon ML würde anhand dieser Daten ein ML-Modell trainieren, was zu einem Modell führen würde, das versucht, vorherzusagen, ob es sich bei neuen E-Mails um Spam handelt oder nicht.

Allgemeine Informationen über ML-Modelle und ML-Algorithmen finden Sie unter [Machine Learning-Konzepte](#).

Themen

- [ML-Modelltypen](#)
- [Schulungsprozess](#)
- [Schulungsparameter](#)
- [Erstellen eines ML-Modells](#)

ML-Modelltypen

Amazon ML unterstützt drei Arten von ML-Modellen: binäre Klassifizierung, Mehrklassenklassifizierung und Regression. Wählen Sie den Modelltyp danach aus, welches Ziel Sie voraussagen möchten.

Binäres Klassifizierungsmodell

ML-Modelle für binäre Klassifizierungsprobleme prognostizieren ein binäres Ergebnis (eine von zwei möglichen Klassen). Um binäre Klassifikationsmodelle zu trainieren, verwendet Amazon ML den branchenüblichen Lernalgorithmus, der als logistische Regression bekannt ist.

Beispiele für binäre Klassifizierungsprobleme:

- "Ist diese E-Mail Spam oder nicht?"
- "Wird der Kunde das Produkt kaufen?"
- "Ist Ihr Produkt ein Buch oder ein Nutztier?"
- "Wurde diese Bewertung von einem Kunden oder einer Maschine geschrieben?"

Mehrklassen-Klassifizierungsmodell

Mit ML-Modellen für Mehrklassen-Klassifizierungsprobleme können Sie Prognosen für mehrere Klassen generieren (Vorhersage von einem aus mehr als zwei Ergebnissen). Für das Training von Mehrklassenmodellen verwendet Amazon ML den branchenüblichen Lernalgorithmus, der als multinomiale logistische Regression bekannt ist.

Beispiele für Mehrklassen-Probleme:

- "Ist das Produkt ein Buch, ein Film oder Kleidung?"
- "Ist dieser Film ein Liebeskomödie, eine Dokumentation oder ein Thriller?"
- "Welche Kategorie von Produkten für diesen Kunden am interessantesten?"

Regressionsmodell

ML-Modelle für Regressionsprobleme sagen einen numerischen Wert voraus. Für das Training von Regressionsmodellen verwendet Amazon ML den branchenüblichen Lernalgorithmus, der als lineare Regression bekannt ist.

Beispiele für Regressionsprobleme:

- "Wie wird die Temperatur in Seattle morgen sein?"
- "Wie viele Einheiten dieses Produkts werden wir verkaufen?"
- "Für welchen Preis wird dieses Haus verkauft?"

Schulungsprozess

Wenn Sie ein ML-Modell schulen, müssen Sie Folgendes angeben:

- Eingabe-Schulungsdatenquelle
- Name des Datenattributs, welche das vorherzusagende Ziel enthält
- Erforderliche Datentransformationsanweisungen
- Schulungsparameter zur Steuerung des Lern-Algorithmus

Während des Schulungsprozesses wählt Amazon ML automatisch den richtigen Lern-Algorithmus für Sie aus, basierend auf dem Typ des Ziels, das Sie in der Schulungsdatenquelle angegeben haben.

Schulungsparameter

In der Regel akzeptieren Algorithmen für Machine Learning Parameter, die verwendet werden können, um bestimmte Eigenschaften des Schulungsmodells und des resultierenden ML-Modells zu steuern. In Amazon Machine Learning werden diese als Trainingsparameter bezeichnet. Sie können diese Parameter über die Amazon ML-Konsole, API oder Befehlszeilenschnittstelle (CLI) festlegen. Wenn Sie keine Parameter festlegen, verwendet Amazon ML Standardwerte, von denen bekannt ist, dass sie sich für eine Vielzahl von Machine-Learning-Aufgaben gut eignen.

Sie können Werte für die folgenden Schulungsparameter angeben:

- Maximale Modellgröße
- Maximale Anzahl von Durchläufen von Schulungsdaten
- Art der Mischung
- Regularisationstyp
- Regularisationsumfang

In der Amazon ML-Konsole sind die Trainingsparameter standardmäßig festgelegt. Die Standardeinstellungen sind für die meisten ML-Probleme geeignet, Sie können jedoch andere Werte auswählen, um die Leistung zu optimieren. Bestimmte andere Schulungsparameter, z. B. das Lerntempo, werden basierend auf Ihren Daten für Sie konfiguriert.

In den folgenden Abschnitten finden Sie weitere Informationen zu Schulungsparametern.

Maximale Modellgröße

Die maximale Modellgröße ist die Gesamtgröße der Muster, die Amazon ML während des Trainings eines ML-Modells erstellt, in Byteeinheiten.

Standardmäßig erstellt Amazon ML ein 100-MB-Modell. Sie können Amazon ML anweisen, ein kleineres oder größeres Modell zu erstellen, indem Sie eine andere Größe angeben. Den Bereich verfügbarer Größen finden Sie unter [ML-Modelltypen](#)

Wenn Amazon ML nicht genügend Muster finden kann, um die Modellgröße zu füllen, wird ein kleineres Modell erstellt. Wenn Sie beispielsweise eine maximale Modellgröße von 100 MB angeben, Amazon ML jedoch Muster findet, die insgesamt nur 50 MB umfassen, ist das resultierende Modell 50 MB groß. Wenn Amazon ML mehr Muster findet, als in die angegebene Größe passen, wird ein maximaler Grenzwert erzwungen, indem die Muster gekürzt werden, die die Qualität des erlernten Modells am wenigsten beeinträchtigen.

Durch Auswählen der Modellgröße können Sie den Kompromiss zwischen der prognostizierten Qualität und den Kosten der Verwendung steuern. Kleinere Modelle können dazu führen, dass Amazon ML viele Muster entfernt, sodass sie innerhalb der maximalen Größenbeschränkung liegen, was sich auf die Qualität der Prognosen auswirkt. Bei größeren Modellen ist hingegen das Abfragen von Echtzeitvoraussagen kostspieliger.

Note

Wenn Sie ein ML-Modell verwenden, um Echtzeitvoraussagen zu erstellen, fallen Gebühren für die Kapazitätsreservierung an, die auf der Größe des Modells basieren. Weitere Informationen finden Sie unter [Preise für Amazon ML](#).

Größere Eingabedatensätze führen nicht unbedingt zu größeren Modellen, da Modelle Muster speichern, und nicht Eingabedaten. Wenn es nur wenige simple Muster gibt, ist das resultierende Modell klein. Bei Eingabedaten mit einer großen Anzahl von Rohattributen (Eingabespalten) oder abgeleiteten Merkmalen (Ausgaben der Amazon ML-Datentransformationen) werden während des Trainingsprozesses wahrscheinlich mehr Muster gefunden und gespeichert. Das Auswählen der richtigen Modellgröße für Ihre Daten und Problem erfolgt am besten mit ein paar Experimenten. Das Amazon ML-Modelltrainingsprotokoll (das Sie von der Konsole oder über die API herunterladen können) enthält Meldungen darüber, wie stark das Modell während des Trainingsprozesses gekürzt wurde (falls vorhanden), sodass Sie die potenzielle hit-to-prediction Qualität abschätzen können.

Maximale Anzahl von Datendurchläufen

Um optimale Ergebnisse zu erzielen, muss Amazon ML Ihre Daten möglicherweise mehrfach durchgehen, um Muster zu erkennen. Standardmäßig macht Amazon ML 10 Durchgänge, aber Sie können die Standardeinstellung ändern, indem Sie eine Zahl bis zu 100 festlegen. Amazon ML verfolgt die Qualität der Muster (Modellkonvergenz) im Laufe der Zeit und beendet das Training automatisch, wenn keine Datenpunkte oder Muster mehr zu entdecken sind. Wenn Sie beispielsweise die Anzahl der Durchgänge auf 20 festlegen, Amazon ML aber feststellt, dass nach Ablauf von 15 Durchgängen keine neuen Muster gefunden werden können, wird das Training bei 15 Durchgängen beendet.

Im Allgemeinen sind für Datensätze mit nur wenigen Beobachtungen in der Regel mehr Datendurchläufe erforderlich, um eine höhere Modellqualität zu erzielen. Größere Datensätze enthalten häufig viele ähnliche Datenpunkte, sodass keine größere Anzahl von Durchläufen erforderlich ist. Es gibt zwei Auswirkungen der Auswahl mehrerer Datendurchläufe: die Modellschulung dauert länger und sie kostet mehr.

Art der Mischung von Schulungsdaten

In Amazon ML müssen Sie Ihre Trainingsdaten mischen. Beim Mischen wird die Reihenfolge der Daten so geändert, dass der SGD-Algorithmus nacheinander nicht nur einen Datentyp bei zahlreichen Beobachtungen erkennt. Wenn Sie beispielsweise ein ML-Modell so schulen, dass es einen Produkttyp vorhersagen kann, und Ihre Schulungsdaten enthalten die Produkttypen "Film", "Spielzeug" und "Videospiel", so sortiert der Algorithmus die Daten alphabetisch nach Produkttyp, wenn Sie die Daten vor dem Hochladen nach der Spalte für den Produkttyp sortiert haben. Der Algorithmus erkennt alle Daten für Filme zuerst, und das ML-Modell beginnt, Muster für Filme zu erlernen. Wenn das Modell dann Daten zu Spielsachen erkennt, würde jedes Update, das der Algorithmus vornimmt, das Modell an den Produkttyp "Spielzeug" anpassen, auch wenn diese Updates die Muster herabsetzen, die Filmen entsprechen. Durch diesen plötzlichen Wechsel vom Typ "Film" zu "Spielzeug" kann ein Modell erzeugen, das nicht lernt, wie Produkttypen korrekt vorhergesagt werden.

Sie müssen Ihre Trainingsdaten auch dann mischen, wenn Sie die Option für eine zufällige Aufteilung beim Aufteilen der Eingabedatenquelle in Schulungs- und Evaluierungsabschnitte auswählen. Bei der Strategie der zufälligen Aufteilung wird eine zufällige Teilmenge der Daten für jede Datenquelle ausgewählt, die Reihenfolge der Zeilen in der Datenquelle wird jedoch nicht geändert. Weitere Informationen zum Aufteilen der Daten finden Sie unter [Aufteilen Ihrer Daten](#).

Wenn Sie mit der Konsole ein ML-Modell erstellen, mischt Amazon ML die Daten standardmäßig mit einer Technik des Pseudo-Zufallsmischens. Unabhängig von der Anzahl der angeforderten Durchläufe mischt Amazon ML die Daten nur einmal, bevor das ML-Modell trainiert wird. Wenn Sie Ihre Daten gemischt haben, bevor Sie sie Amazon ML zur Verfügung gestellt haben, und nicht möchten, dass Amazon ML Ihre Daten erneut mischt, können Sie den Shuffle-Typ auf `none` einstellen. Wenn Sie beispielsweise die Datensätze in Ihrer CSV-Datei vor dem Hochladen auf Amazon S3 nach dem Zufallsprinzip gemischt haben, die `rand()` Funktion in Ihrer MySQL-SQL-Abfrage verwendet haben, als Sie Ihre Datenquelle aus Amazon RDS erstellt haben, oder die `random()` Funktion in Ihrer Amazon Redshift Redshift-SQL-Abfrage verwendet haben, hat die Einstellung des Shuffle-Typs keinen Einfluss auf die Vorhersagegenauigkeit Ihres ML-Modells. Durch einmaliges Mischen der Daten werden die Laufzeit und die Kosten für das Erstellen eines ML-Modells reduziert.

Important

Wenn Sie ein ML-Modell mithilfe der Amazon ML-API erstellen, mischt Amazon ML Ihre Daten standardmäßig nicht. Wenn Sie die API anstelle der Konsole zum Erstellen des ML-Modells verwenden, wird dringend empfohlen, dass Sie die Daten mischen, indem Sie den Parameter `sgd.shuffleType` auf `auto` festlegen.

Regularisationstyp und -umfang

Die prädiktive Leistung komplexer ML-Modelle (die Modelle mit vielen Eingabeattributen) wird beeinträchtigt, wenn die Daten zu viele Muster enthalten. Wenn die Anzahl von Mustern steigt, so steigt auch die Wahrscheinlichkeit, dass das Modell unbeabsichtigte Datenartefakte anstelle von echten Datenmustern erlernt. In einem solchen Fall weist das Modell eine hervorragende Leistung bei Schulungsdaten auf, kann aber neue Daten nicht verallgemeinern. Dieses Phänomen wird als Überanpassung der Schulungsdaten bezeichnet.

Mithilfe der Regularisation wird verhindert, dass eine Überanpassung von Schulungsdatenbeispielen durch lineare Modelle stattfindet, indem extreme Gewichtungswerte bestraft werden. Durch die L1-Regularisation wird die Anzahl von Funktionen reduziert, die in dem Modell verwendet werden, indem das Gewicht von Funktionen, die ansonsten ein sehr geringes Gewicht hätten, auf Null gedrückt wird. Die L1-Regularisation erzeugt platzsparende Modelle und reduziert das Rauschen im Modell. Die L2-Regularisation führt zu kleineren Gesamtgewichtungswerten, wodurch die Gewichtungen stabilisiert werden, wenn eine hohe Korrelation zwischen den Funktionen besteht. Sie können den Umfang der L1- oder der L2-Regularisation steuern, indem Sie den Parameter `Regularization amount`

verwenden. Das Festlegen eines besonders hohen Regularization amount-Werts kann dazu führen, dass alle Funktionen kein Gewicht aufweisen.

Das Auswählen und Einstellen des optimalen Regularisationswerts ist ein aktives Thema bei der Erforschung von Machine Learning. Sie werden wahrscheinlich von der Auswahl eines moderaten Umfangs an L2-Regularisierung profitieren, was die Standardeinstellung in der Amazon ML-Konsole ist. Fortgeschrittene Benutzer haben die Wahl zwischen drei Arten von Regularisation (Keine, L1 oder L2) und deren Umfang. Weitere Informationen zur Regularisation erhalten Sie unter [Regularisation \(Mathematik\)](#).

Schulungsparameter: Typen und Standardwerte

In der folgenden Tabelle sind die Amazon ML-Trainingsparameter zusammen mit den Standardwerten und dem jeweils zulässigen Bereich aufgeführt.

Schulungsparameter	Typ	Default Value (Standardwert)	Beschreibung
max MLModel SizeInBytes	Ganzzahl	100.000.000 Byte (100 MiB)	Zulässiger Bereich: 100.000 (100 KiB) bis 2.147.483.648 (2 GiB) In Abhängigkeit von den Eingabedaten kann sich die Modellgröße auf die Leistung auswirken.
sgd.maxPasses	Ganzzahl	10	Zulässiger Bereich: 1-100
sgd.shuffleType	Zeichenfolge	auto	Zulässige Werte: auto oder none
sgd.l1 RegularizationAmount	Double	0 (L1 wird standardmäßig nicht verwendet)	Zulässiger Bereich: 0 bis MAX_DOUBLE L1-Werte zwischen 1E-4 und 1E-8 erzeugen bekanntermaßen gute Ergebnisse. Höhere Werte erzeugen möglicherweise Modell, die nicht sehr hilfreich sind.

Schulungsparameter	Typ	Default Value (Standardwert)	Beschreibung
			Sie können sowohl L1 als auch L2 festlegen. Sie müssen sich für eine Option entscheiden.
sgd.l2 RegularizationAmount	Double	1E-6 (L2 wird standardmäßig für diesen Regularisationsumfang verwendet)	<p>Zulässiger Bereich: 0 bis MAX_DOUBLE</p> <p>L2-Werte zwischen 1E-2 and 1E-6 erzeugen bekanntermaßen gute Ergebnisse. Höhere Werte erzeugen möglicherweise Modell, die nicht sehr hilfreich sind.</p> <p>Sie können sowohl L1 als auch L2 festlegen. Sie müssen sich für eine Option entscheiden.</p>

Erstellen eines ML-Modells

Nachdem Sie eine Datenquelle erstellt haben, können Sie ein ML-Modell erstellen. Wenn Sie die Amazon Machine Learning Learning-Konsole verwenden, um ein Modell zu erstellen, können Sie wählen, ob Sie die Standardeinstellungen verwenden oder Ihr Modell anpassen möchten, indem Sie benutzerdefinierte Optionen anwenden.

Zu den benutzerdefinierten Optionen gehören:

- **Bewertungseinstellungen:** Sie können festlegen, dass Amazon ML einen Teil der Eingabedaten reserviert, um die Vorhersagequalität des ML-Modells zu bewerten. Weitere Informationen zu Auswertungen finden Sie unter [Evaluation von ML-Modellen](#).
- **Ein Rezept:** Ein Rezept teilt Amazon ML mit, welche Attribute und Attributtransformationen für das Modelltraining verfügbar sind. Informationen zu Amazon ML-Rezepten finden Sie unter [Feature-Transformationen mit Datenrezepten](#).

- Schulungsparameter: Parameter steuern bestimmte Eigenschaften des Schulungsprozesses und des resultierenden ML-Modells. Weitere Informationen zu Schulungsparametern finden Sie unter [Schulungsparameter](#).

Um Werte für diese Einstellungen auszuwählen oder anzugeben, wählen Sie die Option Benutzerdefiniert aus, wenn Sie den Assistenten zum Erstellen des ML-Modells verwenden. Wenn Sie möchten, dass Amazon ML die Standardeinstellungen anwendet, wählen Sie Standard.

Wenn Sie ein ML-Modell erstellen, wählt Amazon ML den Typ des Lernalgorithmus, den es verwenden wird, basierend auf dem Attributtyp Ihres Zielattributs aus. (Das Zielattribut ist das Attribut, das die "richtigen" Antworten enthält.) Wenn Ihr Zielattribut Binär ist, erstellt Amazon ML ein binäres Klassifizierungsmodell, das den logistischen Regressionsalgorithmus verwendet. Wenn Ihr Zielattribut „Kategorisch“ ist, erstellt Amazon ML ein Mehrklassenmodell, das einen multinomialen logistischen Regressionsalgorithmus verwendet. Wenn Ihr Zielattribut Numerisch ist, erstellt Amazon ML ein Regressionsmodell, das einen linearen Regressionsalgorithmus verwendet.

Themen

- [Voraussetzungen](#)
- [Erstellen eines ML-Modells mit Standardoptionen](#)
- [Erstellen eines ML-Modells mit benutzerdefinierten Optionen](#)

Voraussetzungen

Bevor Sie mit der Amazon ML-Konsole ein ML-Modell erstellen können, müssen Sie zwei Datenquellen erstellen, eine für das Training des Modells und eine für die Auswertung des Modells. Wenn Sie nicht zwei Datenquellen erstellt haben, lesen Sie [Schritt 2: Erstellen einer Schulungsdatenquelle](#) im Tutorial.

Erstellen eines ML-Modells mit Standardoptionen

Wählen Sie die Standardoptionen, wenn Amazon ML:

- Aufteilen der Eingabedaten so, dass die ersten 70 Prozent für die Schulung und die verbleibenden 30 Prozent für die Auswertung verwendet werden
- Vorschlagen eines Rezeptes basierend auf Statistiken, die in der Schulungsdatenbank erfasst wurden, was 70 Prozent der Eingabedatenbank entspricht.
- Auswählen der Standardschulungsparameter

So wählen Sie Standardoptionen aus

1. Wählen Sie in der Amazon ML-Konsole Amazon Machine Learning und dann ML-Modelle aus.
2. Wählen Sie auf der Zusammenfassungsseite der ML-Modelle die Option zum Erstellen eines neuen ML-Modells aus.
3. Stellen Sie auf der Seite mit den Eingabedaten sicher, dass die Option ausgewählt ist, dass Sie bereits eine Datenquelle erstellt haben, die auf Ihre S3-Daten zeigt.
4. Wählen Sie in der Tabelle Ihre Datenquelle aus, und wählen Sie dann Continue aus.
5. Geben Sie auf der Seite ML-Modelleinstellungen für ML-Modellname einen Namen für Ihr ML-Modell ein.
6. Stellen Sie sicher, dass in den Schulungs- und Auswertungseinstellungen die Option Standard ausgewählt ist.
7. Geben Sie unter Diese Bewertung benennen einen Namen für die Bewertung ein und wählen Sie dann Überprüfen aus. Amazon ML umgeht den Rest des Assistenten und leitet Sie zur Bewertungsseite weiter.
8. Überprüfen Sie Ihre Daten, löschen Sie alle aus der Datenquelle kopierten Tags, die nicht auf Ihr Modell und die Auswertungen angewendet werden sollen, und wählen Sie dann Finish aus.

Erstellen eines ML-Modells mit benutzerdefinierten Optionen

Durch Anpassen Ihres ML-Modells können Sie:

- Ihr eigenes Rezept bereitstellen. Weitere Informationen dazu, wie Sie Ihre eigenes Rezept bereitstellen, finden Sie unter [Referenz zum Rezeptformat](#).
- Wählen Sie Schulungsparameter aus. Weitere Informationen zu Schulungsparametern finden Sie unter [Schulungsparameter](#).
- Wählen Sie ein anderes training/evaluation Aufteilungsverhältnis als das standardmäßige Verhältnis 70/30 oder geben Sie eine andere Datenquelle an, die Sie bereits für die Evaluierung vorbereitet haben. Weitere Informationen über Aufteilungsstrategien finden Sie unter [Aufteilen Ihrer Daten](#).

Sie können auch die Standardwerte für diese Einstellungen auswählen.

Wenn Sie bereits ein Modell mithilfe der Standardoptionen erstellt haben und die prädiktive Leistung Ihres Modells verbessern möchten, verwenden Sie die Option, um ein neues Modell

mit einigen benutzerdefinierten Einstellungen zu erstellen. Vielleicht möchten Sie weitere Funktionstransformationen zu dem Rezept hinzufügen oder die Anzahl von Durchläufen im Schulungsparameter erhöhen.

So erstellen Sie ein Modell mit benutzerdefinierten Optionen

1. Wählen Sie in der Amazon ML-Konsole Amazon Machine Learning und dann ML-Modelle aus.
2. Wählen Sie auf der Zusammenfassungsseite der ML-Modelle die Option zum Erstellen eines neuen ML-Modells aus.
3. Wenn Sie bereits eine Datenquelle erstellt haben, wählen Sie auf der Seite Input Data die Option I already created a datasource pointing to my S3 data aus. Wählen Sie in der Tabelle Ihre Datenquelle aus, und wählen Sie dann Continue aus.

Wenn Sie eine Datenquelle erstellen müssen, wählen Sie My data is in S3, and I need to create a datasource aus, und wählen Sie dann Continue (Weiter). Sie werden zum Assistenten zum Erstellen einer Datenquelle weitergeleitet. Geben Sie an, ob sich Ihre Daten in S3 oder Redshift befinden, und klicken Sie anschließend auf Verify. Führen Sie die Schritte zum Erstellen einer Datenquelle aus.

Nachdem Sie eine Datenquelle erstellt haben, werden Sie automatisch zum nächsten Schritt im Assistenten zum Erstellen eines ML-Modells weitergeleitet.

4. Geben Sie auf der Seite ML-Modelleinstellungen für ML-Modellname einen Namen für Ihr ML-Modell ein.
5. Wählen Sie unter Schulungs- und Auswertungseinstellungen die Option Benutzerdefiniert aus, und klicken Sie dann auf Continue.
6. Auf der Seite Rezept können Sie [customize a recipe](#). Wenn Sie ein Rezept nicht anpassen möchten, schlägt Ihnen Amazon ML eines vor. Klicken Sie auf Weiter.
7. Geben Sie auf der Seite Erweiterte Einstellungen die maximale Größe des ML-Modells, die maximale Anzahl von Datendurchläufen, die Mischungsart für Schulungsdaten, den Regularisationstyp sowie den Regularisationsumfang an. Wenn Sie diese nicht angeben, verwendet Amazon ML die Standard-Trainingsparameter.

Weitere Informationen zu diesen Parametern und ihren Standardwerten finden Sie unter [Schulungsparameter](#).

Klicken Sie auf Weiter.

8. Geben Sie auf der Auswertung an, ob das ML-Modell sofort ausgewertet werden soll. Wenn das ML-Modell nicht jetzt ausgewertet werden soll, wählen Sie Review aus.

Wenn das ML-Modell jetzt ausgewertet werden soll:

- a. Geben Sie unter Diese Auswertung benennen einen Namen für die Auswertung ein.
 - b. Wählen Sie unter Bewertungsdaten auswählen aus, ob Amazon ML einen Teil der Eingabedaten für die Auswertung reservieren soll und, falls ja, wie Sie die Datenquelle aufteilen möchten, oder ob Sie eine andere Datenquelle für die Auswertung bereitstellen möchten.
 - c. Wählen Sie Überprüfen aus.
9. Bearbeiten Sie auf der Seite Review Ihre Auswahl, löschen Sie alle aus der Datenquelle kopierten Tags, die nicht auf Ihr Modell und die Auswertungen angewendet werden sollen, und wählen Sie dann Finish.

Lesen Sie [Schritt 4: Überprüfen der Voraussageleistung des ML-Modells und Festlegen eines Punktzahlschwellenwerts](#), nachdem Sie das Modell erstellt haben.

Datentransformationen für maschinelles Lernen

Machine Learning-Modelle sind nur so gut wie die verwendeten Daten für ihre Schulung. Ein Schlüsselmerkmal guter Schulungsdaten ist, dass sie auf eine Weise bereitgestellt werden, die für das Lernen und die Generalisierung optimiert ist. Der Vorgang, bei dem die Daten in diesem optimalen Format zusammengestellt werden, wird in der Branche als Funktionstransformation bezeichnet.

Themen

- [Bedeutung der Funktionstransformation](#)
- [Funktionstransformation mit Datenrezepten](#)
- [Referenz zum Rezeptformat](#)
- [Empfohlene Rezepte](#)
- [Referenz zur Datentransformation](#)
- [Neuordnung von Daten](#)

Bedeutung der Funktionstransformation

Betrachten wir ein Machine Learning-Modell, das entscheiden soll, ob eine Kreditkartentransaktion betrügerisch ist oder nicht. Basierend auf Ihrem Wissen über die Anwendung und Ihre Datenanalyse können Sie entscheiden, welche Datenfelder (oder Funktionen) in den Eingabedaten enthalten sein sollten. Beispielsweise sollten Transaktionsbetrag, Name des Händlers, Adresse und Adresse des Eigentümers der Kreditkarte im Lernprozess enthalten sein. Eine zufällig erstellte Transaktionsnummer hingegen enthält keine Informationen (sofern wir wissen, dass sie wirklich zufällig ist) und ist nicht nützlich.

Sobald Sie sich entschieden haben, welche Felder verwendet werden sollen, transformieren Sie diese Funktionen so, dass sie den Lernprozess unterstützen. Transformationen ergänzen die Eingabedaten mit Hintergrunderfahrung, sodass das Machine Learning-Modell aus dieser Erfahrung lernen kann. Beispielsweise steht die folgende Händleradresse in einer Zeichenfolge:

```
"123 Main Street, Seattle, WA 98101"
```

Die Adresse verfügt über begrenzte Aussagekraft – sie dient nur dem Erlernen von Mustern für diese spezielle Adresse. Durch das Herunterbrechen der Adresse in mehrere Teile jedoch können weitere Funktionen wie "Adresse" (123 Main Street), "Stadt" (Seattle), "Staat" (WA) und "ZIP" (98101) erstellt

werden. Der Lernalgorithmus kann nun mehrere separate Transaktionen zusammenführen und größere Muster erkennen – möglicherweise liegen zu bestimmten Händler-ZIPs mehr betrügerische Erfahrungen vor als zu anderen.

Weitere Informationen zur Funktionstransformation finden Sie unter [Machine Learning-Konzepte](#).

Funktionstransformation mit Datenrezepten

Es gibt zwei Möglichkeiten zum Umwandeln von Funktionen vor dem Erstellen von ML-Modellen mit Amazon ML: Sie können Ihre Eingabedaten direkt transformieren, bevor Sie sie an Amazon ML weitergeben, oder Sie können die integrierte Datentransformation von Amazon ML nutzen. Sie können Amazon ML-Rezepte verwenden, die vorformatierte Anweisungen für gängige Transformationen enthalten. Mit Rezepten können Sie Folgendes ausführen:

- Wählen Sie aus einer Liste von integrierten gängigen Machine Learning-Transformationen und wenden Sie diese auf einzelne Variablen oder Gruppen von Variablen an.
- Wählen Sie, welche der Eingabevariablen und Transformationen für den maschinellen Lernprozess zur Verfügung gestellt werden.

Die Verwendung von Amazon ML-Rezepten bietet mehrere Vorteile. Amazon ML führt die Datentransformationen für Sie aus. Es ist also nicht erforderlich, sie selbst zu implementieren. Außerdem sind sie schnell, da Amazon ML die Transformationen beim Lesen der Eingabedaten anwendet und die Ergebnisse an den Lernprozess weiterleitet, ohne dass die Ergebnisse als Zwischenschritt auf die Festplatte gespeichert werden.

Referenz zum Rezeptformat

Amazon ML-Rezepte enthalten Anweisungen zur Transformation Ihrer Daten als Teil des maschinellen Lernprozesses. Rezepte werden mit einer JSON-ähnlichen Syntax definiert, weisen aber zusätzliche Einschränkungen über die normalen JSON-Einschränkungen hinaus auf. Rezepte weisen die folgenden Abschnitte auf, die in der hier dargestellten Reihenfolge angezeigt werden müssen:

- Gruppen ermöglichen die Gruppierung mehrerer Variablen zur einfacheren Anwendung von Transformationen. Sie können beispielsweise eine Gruppe aller Variablen erstellen, die im Zusammenhang mit Freitextteilen einer Webseite (Titel, Textkörper) stehen, und dann eine Transformation für alle Teile gleichzeitig ausführen.

- Zuweisungen ermöglichen die Erstellung von benannten Zwischenvariablen, die bei der Verarbeitung wiederverwendet werden können.
- Ausgaben definieren, welche Variablen im Lernprozess verwendet werden und welche Transformationen ggf. für diese Variablen gelten.

Gruppen

Sie können Gruppen von Variablen definieren, um alle Variablen innerhalb der Gruppen gemeinsam zu transformieren oder um diese Variablen für maschinelles Lernen ohne Transformation zu verwenden. Standardmäßig erstellt Amazon ML die folgenden Gruppen für Sie:

ALL_TEXT, ALL_NUMERIC, ALL_CATEGORICAL, ALL_BINARY – Typspezifische Gruppen basierend auf Variablen, die im Datenquellschema definiert sind.

Note

Mit ALL_INPUTS kann keine Gruppe erstellt werden.

Diese Variablen können im Ausgabenabschnitts Ihres Rezepts verwendet werden, ohne definiert zu werden. Sie können auch benutzerdefinierte Gruppen erstellen, indem Sie Variablen zu bzw. von vorhandenen Gruppen addieren bzw. subtrahieren, oder direkt aus einer Sammlung von Variablen. Im folgenden Beispiel zeigen werden alle drei Ansätze sowie die Syntax für die Gruppenzuweisung veranschaulicht:

```
"groups": {  
  
  "Custom_Group": "group(var1, var2)",  
  "All_Categorical_plus_one_other": "group(ALL_CATEGORICAL, var2)"  
  
}
```

Gruppennamen müssen mit einem Buchstaben beginnen und können zwischen 1 und 64 Zeichen lang sein. Wenn der Gruppenname nicht mit einem Buchstaben beginnt oder Sonderzeichen (""\t\r\n () \) enthält, muss der Name in Anführungszeichen eingeschlossen werden, damit er in das Rezept aufgenommen werden kann.

Zuweisungen

Zur besseren Lesbarkeit und der Einfachheit halber können Sie eine oder mehrere Transformationen einer Zwischenvariablen zuweisen. Wenn Sie beispielsweise eine Textvariable mit dem Namen "email_subject" haben und Sie die Kleinbuchstaben-Transformation darauf anwenden, können Sie der resultierenden Variable den Namen "email_subject_lowercase" geben, sodass diese an anderer Stelle im Rezept leicht auffindbar ist. Zuweisungen können auch verkettet werden, sodass Sie mehrere Transformationen in einer angegebenen Reihenfolge anwenden können. Das folgende Beispiel zeigt einzelne und verkettete Zuordnungen in der Rezeptsyntax:

```
"assignments": {  
  
  "email_subject_lowercase": "lowercase(email_subject)",  
  
  "email_subject_lowercase_ngram": "ngram(lowercase(email_subject), 2)"  
  
}
```

Namen von Zwischenvariablen müssen mit einem Buchstaben beginnen und können zwischen 1 und 64 Zeichen lang sein. Wenn der Name nicht mit einem Buchstaben beginnt oder Sonderzeichen ("\"t\r\n () \) enthält, muss der Name in Anführungszeichen eingeschlossen werden, damit er in das Rezept aufgenommen werden kann.

Outputs

Der Ausgabeabschnitt steuert, welche Eingabevariablen für den Lernprozess verwendet werden und welche Transformationen darauf angewendet werden. Ein leerer oder nicht vorhandener Ausgabeabschnitt stellt einen Fehler dar, da keine Daten an den Lernprozess übergeben werden.

Der einfachste Ausgabeabschnitt umfasst die vordefinierte Gruppe ALL_INPUTS, die Amazon ML anweist, alle Variablen für den Lernprozess zu verwenden, die in der Datenquelle definiert sind:

```
"outputs": [  
  
  "ALL_INPUTS"  
  
]
```

Der Ausgabeabschnitt kann auch auf die anderen vordefinierten Gruppen verweisen, indem Amazon ML angewiesen wird, alle Variablen in diesen Gruppen zu verwenden:

```
"outputs": [  
  "ALL_NUMERIC",  
  "ALL_CATEGORICAL"  
]
```

Der Ausgabeabschnitt kann auch auf benutzerdefinierte Gruppen verweisen. Im folgenden Beispiel wird nur eine der benutzerdefinierten Gruppen für maschinelles Lernen verwendet, die im Abschnitt mit den Gruppierungszuweisungen im vorhergehenden Beispiel definiert sind. Alle anderen Variablen werden gelöscht:

```
"outputs": [  
  "All_Categorical_plus_one_other"  
]
```

Der Ausgabeabschnitt kann auch auf Variablenzuweisungen verweisen, die im Zuweisungsabschnitt definiert sind:

```
"outputs": [  
  "email_subject_lowercase"  
]
```

Und Eingabevariablen oder Transformationen können direkt im Ausgabenabschnitt definiert werden:

```
"outputs": [  
  "var1",  
  "lowercase(var2)"  
]
```

```
]
```

Die Ausgabe muss explizit alle Variablen und transformierten Variablen angeben, von denen erwartet wird, dass sie für den Lernprozess verfügbar sind. Angenommen, Sie schließen ein kartesisches Produkt aus `var1` und `var2` in die Ausgabe ein. Wenn Sie auch die unformatierten Variablen `var1` und `var2` einschließen möchten, müssen Sie die unformatierten Variablen im Ausgabeabschnitt hinzufügen:

```
"outputs": [  
  "cartesian(var1,var2)",  
  "var1",  
  "var2"  
]
```

Ausgaben können zur besseren Lesbarkeit Kommentare umfassen, indem der Kommentartext zusammen mit der Variablen hinzugefügt wird:

```
"outputs": [  
  "quantile_bin(age, 10) //quantile bin age",  
  "age // explicitly include the original numeric variable along with the  
  binned version"  
]
```

Sie können alle diese Ansätze innerhalb des Ausgabeabschnitts miteinander mischen.

Note

Kommentare sind in der Amazon ML-Konsole nicht erlaubt, wenn ein Rezept hinzugefügt wird.

Beispiel eines vollständigen Rezepts

Das folgende Beispiel bezieht sich auf mehrere integrierten Datenprozessoren, die den vorherigen Beispielen eingeführt wurden:

```
{
  "groups": {
    "LONGTEXT": "group_remove(ALL_TEXT, title, subject)",
    "SPECIALTEXT": "group(title, subject)",
    "BINCAT": "group(ALL_CATEGORICAL, ALL_BINARY)"
  },
  "assignments": {
    "binned_age" : "quantile_bin(age,30)",
    "country_gender_interaction" : "cartesian(country, gender)"
  },
  "outputs": [
    "lowercase(no_punct(LONGTEXT))",
    "ngram(lowercase(no_punct(SPECIALTEXT)),3)",
    "quantile_bin(hours-per-week, 10)",
    "hours-per-week // explicitly include the original numeric variable
    along with the binned version",
    "cartesian(binned_age, quantile_bin(hours-per-week,10)) // this one is
    critical",
    "country_gender_interaction",
    "BINCAT"
```

```
]
}
```

Empfohlene Rezepte

Wenn Sie eine neue Datenquelle in Amazon ML erstellen und Statistiken für die Datenquelle berechnet werden, erstellt Amazon ML außerdem eine Rezeptempfehlung, um ein neues ML-Modell aus der Datenquelle zu erstellen. Die empfohlene Datenquelle basiert auf den Daten und in den vorhandenen Daten Zielattributen und bietet einen nützlichen Ausgangspunkt für das Erstellen und Optimieren der ML-Modelle.

Zur Verwendung des empfohlenen Rezepts in der Amazon ML-Konsole wählen Sie Datasource oder Datasource and ML model aus der Dropdown-Liste Create new. Für ML-Modelleinstellungen haben Sie verschiedene Standard- oder benutzerdefinierte Schulungs- und Auswertungseinstellungen im Schritt ML Model Settings des Assistenten für Create ML Model. Wenn Sie die Option "Default" auswählen, verwendet Amazon ML automatisch das empfohlene Rezept. Wenn Sie die Option "Custom" auswählen, wird der Rezepteditor im nächsten Schritt angezeigt, und Sie haben die Möglichkeit, das empfohlenen Rezept zu prüfen oder zu ändern.

Note

Amazon ML ermöglicht Ihnen die Erstellung einer Datenquelle und die sofortige Verwendung zum Erstellen eines ML-Modells, bevor die Statistikberechnung abgeschlossen ist. In diesem Fall können Sie das empfohlene Rezept nicht in der Option "Custom" sehen, aber Sie können über diesen Schritt hinaus fortfahren und Amazon ML das Standardrezept für die Modellschulung verwenden lassen.

Um das vorgeschlagene Rezept mit der Amazon ML-API zu verwenden, können Sie sowohl im Recipe- als auch im RecipeUri API-Parameter eine leere Zeichenfolge übergeben. Es ist nicht möglich, das empfohlene Rezept mit der Amazon ML-API abzurufen.

Referenz zur Datentransformation

Themen

- [N-Gramm-Transformation](#)

- [Orthogonal Sparse Bigram \(OSB\)-Transformation](#)
- [Umwandlung in Kleinbuchstaben](#)
- [Transformation zum Entfernen von Satzzeichen](#)
- [Quartile-Binning-Transformation](#)
- [Normierungstransformation](#)
- [Kartesische Produkt-Transformation](#)

N-Gramm-Transformation

Bei einer N-Gramm-Transformation wird eine Textvariable als Eingabe erfasst und Zeichenfolgen erzeugt, die einem Fenster mit "n" Wörtern (benutzerdefiniert) entsprechen. Dabei werden Ausgaben generiert. Im folgenden Beispiel wird die Textzeichenfolge "Ich las dieses Buch wirklich gern".

Durch Angabe der N-Gramm-Transformation mit Fenstergröße = 1 erhalten Sie alle einzelnen Wörter in dieser Zeichenfolge:

```
{"I", "really", "enjoyed", "reading", "this", "book"}
```

Wird für eine N-Gramm-Transformation die Fenstergröße = 2 angegeben, erhalten Sie alle Kombinationen aus zwei Wörtern sowie alle Einzelwortkombinationen:

```
{"I really", "really enjoyed", "enjoyed reading", "reading this", "this book", "I", "really", "enjoyed", "reading", "this", "book"}
```

Durch Angabe der N-Gramm-Transformation mit Fenstergröße = 3 werden der Liste Kombinationen aus drei Wörtern hinzugefügt. Dies führt zu folgendem Ergebnis:

```
{"I really enjoyed", "really enjoyed reading", "enjoyed reading this", "reading this book", "I really", "really enjoyed", "enjoyed reading", "reading this", "this book", "I", "really", "enjoyed", "reading", "this", "book"}
```

Sie können N-Gramme mit einer Größe von 2-10 Wörtern anfordern. N-Gramme mit der Größe 1 werden implizit für alle Eingaben generiert, deren Typ als Text im Datenschema markiert ist, sodass

Sie dies nicht extra angeben müssen. Außerdem sollten Sie bedenken, dass N-Gramme generiert werden, indem die Eingabedaten durch Leerzeichen unterbrochen werden. Das bedeutet, dass beispielsweise Interpunktionszeichen werden als Teil des Worttokens betrachtet werden: Generieren eines N-Gramms mit einem Fenster von 2 für die Zeichenfolge "Rot, Grün, Blau" ergibt {"Rot,", "Grün,", "Blau,", "Rot, Grün", "Grün, Blau"}. Sie können den Satzzeichenentfernungs-Prozessor (siehe weiter unten in diesem Dokument) verwenden, um die Satzzeichen zu entfernen, wenn Sie dies nicht wünschen.

So berechnen Sie N-Gramme mit der Fenstergröße 3 für Variable var1:

```
"ngram(var1, 3)"
```

Orthogonal Sparse Bigram (OSB)-Transformation

Die OSB-Transformation soll bei der Textzeichenfolgenanalyse helfen und ist eine Alternative zur Bigramm-Transformation (N-Gramm mit Fenstergröße 2). OSBs werden generiert, indem das Fenster der Größe n über den Text geschoben wird und jedes Wortpaar ausgegeben wird, das das erste Wort im Fenster enthält.

Zum Erstellen von OSB werden die enthaltenen Wörter mit einem Unterstrich "_" verbunden und alle übersprungenen Token durch Angabe eines weiteren Unterstrichs im OSB angegeben. Daher codiert die OSB-Transformation nicht nur die Token in einem Fenster, sondern auch die Anzahl der übersprungenen Token in diesem Fenster.

Stellen Sie sich zur Veranschaulichung die Zeichenfolge „Der schnelle braune Fuchs springt über den faulen Hund“ OSBs der Größe 4 vor. Die sechs aus vier Wörtern bestehenden Fenster und die letzten beiden kürzeren Fenster am Ende der Zeichenfolge werden im folgenden Beispiel dargestellt und jeweils anhand der einzelnen Fenster OSBs generiert:

Fenster, {OSBs generiert}

```
"The quick brown fox", {The_quick, The__brown, The___fox}
```

```
"quick brown fox jumps", {quick_brown, quick__fox, quick___jumps}
```

```
"brown fox jumps over", {brown_fox, brown__jumps, brown___over}
```

```
"fox jumps over the", {fox_jumps, fox__over, fox___the}
```

```
"jumps over the lazy", {jumps_over, jumps_the, jumps_lazy}
```

```
"over the lazy dog", {over_the, over_lazy, over_dog}
```

```
"the lazy dog", {the_lazy, the_dog}
```

```
"lazy dog", {lazy_dog}
```

OSBs sind eine Alternative für N-Gramme, die ggf. in einigen Fällen besser funktionieren. Wenn Ihre Daten große Textfelder (10 oder mehr Wörter) haben, experimentieren Sie damit, um zu sehen, welche Option besser geeignet ist. Bitte beachten Sie: Was ein „großes Textfeld“ ist, kann je nach Situation unterschiedlich sein. Bei größeren Textfeldern wurde jedoch empirisch OSBs nachgewiesen, dass sie den Text aufgrund des speziellen Skip-Symbols (des Unterstrichs) eindeutig darstellen.

Sie können eine Fenstergröße von 2 bis 10 für OSB-Transformationen von Eingabetextvariablen angeben.

Um OSBs mit der Fenstergröße 5 für die Variable `var1` zu rechnen:

```
"osb(var1, 5)"
```

Umwandlung in Kleinbuchstaben

Der Kleinbuchstaben-Transformationsprozessor wandelt Texteingaben in Kleinbuchstaben um. Die Eingabe "Franz jagt im komplett verwahrlosten Taxi quer durch Bayern" wird vom Prozessor beispielsweise in die Ausgabe "franz jagt im komplett verwahrlosten taxi quer durch bayern" umgewandelt.

So wenden Sie Kleinbuchstaben-Transformation auf die Variable `var1` an:

```
"lowercase(var1)"
```

Transformation zum Entfernen von Satzzeichen

Amazon ML unterteilt als Text markierte Eingaben im Datenschema implizit bei Leerzeichen. Satzzeichen in der Zeichenfolge ergeben entweder angrenzende Wort-Token oder vollständig separate Token, abhängig von den umgebenden Leerzeichen. Wenn Sie dies verhindern möchten, können Sie die Transformation zum Entfernen der Satzzeichen verwenden, um Satzzeichen aus

generierten Funktionen zu entfernen. Beispielsweise werden für die Zeichenfolge "Willkommen bei AML – bitte verwenden Sie Sicherheitsgurte!" implizit die folgenden Token generiert:

```
{"Welcome", "to", "Amazon", "ML", "-", "please", "fasten", "your", "seat-belts!"}
```

Die Anwendung des Satzzeichenentfernungs-Prozessors auf diese Zeichenfolge ergibt folgenden Satz:

```
{"Welcome", "to", "Amazon", "ML", "please", "fasten", "your", "seat-belts"}
```

Beachten Sie, dass nur vorangestellte und nachfolgende Satzzeichen entfernt werden. Satzzeichen, die mitten in einem Token stehen, z. B. ein Bindestrich in "Sicherheits-Gurt", werden nicht entfernt.

So wenden Sie Satzzeichenentfernung auf die Variable `var1` an:

```
"no_punct(var1)"
```

Quartile-Binning-Transformation

Der Quartile-Binning-Prozessor verwendet zwei Eingaben, nämlich eine numerische Variable und ein als Bin-Nummer bezeichneter Parameter. Die Ausgabe besteht aus einer kategorischen Variable. Der Zweck ist das Erkennen von Nicht-Linearität in der Variablenverteilung durch Gruppierung der beobachteten Werte.

In vielen Fällen ist die Beziehung zwischen einer numerischen Variablen und dem Ziel nicht linear (der numerische Variablenwert wird nicht gleichmäßig mit dem Ziel erhöht oder verringert). In solchen Fällen kann es nützlich sein, die numerische Funktion in eine kategorische Funktion zu packen, um verschiedene Bereiche der numerischen Funktion darzustellen. Jeder kategorische Funktionswert (Bin) kann dann mit einer eigenen linearen Beziehung zum Ziel im Modell dargestellt werden. Nehmen wir an, Sie wissen, dass die kontinuierliche numerische Funktion Kontodauer nicht linear mit der Wahrscheinlichkeit verläuft, ein Buch zu kaufen. Sie können die Dauer also in kategorische Funktionen packen, die in der Lage sind, die Beziehung zum Ziel genauer zu erfassen.

Der Quartile-Binning-Prozessor kann verwendet werden, um Amazon ML anzuweisen, `n` Pakete gleicher Größe basierend auf der Verteilung aller Eingabewerte der Dauer-Variable zu erstellen und dann jede Zahl durch ein Text-Token mit dem darin enthaltenen Paket zu ersetzen. Die optimale Anzahl von Paketen für eine numerische Variable hängt von den Eigenschaften der Variablen und ihrer Beziehung mit dem Ziel ab und wird am besten durch Experimente bestimmt. Amazon ML

schlägt die optimale Paketanzahl für eine numerische Funktion basierend auf den Datenstatistiken im [vorgeschlagenen Rezept](#) vor.

Sie können zwischen 5 und 1000 Quantil-Pakete für jede numerische Eingabevariable berechnet lassen.

Im folgenden Beispiel wird gezeigt, wie 50 Pakete anstelle der numerischen Variablen var1 berechnet und verwendet werden:

```
"quantile_bin(var1, 50)"
```

Normierungstransformation

Die Normierungstransformation normalisiert numerische Variablen auf einen Mittelwert von 0 und die Varianz 1. Die Normierung von numerischen Variablen kann den Lernprozess unterstützen, wenn es sehr große Bereichsunterschiede zwischen numerischen Variablen gibt, da Variablen mit der höchsten Größenordnung das ML-Modell dominieren könnten, unabhängig davon, ob die Funktion in Bezug auf das Ziel informativ ist oder nicht.

Um diese Transformation auf die numerische Variable var1 anzuwenden, fügen Sie Folgendes zum Rezept hinzu:

```
normalize(var1)
```

Diese Transformation kann auch eine benutzerdefinierte Gruppe von numerischen Variablen oder die voreingestellte Gruppe für alle numerischen Variablen (ALL_NUMERIC) als Eingabe verwenden:

```
normalize(ALL_NUMERIC)
```

Hinweis

Es ist nicht erforderlich, den Normierungsprozessor für numerische Variablen zu verwenden.

Kartesische Produkt-Transformation

Die kartesische Transformation generiert Permutationen von zwei oder mehr Text- oder kategorischen Eingabevariablen. Diese Transformation wird verwendet, wenn eine Interaktion zwischen Variablen vermutet wird. Nehmen Sie zum Beispiel den Bank-Marketing-Datensatz im Tutorial: Verwenden von Amazon ML zur Voraussage von Antworten auf ein Marketing-Angebot. Mit diesem Datensatz möchten wir voraussagen, ob eine Person positiv auf ein Bankangebot reagiert,

basierend auf wirtschaftlichen und demografischen Informationen. Wir könnten vermuten, dass die Person einen wichtigen Job hat (vielleicht gibt es einen Zusammenhang zwischen einer Anstellung in bestimmten Bereichen und verfügbarem Geld), und auch der höchste erreichte Bildungsabschluss ist ebenfalls wichtig. Wir könnten auch eine tiefergehende Intuition haben, dass es eine klare Botschaft in der Interaktion dieser beiden Variablen gibt, z. B., dass die Werbeaktion besonders für Kunden geeignet ist, die Unternehmer mit Hochschulabschluss sind.

Die kartesische Produkt-Transformation nimmt kategorische Variablen oder Text als Eingabe und erzeugt neue Funktionen, um die Interaktion zwischen diesen Eingabevariablen zu erfassen. Insbesondere für jedes Schulungsbeispiel erstellt es eine Kombination aus Funktionen und fügt sie dann als eigenständige Funktion hinzu. Angenommen, unsere vereinfachten Eingabezeilen sehen so aus:

Ziel, Bildung, Job

0, Universität.Abschluss, Techniker

0, Fach.Hochschule, Service

1, Universität.Abschluss, Admin

Wenn wir angeben, dass die kartesischen Transformation auf die kategorischen Variablen "Bildung" und "Job" angewendet wird, sieht die resultierende Funktion Bildung_Job_Interaktion wie folgt aus:

Ziel, Bildung_Job_Interaktion

0, Universität.Abschluss_Techniker

0, Fach.Hochschule_Service

1, Universität.Abschluss_Admin

Die kartesische Transformation ist sogar noch leistungsfähiger, wenn es um die Bearbeitung von Token-Sequenzen geht. Dies ist der Fall, wenn es sich bei einem der Argumente um eine Textvariable handelt, die implizit oder explizit in Token aufgeteilt ist. Nehmen Sie beispielsweise die Klassifizierungsaufgabe, ob ein Buch als Lehrbuch eingesetzt wird oder nicht. Intuitiv denken wir, dass etwas im Buchtitel uns verrät, ob es sich um ein Lehrbuch handelt (bestimmte Wörter können häufiger in Lehrbuchtiteln auftauchen), und wir vermuten auch den Bucheinband (Fachbücher sind mit höherer Wahrscheinlichkeit gebunden), aber es ist in Wirklichkeit die Kombination von einigen Wörtern im Titel und der Einband, die die beste Voraussage ergeben. Für ein praktisches Beispiel

finden Sie in der folgenden Tabelle die Ergebnisse der Anwendung des kartesischen Prozessors auf die Eingabevariablen für Einband und Titel:

Lehr	Title	Einband	Kartesisches Produkt aus no_punct(Titel) und Einband
1	Wirtschaft: Prinzipien, Probleme, Richtlini en	Hardcover	{"Wirtschaft_Hardcover", "Prinzipien_Hardcover", "Probleme_Hardcover", "Richtlinien_Hardcover"}
0	Das unsichtba re Herz: Eine Wirtschaftromanze	Taschenb ch	{"Das_Taschenbuch", "unsichtbare_Taschenbuch", "Herz_Taschenbuch", "Eine_Taschenbuch", "Wirtscha ftromanze_Taschenbuch"}
0	Spaß mit Problemen	Taschenb ch	{"Spaß_Taschenbuch", "mit_Taschenbuch", "Probleme n_Taschenbuch"}

Das folgende Beispiel zeigt, wie Sie die kartesische Transformation auf var1 und var2 anwenden:

```
cartesian(var1, var2)
```

Neuordnung von Daten

Mit der Funktionalität Neuordnung von Daten können Sie eine Datenquelle erstellen, die lediglich auf einem Teil der Eingabedaten basiert, auf die sie verweist. Wenn Sie beispielsweise mit dem Assistenten „ML-Modell erstellen“ in der Amazon ML-Konsole ein ML-Modell erstellen und die Standardauswertungsoption wählen, reserviert Amazon ML automatisch 30% Ihrer Daten für die ML-Modell-Evaluierung und verwendet die anderen 70% für Schulungen. Diese Funktionalität wird durch die Funktion Data Rearrangement von Amazon ML ermöglicht.

Wenn Sie die Amazon ML-API verwenden, um Datenquellen zu erstellen, können Sie angeben, auf welchem Teil der Eingabedaten eine neue Datenquelle basieren soll. Sie tun dies, indem Sie Anweisungen im DataRearrangement Parameter an, oder übergeben.

CreateDataSourceFromS3 CreateDataSourceFromRedshift CreateDataSourceFromRDS APIs Der Inhalt der DataRearrangement Zeichenfolge ist eine JSON-Zeichenfolge, die die Anfangs- und Endpositionen Ihrer Daten enthält, ausgedrückt als Prozentsätze, ein Komplement-Flag und eine Aufteilungsstrategie. Die folgende DataRearrangement Zeichenfolge gibt beispielsweise an, dass die ersten 70% der Daten zur Erstellung der Datenquelle verwendet werden:

```
{
  "splitting": {
    "percentBegin": 0,
    "percentEnd": 70,
    "complement": false,
    "strategy": "sequential"
  }
}
```

DataRearrangement Parameter

Verwenden Sie die folgenden Parameter, um zu ändern, wie Amazon ML eine Datenquelle erstellt.

PercentBegin (Fakultativ)

Verwenden Sie `percentBegin`, um anzugeben, wo die Daten für die Datenquelle beginnen. Wenn Sie `percentBegin` und nicht `percentEnd` angeben, bezieht Amazon ML bei der Erstellung der Datenquelle alle Daten mit ein.

Gültige Werte sind 0 bis einschließlich 100.

PercentEnd (Fakultativ)

Verwenden Sie `percentEnd`, um anzugeben, wo die Daten für die Datenquelle enden. Wenn Sie `percentBegin` und nicht `percentEnd` angeben, bezieht Amazon ML bei der Erstellung der Datenquelle alle Daten mit ein.

Gültige Werte sind 0 bis einschließlich 100.

Complement (Optional)

Der `complement` Parameter weist Amazon ML an, die Daten, die nicht im Bereich von `percentBegin` bis `percentEnd` enthalten sind, zur Erstellung einer Datenquelle `percentEnd` zu verwenden. Der Parameter `complement` ist nützlich, wenn Sie ergänzende Datenquellen zu Schulungs- und Auswertungszwecken erstellen müssen. Um eine ergänzende Datenquelle zu erstellen, verwenden Sie die gleichen Werte für `percentBegin` und `percentEnd` mit dem Parameter `complement`.

Die beiden folgenden Datenquellen teilen beispielsweise keine Daten und können verwendet werden, um ein Modell zu schulen und auszuwerten. Die erste Datenquelle besteht aus 25 % und die zweite aus 75 % der Daten.

Auswertungsdatenquelle:

```
{
  "splitting":{
    "percentBegin":0,
    "percentEnd":25
  }
}
```

Schulungsdatenquelle:

```
{
  "splitting":{
    "percentBegin":0,
    "percentEnd":25,
    "complement":"true"
  }
}
```

Gültige Werte sind `true` und `false`.

Strategy (Optional)

Verwenden Sie den Parameter, um zu ändern, wie Amazon ML die Daten für eine Datenquelle aufteilt. `strategy`

Der Standardwert für den `strategy` Parameter ist `sequential`, was bedeutet, dass Amazon ML alle Datensätze zwischen den `percentEnd` Parametern `percentBegin` und für die Datenquelle in der Reihenfolge verwendet, in der die Datensätze in den Eingabedaten erscheinen.

Die folgenden beiden `DataRearrangement`-Zeilen sind Beispiele für sequentiell geordnete Schulungs- und Auswertungsdatenquellen:

Auswertungsdatenquelle: `{"splitting":{"percentBegin":70, "percentEnd":100, "strategy":"sequential"}}`

Schulungsdatenquelle: `{"splitting":{"percentBegin":70, "percentEnd":100, "strategy":"sequential", "complement":"true"}}`

Wenn Sie eine Datenquelle aus einer Zufallsauswahl von Daten erstellen möchten, setzen Sie den Parameter `strategy` auf `random` und geben Sie eine Zeichenfolge an, die als Ausgangswert für die zufällige Datenaufteilung verwendet wird (z. B. den S3-Pfad zu Ihren

Daten als zufällige Seed-Zeichenfolge). Wenn Sie sich für die Strategie der zufälligen Aufteilung entscheiden, weist Amazon ML jeder Datenzeile eine Pseudo-Zufallszahl zu und wählt dann die Zeilen aus, denen eine Zahl zwischen und zugewiesen ist. `percentBegin` `percentEnd` Pseudo-Zufallszahlen werden mit dem Byte-Offset als Seed zugewiesen, sodass die Datenergebnisse anders aufgeteilt werden. Alle vorhandenen Reihenfolgen bleiben erhalten. Die zufällige Aufteilungsstrategie stellt sicher, dass die Variablen der Schulungs- und Auswertungsdaten gleichmäßig verteilt werden. Dies ist nützlich, wenn die Eingabedaten möglicherweise eine implizite Sortierreihenfolge besitzen, was ansonsten dazu führen würde, dass Schulungs- und Auswertungsdatenquellen nicht-ähnliche Datensätze enthalten würden.

Die folgenden beiden `DataRearrangement`-Zeilen sind Beispiele für nicht-sequentiell geordnete Schulungs- und Auswertungsdatenquellen:

Auswertungsdatenquelle:

```
{
  "splitting":{
    "percentBegin":70,
    "percentEnd":100,
    "strategy":"random",
    "strategyParams": {
      "randomSeed":"RANDOMSEED"
    }
  }
}
```

Schulungsdatenquelle:

```
{
  "splitting":{
    "percentBegin":70,
    "percentEnd":100,
    "strategy":"random",
    "strategyParams": {
      "randomSeed":"RANDOMSEED"
    }
    "complement":"true"
  }
}
```

Gültige Werte sind `sequential` und `random`.

(Optional) Strategie: RandomSeed

Amazon ML verwendet RandomSeed, um die Daten aufzuteilen. Der Standard-Seed für die API ist eine leere Zeichenfolge. Um einen Seed für die zufällige Aufteilungsstrategie anzugeben, übergeben Sie eine Zeichenfolge. Weitere Informationen zu Random Seeds finden Sie [Zufällige Aufteilung Ihrer Daten](#) im Amazon Machine Learning Developer Guide.

Beispielcode, der demonstriert, wie die Kreuzvalidierung mit Amazon ML verwendet wird, finden Sie unter [Github Machine Learning Samples](#).

Evaluation von ML-Modellen

Sie sollten ein Modell evaluieren, um festzustellen, ob es das Ziel in neuen und zukünftigen Daten gut voraussagen kann. Da künftigen Instances unbekannt Zielwerte haben, müssen Sie die Richtigkeitsmetrik des ML-Modells für Daten prüfen, deren Zielantwort Sie bereits kennen, und diese Bewertung als Proxy für die Voraussagerichtigkeit für zukünftige Daten verwenden.

Um ein Modell ordnungsgemäß zu bewerten, sollten Sie eine Stichprobe der Daten zurückhalten, die mit dem Ziel (Referenzdaten) aus der Schulungsdatenquelle gekennzeichnet wurden. Das Testen der Voraussagerichtigkeit eines ML-Modell mit denselben Daten, die für die Schulung verwendet wurden, ist nicht sinnvoll, weil sich Modelle an spezifische Schulungsdaten „erinnern“ anstatt sie zu verallgemeinern. Sobald Sie die Schulung des ML-Modells abgeschlossen haben, senden Sie die dem Modell die zurückgehaltenen Beobachtungen, deren Zielwerte Sie kennen. Anschließend vergleichen Sie die vom ML-Modell zurückgegebenen Voraussagen mit dem bekannten Zielwert. Schließlich berechnen Sie eine Zusammenfassungsmetrik, die Ihnen sagt, wie gut die prognostizierten und tatsächlichen Werte übereinstimmen.

In Amazon ML evaluieren Sie ein ML-Modell, indem Sie eine Bewertung erstellen. Um eine Bewertung für ein ML-Modell zu erstellen, benötigen Sie ein zu bewertendes ML-Modell und gekennzeichnete Daten, die nicht für Schulungszwecke verwendet wurden. Erstellen Sie zunächst eine Datenquelle für die Auswertung, indem Sie eine Amazon ML-Datenquelle mit den ausgebliebenen Daten erstellen. Die bei der Evaluation verwendeten Daten müssen dasselbe Schema aufweisen wie die in der Schulung verwendeten Daten, und sie müssen tatsächlichen Werte für die Zielvariable enthalten.

Wenn sich all Ihre Daten in einer einzigen Datei oder einem einzigen Verzeichnis befinden, können Sie die Amazon ML-Konsole verwenden, um die Daten aufzuteilen. Der Standard-Pfad im Create ML-Modellassistenten trennt die eingegebenen Datenquelle und verwendet die ersten 70 % als Schulungsdatenquelle sowie die verbleibenden 30 % als Evaluationsdatenquelle. Sie können das Teilungsverhältnis auch anpassen, indem Sie die Option Custom im Create ML-Modellassistenten verwenden, mit der Sie ein zufälliges Beispiel von 70 % für Schulungen und die verbleibenden 30 % für die Evaluation verwenden können. Um weitere benutzerdefinierte Teilungsverhältnisse anzugeben, verwenden Sie die Zeichenfolge zur Neuerstellung von Daten in der [Create Datasource](#)-API. Sobald Sie über eine Evaluationsdatenquelle und ein ML-Modell verfügen, können Sie eine Bewertung erstellen und die Ergebnisse davon überprüfen.

Themen

- [Einblicke in ML-Modelle](#)
- [Einblicke in binäre Modelle](#)
- [Einblicke in Mehrklassen-Modelle](#)
- [Regressionsmodell-Einblicke](#)
- [Verhindern von Overfitting](#)
- [Kreuzvalidierung](#)
- [Auswertungswarnungen](#)

Einblicke in ML-Modelle

Zur Auswertung eines ML-Modells bietet Amazon ML eine Metrik nach Branchenstandard sowie eine Reihe von Einblicken, um die Prognosegenauigkeit Ihres Modells zu prüfen. In Amazon ML umfasst das Ergebnis einer Auswertung Folgendes:

- Eine Prognosegenauigkeits-Metrik, einen Bericht zum Gesamterfolg des Modells
- Visualisierungen, mit denen die Genauigkeit Ihres Modells über die Prognosegenauigkeits-Metrik hinaus dargestellt wird
- Die Möglichkeit, die Auswirkungen der Einstellung eines Schwellenwerts zu überprüfen (nur für binäre Klassifizierung)
- Warnungen zu Kriterien, um die Gültigkeit der Auswertung zu überprüfen

Die Wahl der Metrik und Visualisierung ist abhängig von der Art des ML-Modells, das Sie testen. Es ist wichtig, diese Visualisierungen zu überprüfen, um zu entscheiden, wann Ihr Modell gut genug ist, um Ihre geschäftlichen Anforderungen zu erfüllen.

Einblicke in binäre Modelle

Interpretieren der Voraussagen

Die tatsächliche Ausgabe von vielen binären Klassifizierungsalgorithmen ist eine Voraussagepunktzahl. Die Punktzahl gibt die Sicherheit des Systems an, dass die angegebene Beobachtung der positiven Klasse angehört (der tatsächliche Zielwert ist 1). Binäre Klassifizierungsmodelle in Amazon ML geben eine Punktzahl aus, die zwischen 0 und 1 liegt. Als Verbraucher dieser Bewertung können Sie die Punktzahl interpretieren, indem Sie einen

Klassifizierungsschwellenwert oder Grenzwert festlegen und die Punktzahl damit vergleichen, um zu entscheiden, ob die Beobachtung als 1 oder 0 klassifiziert wird. Alle Beobachtungen mit Ergebnissen über dem Grenzwert werden als "Ziel = 1" vorausgesagt; Beobachtungen mit Ergebnissen unter dem Grenzwert werden als "Ziel = 0" vorausgesagt.

In Amazon ML liegt der Standard-Score-Grenzwert bei 0,5. Sie können diesen Grenzwert Ihren geschäftlichen Anforderungen entsprechend ändern. Sie können die Visualisierungen in der Konsole verwenden, um zu verstehen, wie sich die Auswahl des Grenzwerts auf Ihre Anwendung auswirkt.

Messung der ML-Modellgenauigkeit

Amazon ML bietet eine branchenübliche Genauigkeitsmetrik für binäre Klassifizierungsmodelle mit der Bezeichnung Area Under the (Receiver Operating Characteristic) Curve (AUC). AUC misst die Fähigkeit des Modells, eine höhere Bewertung für positive Beispiele im Vergleich zu negativen Beispielen vorherzusagen. Da es unabhängig vom Grenzwert ist, bekommen Sie ein Gefühl für die Voraussagegenauigkeit Ihres Modells aus der AUC-Metrik, ohne einen Schwellenwert auszuwählen.

Die AUC-Metrik gibt einen Dezimalwert zwischen 0 und 1 zurück. AUC-Werte nahe 1 weisen auf ein sehr genaues ML-Modell hin. Werte um 0,5 weisen auf ein ML-Modell hin, das nicht besser als zufälliges Raten ist. Werte um 0 sind ungewöhnlich und weisen in der Regel auf ein Problem mit den Daten hin. Im Wesentlichen gibt ein AUC in der Nähe von 0 an, dass das ML-Modell die richtigen Muster gelernt hat, aber diese verwendet, um Voraussagen zu geben, die im Gegensatz zur Realität stehen (0 wird als 1 vorhergesagt und umgekehrt). Weitere Informationen zur AUC finden Sie auf der Seite [Receiver Operating Characteristic](#) in Wikipedia.


Die grundlegende AUC-Metrik für ein binäres Modell ist 0,5. Dies ist der Wert für ein hypothetisches ML-Modell, das zufällig eine Antwort von 1 oder 0 voraussagt. Ihr binäres ML-Modell sollte besser als das funktionieren, um einen Mehrwert zu bieten.

Verwenden der Performance-Visualisierung

Um die Genauigkeit des ML-Modells zu überprüfen, können Sie sich die Grafiken auf der Bewertungsseite der Amazon ML-Konsole ansehen. Diese Seite zeigt Ihnen zwei Histogramme: a) ein Histogramm der Punktzahlen für die tatsächlichen positiven Ergebnisse (das Ziel ist 1) und b) ein Histogramm der Punktzahlen für die tatsächlichen negativen Ergebnisse (das Ziel ist 0) in den Auswertungsdaten.

Ein ML-Modell mit guter Voraussagegenauigkeit sagt höhere Ergebnisse für die tatsächliche 1 und niedrigere Ergebnisse für die tatsächliche 0 voraus. Ein perfektes Modell zeigt in den zwei Histogramme an den zwei verschiedenen Enden der X-Achse, dass alle tatsächlichen

positiven Ergebnisse hohe Punktzahlen und die tatsächlichen negativen Ergebnisse niedrige Punktzahlen haben. ML-Modelle machen jedoch auch Fehler, und ein typisches Diagramm zeigt Überschneidungen an bestimmten Punktzahlen. Ein extrem schlechtes Modell unterscheidet nicht zwischen den positiven und negativen Klassen, und beide Klassen haben vorwiegend überlappende Histogramme.



Anhand von Visualisierungen können Sie die Anzahl der Voraussagen bestimmen, die in zwei Arten von richtigen Voraussagen und zwei Arten von falschen Voraussagen unterteilt werden.

Richtige Voraussagen

- Richtig positiv (TP): Amazon ML hat den Wert als 1 vorhergesagt, und der wahre Wert ist 1.
- True Negative (TN): Amazon ML hat den Wert als 0 vorhergesagt, und der wahre Wert ist 0.

Falsche Voraussagen

- Falsch positiv (FP): Amazon ML hat den Wert als 1 vorhergesagt, aber der wahre Wert ist 0.
- Falsch negativ (FN): Amazon ML hat den Wert als 0 vorhergesagt, aber der wahre Wert ist 1.

i Note

Die Anzahl von TP, TN, FP und FN richtet sich nach dem ausgewählten Schwellenwert, und die Optimierung für eine dieser Zahlen würde einen Kompromiss bei den anderen bedeuten. Eine hohe Anzahl von führt in der TPs Regel zu einer hohen Anzahl von FPs und einer niedrigen Anzahl von TNs.

Anpassen des Ergebnisgrenzwerts

ML-Modelle arbeiten mittels Generierung von numerischen Voraussagepunktzahlen und Anwenden eines Grenzwertes, um diese Punktzahlen in binäre 0/1-Etiketten zu konvertieren. Durch das Ändern des Grenzwerts können Sie das Verhalten des Modells anpassen, wenn es einen Fehler macht. Auf der Bewertungsseite in der Amazon ML-Konsole können Sie die Auswirkungen verschiedener Score-Grenzwerte überprüfen und den Score-Grenzwert speichern, den Sie für Ihr Modell verwenden möchten.

Beachten Sie bei der Anpassung des Schwellenwerts für den Ergebnisgrenzwert den Kompromiss zwischen den beiden Arten von Fehlern. Wenn Sie den Grenzwert nach links verschieben, werden mehr positive Ergebnisse erfasst, aber der Kompromiss besteht in der Erhöhung der Anzahl von falschen Positivangaben. Verschieben nach rechts ergibt weniger falsche Positivangaben, aber der Kompromiss ist, dass einige tatsächliche positive Ergebnisse nicht erfasst werden. Für die Voraussageanwendung können Sie entscheiden, welche Art von Fehler eher akzeptabel ist, indem Sie einen geeigneten Ergebnisgrenzwert festlegen.

Überprüfen von erweiterten Metriken

Amazon ML bietet die folgenden zusätzlichen Metriken zur Messung der Vorhersagegenauigkeit des ML-Modells: Genauigkeit, Präzision, Erinnerungsvermögen und Falsch-Positiv-Rate.

Accuracy

Die Richtigkeit (ACC) misst den Anteil der richtigen Voraussagen. Der Bereich liegt zwischen 0 und 1. Ein größerer Wert gibt eine bessere Richtigkeit an:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN}$$

Genauigkeit

Genauigkeit misst den Anteil der tatsächlichen Positiva unter den Beispielen, die als positiv vorausgesagt wurden. Der Bereich liegt zwischen 0 und 1. Ein größerer Wert gibt eine bessere Richtigkeit an:

$$Precision = \frac{TP}{TP + FP}$$

Wiedererkennung

Wiedererkennung misst den Anteil der tatsächlichen Positiva, die als positiv vorausgesagt wurden. Der Bereich liegt zwischen 0 und 1. Ein größerer Wert gibt eine bessere Richtigkeit an:

$$Recall = \frac{TP}{TP + FN}$$

Falschpositivrate

Die Falschpositivrate (FPR) misst den Anteil falscher Alarme oder den Anteil tatsächlicher negativer Ergebnisse, die als positiv vorhergesagt wurden. Der Bereich liegt zwischen 0 und 1. Ein kleinerer Wert gibt eine bessere Richtigkeit der Voraussage an:

$$FPR = \frac{FP}{FP + TN}$$

Abhängig von Ihrem Unternehmensproblem benötigen Sie vielleicht eher ein Modell, das für eine bestimmte Teilmenge dieser Metriken gut funktioniert. Zwei Unternehmensanwendungen können beispielsweise sehr unterschiedliche Anforderungen an ihr ML-Modell haben:

- Eine Anwendung muss vielleicht sehr sicher sein, dass die positiven Voraussagen tatsächlich positiv sind (hohe Präzision) und kann es verkraften, dass einige positive Beispiele falsch als negativ klassifiziert werden (moderate Wiedererkennung).
- Eine andere Anwendung soll so viele positive Beispiele wie möglich korrekt voraussagen (hohe Wiedererkennung) und nimmt es in Kauf, dass einige negative Beispiele falsch als positiv klassifiziert werden (moderate Genauigkeit).

Mit Amazon ML können Sie einen Punktegrenzwert wählen, der einem bestimmten Wert einer der vorherigen erweiterten Metriken entspricht. Außerdem werden die Kompromisse durch Optimierung für eine der Metriken angezeigt. Wenn Sie beispielsweise einen Grenzwert auswählen, der eine hohe Genauigkeit erzielt, erhalten Sie dafür in der Regel eine geringere Wiedererkennung.

Note

Sie müssen den Ergebnispunktgrenzwert speichern, damit er für die Klassifizierung künftiger Voraussagen Ihrer ML-Modelle wirksam wird.

Einblicke in Mehrklassen-Modelle

Interpretieren der Voraussagen

Die tatsächliche Ausgabe eines Mehrklassen-Klassifizierungsalgorithmus ist ein Satz von Voraussagepunktzahlen. Die Punktzahl gibt die Gewissheit des Modells an, dass die angegebene Beobachtung zu jeder der Klassen gehört. Im Gegensatz zu binären Klassifizierungsproblemen müssen Sie für Voraussagen keinen Ergebnismittelwert auswählen. Die vorhergesagte Antwort ist die Klasse (z. B. Bezeichnung) mit der höchsten vorhergesagten Punktzahl.

Messung der ML-Modellgenauigkeit

Typische Metriken, die in Mehrklassen-Modellen verwendet werden, sind dieselben Metriken, die auch bei der binären Klassifizierung verwendet werden, nachdem über alle Klassen hinweg der Durchschnitt hierfür berechnet wurde. In Amazon ML wird der makrodurchschnittliche F1-Wert verwendet, um die Vorhersagegenauigkeit einer Multiklassen-Metrik zu bewerten.

F1-Bewertung mit Makro-Durchschnitt

Die F1-Bewertung ist eine binäre Klassifizierungsmetrik, die sowohl die binäre Metrikpräzision als auch Rückruf berücksichtigt. Sie ist das harmonische Mittel zwischen Präzision und Rückruf. Der Bereich liegt zwischen 0 und 1. Ein größerer Wert gibt eine bessere Richtigkeit an:

$$F1 \text{ score} = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}}$$

Die F1-Bewertung mit Makro-Durchschnitt ist der nicht gewichtete Durchschnitt der F1-Bewertung über alle Klassen in dem Mehrklassen-Modell. Sie berücksichtigt nicht die Frequenz des Auftretens der Klassen im Auswertungsdatensatz. Ein größerer Wert gibt eine bessere prädiktive Richtigkeit an: Das folgende Beispiel zeigt K Klassen in der Auswertungsdatenquelle:

$$\text{Macro average F1 score} = \frac{1}{K} \sum_{k=1}^K \text{F1 score for class } k$$

Grundlegende F1-Bewertung mit Makro-Durchschnitt


Amazon ML bietet eine Basismetrik für Mehrklassenmodelle. Es handelt sich um die F1-Bewertung mit Makro-Durchschnitt für ein hypothetisches Mehrklassen-Modell, das immer die häufigste Klasse als Antwort vorhersagen würde. Wenn Sie beispielsweise das Genre eines Films vorhersagen

würden, und das gängigste Genre in Ihren Schulungsdaten ist "Romanze", so würde das grundlegende Modell das Genre immer als "Romanze" vorhersagen. Sie würden das ML-Modell mit dieser Grundlage vergleichen, um auszuwerten, ob das ML-Modell besser als ein ML-Modell ist, das diese konstante Antwort vorhersagt.

Verwenden der Performance-Visualisierung

Amazon ML bietet eine Konfusionsmatrix, um die Genauigkeit von Prognosemodellen zur Klassifizierung mehrerer Klassen zu visualisieren. Die Konfusionsmatrix veranschaulicht in einer Tabelle die Anzahl oder den Prozentwert richtiger und falscher Voraussagen für jede Klasse, indem die vorhergesagte Klasse einer Beobachtung mit der tatsächlichen Klasse verglichen wird.

Wenn Sie beispielsweise versuchen, einen Film in ein Genre zu klassifizieren, sagt das prädiktive Modell möglicherweise hervor, dass das Genre (Klasse) "Romanze" ist. Der tatsächliche Genre ist jedoch möglicherweise "Thriller". Wenn Sie die Genauigkeit eines ML-Modells zur Klassifizierung mehrerer Klassen bewerten, identifiziert Amazon ML diese Fehlklassifizierungen und zeigt die Ergebnisse in der Konfusionsmatrix an, wie in der folgenden Abbildung dargestellt.



Die folgenden Informationen werden in einer Konfusionsmatrix angezeigt:

- Anzahl richtiger und falscher Voraussagen für jede Klasse: Jede Zeile in der Konfusionsmatrix entspricht den Metriken für eine der tatsächlichen Klassen. In der ersten Zeile wird beispielsweise angezeigt, dass für Filme, die sich eigentlich im Genre "Romanze" befinden, die Voraussagen des Mehrklassen-ML-Modells in über 80 % der Fälle korrekt sind. Das Genre "Thriller" wird in weniger als 20 % der Fälle falsch vorhergesagt, genau wie das Genre "Abenteuer".
- Klassenweise F1-Bewertung: Die letzte Spalte zeigt die F1-Bewertung für die einzelnen Klassen an.
- Echte Klassenfrequenzen in den Auswertungsdaten: In der vorletzten Spalte wird angezeigt, dass im Auswertungsdatensatz 57,92 % der Beobachtungen in den Auswertungsdaten unter "Romanze" fallen, 21,23 % unter "Thriller" und 20,85 % unter "Abenteuer".
- Prognostizierte Klassenhäufigkeiten für die Bewertungsdaten: Die letzte Zeile zeigt die Häufigkeit der einzelnen Klassen in den Vorhersagen. 77,56% der Beobachtungen werden als Romanze, 9,33% als Thriller und 13,12% als Abenteuer vorhergesagt.

Die Amazon ML-Konsole bietet eine visuelle Anzeige für bis zu 10 Klassen in der Konfusionsmatrix, die in der Reihenfolge der häufigsten bis seltensten Klassen in den Bewertungsdaten aufgeführt sind. Wenn Ihre Bewertungsdaten mehr als 10 Klassen enthalten, werden Ihnen die 9 am häufigsten vorkommenden Klassen in der Konfusionsmatrix angezeigt, und alle anderen Klassen werden in einer Klasse namens „Andere“ zusammengefasst. Amazon ML bietet auch die Möglichkeit, die vollständige Konfusionsmatrix über einen Link auf der Seite mit Multiklassen-Visualisierungen herunterzuladen.

Regressionsmodell-Einblicke

Interpretieren der Voraussagen

Die Ausgabe eines ML-Regressionsmodells ist ein numerischer Wert für die Modellvoraussage des Ziels. Wenn Sie beispielsweise Wohnungspreise voraussagen, kann die Voraussage des Modells ein Wert wie 254 013 sein.

Note

Der Ergebnisbereich der Voraussagen muss nicht mit dem Bereich des Ziels in den Schulungsdaten übereinstimmen. Nehmen wir beispielsweise an, dass Sie Wohnungspreise voraussagen und das Ziel in den Schulungsdaten Werte zwischen 0 und 450 000 hatte. Das vorausgesagte Ziel muss nicht in diesem Bereich liegen. Es kann jeden beliebigen positiven

Wert (über 450 000) oder negativen Wert (kleiner als 0) haben. Es ist wichtig, einen Plan für die Handhabung von Voraussagewerten außerhalb des akzeptablen Bereichs für Ihre Anwendung zu haben.

Messung der ML-Modellgenauigkeit

Für Regressionsaufgaben verwendet Amazon ML die RMSE-Metrik (Root Mean Square Error, mittlerer quadratischer Vorhersagefehler) nach Branchenstandard. Es handelt sich um ein Maß für die Abweichung zwischen dem vorausgesagten numerischen Ziel und der tatsächlichen numerischen Antwort (Referenzdaten). Je kleiner der RMSE-Wert ist, umso höher ist die Voraussagegenauigkeit des Modells. Ein Modell mit absolut richtigen Voraussagen hat einen RMSE von 0. Das folgende Beispiel zeigt Evaluierungsdaten mit n Datensätzen:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{actual target} - \text{predicted target})^2}$$


Basis-RMSE

Amazon ML bietet eine Basis-Metrik für Regressionsmodelle. Dabei handelt es sich um den RMSE für ein hypothetisches Regressionsmodell, das immer den Durchschnitt des Ziel als Antwort voraussagt. Wenn Sie beispielsweise das Alter eines Hauskäufer voraussagen und das Durchschnittsalter für die Beobachtungen in Ihren Schulungsdaten 35 ist, sagt das Basismodell immer 35 als Antwort voraus. Sie können Ihr ML-Modell dann mit diesem Basismodell vergleichen, um zu ermitteln, ob Ihr ML-Modell besser ist als ein ML-Modell, das diese konstante Antwort vorhersagt.

Verwenden der Performance-Visualisierung

Es ist eine gängige Vorgehensweise, den Rest bei Regressionsproblemen zu überprüfen. Ein Rest für eine Beobachtung in der Evaluierungsdaten ist der Unterschied zwischen dem wahren Ziel und dem vorausgesagten Ziel. Reste stellen den Teil des Ziels dar, den das Modell nicht voraussagen konnte. Ein positiver Rest deutet darauf hin, dass das Modell das Ziel unterschätzt (das tatsächliche Ziel ist größer als das vorausgesagte Ziel). Ein negativer Rest deutet auf eine Überbewertung hin (das tatsächliche Ziel ist kleiner als das vorausgesagte Ziel). Das Histogramm der Reste für die Evaluierungsdaten deutet bei glockenförmiger Anordnung und Zentrierung auf Null darauf hin, dass das Modell willkürliche Fehler macht und keinen spezifischen Zielwertbereich systematisch über- oder unterschätzt. Wenn die Reste keine Glockenform mit Zentrierung auf Null bilden, gibt es eine gewisse

Struktur bei den Voraussagefehlern des Modells. Das Hinzufügen von weiteren Variablen kann es dem Modell ermöglichen, Muster zu erfassen, die vom aktuellen Modell nicht erfasst werden. Die folgende Abbildung zeigt Reste, die nicht um Null zentriert sind.



Verhindern von Overfitting

Beim Erstellen und Schulen eines ML-Modells soll das Modell ausgewählt werden, das die besten Voraussagen liefert, das bedeutet, es wird das Modell mit den besten Einstellungen (ML-Modelleinstellungen oder Hyperparameter) gewählt. In Amazon Machine Learning können Sie vier Hyperparameter festlegen: Anzahl der Durchläufe, Regularisierung, Modellgröße und Shuffle-Typ. Wenn Sie jedoch Modellparametereinstellungen wählen, welche die „beste“ Voraussageleistung für Evaluationsdaten produzieren, können Sie Ihr Modell leicht „überanpassen“. Overfitting tritt auf, wenn ein Modell über gelernte Muster verfügt, die bei der Schulung und in Evaluationsdatenquellen auftreten, diese aber nicht auf allgemein auf Daten angewendet werden können. Dies geschieht häufig, wenn die Schulungsdaten alle Daten bei der Evaluation verwendeten Daten umfassen. Ein überangepasstes Modell zeigt bei einer Evaluation eine hervorragende Leistung, versagt jedoch bei der Anwendung auf ungesehene Daten.

Um zu verhindern, dass ein überangepasstes Modell als beste Modell ausgewählt wird, können Sie zusätzliche Daten reservieren, um die Leistung des ML-Modells zu validieren. Sie können Ihre Daten beispielsweise in Blöcke von 60 Prozent für Schulungen, 20 Prozent für die Bewertung und weitere 20 Prozent für die Validierung aufteilen. Nachdem Sie die Modellparameter ausgewählt haben, die für die Bewertungsdaten gut funktionieren, führen Sie eine zweite Bewertung mit den Validierungsdaten durch, um zu sehen, wie gut die ML-Modell die Validierungsdaten verarbeitet. Wenn das Modell Ihren Erwartungen hinsichtlich der Validierungsdaten entspricht, passt es die Daten nicht übermäßig an.


Unter Verwendung einer dritten Gruppe von Daten für die Validierung können Sie geeignete ML-Modellparameter wählen, um eine Überanpassung zu verhindern. Durch das Zurückhalten von Daten für Evaluation und Validierung stehen jedoch weniger Daten für die Schulung zur Verfügung. Dies ist besonders bei geringen Datenmengen ein Problem, da stets so viele Daten wie möglich für die Schulung verwendet werden sollten. Um dieses Problem zu lösen, können Sie eine Cross-Validierung durchführen. Weitere Informationen zu Cross-Validierungen finden Sie unter [Kreuzvalidierung](#).

Kreuzvalidierung

Die Kreuzvalidierung ist eine Methode zur Bewertung von ML-Modellen, indem Sie mehrere ML-Modelle mit Teilsätzen der verfügbaren Eingabedaten schulen und diese in der ergänzenden Teilmenge der Daten auswerten. Verwenden Sie die Kreuzvalidierung, um eine Überanpassung zu erkennen, d. h. wenn ein Muster nicht verallgemeinert wird.

In Amazon ML können Sie die K-fache Kreuzvalidierungsmethode verwenden, um eine Kreuzvalidierung durchzuführen. Bei der k-fachen Kreuzvalidierung teilen Sie die Eingabedaten in k Teilmengen von Daten auf (auch bekannt als Falten). Sie trainieren ein ML-Modell mit allen Teilmengen außer einer ($k-1$) und evaluieren das Modell dann anhand der Teilmenge, die nicht für das Training verwendet wurde. Dieser Vorgang wird k-Mal wiederholt, wobei jedes Mal eine andere Teilmenge für die Auswertung verwendet wird (die für Schulungen ausgeschlossen ist).

Das folgende Diagramm zeigt ein Beispiel der Schulungsteilmengen und der ergänzenden Auswertungsteilmengen, die für jedes der vier Modelle generiert werden, die während einer 4-fachen Kreuzvalidierung erstellt und geschult werden. Modell 1 verwendet die ersten 25 Prozent der Daten für die Auswertung und die verbleibenden 75 Prozent für die Schulung. Modell 2 verwendet die zweite Teilmenge von 25 Prozent (25 Prozent bis 50 Prozent) für die Auswertung und die verbleibenden drei Teilmengen der Daten für Schulungen und so weiter.



Jedes Modell wird mithilfe der ergänzenden Datenquellen geschult und ausgewertet – die Daten in der Auswertungsdatenquelle umfassen und sind auf alle Daten beschränkt, die sich nicht in der Schulungsdatenquelle befinden. Sie erstellen Datenquellen für jede dieser Teilmengen mit dem `DataRearrangement` Parameter im `createDataSourceFromS3`, `createDataSourceFromRedShift` oder `createDataSourceFromRDS` APIs. Geben Sie im Parameter `DataRearrangement` an, welche Teilmenge von Daten in eine Datenquelle eingeschlossen werden soll, indem Sie angeben, wo jedes Segment angefangen und beendet werden soll. Um die ergänzenden Datenquellen zu erstellen, die für eine 4000-fache Kreuzvalidierung erforderlich sind, geben Sie den Parameter `DataRearrangement` wie im folgenden Beispiel an:

Modell 1:

Auswertungsdatenquelle:

```
{"splitting":{"percentBegin":0, "percentEnd":25}}
```

Schulungsdatenquelle:

```
{"splitting":{"percentBegin":0, "percentEnd":25, "complement":"true"}}
```

Modell 2:

Auswertungsdatenquelle:

```
{"splitting":{"percentBegin":25, "percentEnd":50}}
```

Schulungsdatenquelle:

```
{"splitting":{"percentBegin":25, "percentEnd":50, "complement":"true"}}
```

Modell 3:

Auswertungsdatenquelle:

```
{"splitting":{"percentBegin":50, "percentEnd":75}}
```

Schulungsdatenquelle:

```
{"splitting":{"percentBegin":50, "percentEnd":75, "complement":"true"}}
```

Modell 4:

Auswertungsdatenquelle:

```
{"splitting":{"percentBegin":75, "percentEnd":100}}
```

Schulungsdatenquelle:

```
{"splitting":{"percentBegin":75, "percentEnd":100, "complement":"true"}}
```

Durch die Durchführung einer vierfachen Kreuzvalidierung werden vier Modelle generiert: vier Datenquellen zum Trainieren der Modelle, vier Datenquellen zur Auswertung der Modelle und vier Evaluierungen, eine für jedes Modell. Amazon ML generiert für jede Bewertung eine Modelleistungsmetrik. Bei einer 4-fachen Kreuzvalidierung für ein binäres Klassifizierungsproblem erstellt jede der Auswertungen einen Bericht für eine sogenannte Area Under a Curve (AUC). Die Gesamtleistung erhalten Sie, indem Sie den Durchschnitt der vier AUC-Metriken berechnen. Weitere Informationen zur AUC-Metrik finden Sie unter [Messung der ML-Modellgenauigkeit](#).

Einen Beispielcode, der zeigt, wie eine Kreuzvalidierung erstellt und der Durchschnitt der Modellwerte ermittelt wird, finden Sie im [Amazon ML-Beispielcode](#).

Anpassen Ihrer Modelle

Nachdem Sie die Modelle kreuzvalidiert haben, können Sie die Einstellungen für das nächste Modell anpassen, wenn das Modell nicht Ihren Standards entspricht. Weitere Informationen zur Überanpassung finden Sie unter [Modellanpassung: Unteranpassung vs. Überanpassung](#). Weitere Informationen zur Regularisation finden Sie unter [Regularisation](#). Weitere Informationen zum Ändern

der Regularisationseinstellungen finden Sie unter [Erstellen eines ML-Modells mit benutzerdefinierten Optionen](#).

Auswertungswarnungen

Amazon ML bietet Einblicke, anhand derer Sie überprüfen können, ob Sie das Modell richtig bewertet haben. Wenn eines der Validierungskriterien durch die Bewertung nicht erfüllt wird, warnt Sie die Amazon ML-Konsole, indem sie das Validierungskriterium, gegen das verstoßen wurde, wie folgt anzeigt.

- Auswertung des ML-Modells erfolgt mit zurückgehaltenen Daten

Amazon ML warnt Sie, wenn Sie dieselbe Datenquelle für Schulungen und Evaluierungen verwenden. Wenn Sie Amazon ML verwenden, um Ihre Daten aufzuteilen, erfüllen Sie dieses Gültigkeitskriterium. Wenn Sie Amazon ML nicht verwenden, um Ihre Daten aufzuteilen, stellen Sie sicher, dass Sie Ihr ML-Modell mit einer anderen Datenquelle als der Trainingsdatenquelle auswerten.

- Genügend Daten wurden für die Auswertung des Voraussagemodells verwendet

Amazon ML warnt Sie, wenn die Anzahl der Beobachtungen/Datensätze in Ihren Bewertungsdaten weniger als 10% der Anzahl der Beobachtungen in Ihrer Trainingsdatenquelle beträgt. Um Ihr Modell korrekt zu bewerten, ist es wichtig, ein ausreichend großes Datenbeispiel bereitzustellen. Mit diesem Kriterium wird überprüft, ob Sie genügend Daten verwenden. Die Datenmenge, die für die Bewertung Ihres ML-Modells erforderlich ist, ist subjektiv. 10% werden hier als Notlösung ausgewählt, falls es keine bessere Kennzahl gibt.

- Schema abgeglichen

Amazon ML warnt Sie, wenn das Schema für die Trainings- und Bewertungsdatenquelle nicht identisch ist. Wenn Sie bestimmte Attribute haben, die in der Bewertungsdatenquelle nicht vorhanden sind, oder wenn Sie zusätzliche Attribute haben, zeigt Amazon ML diese Warnung an.

- Alle Datensätze aus Auswertungsdateien wurden für eine vorausschauende Modelleistungsbewertung verwendet

Es ist wichtig zu wissen, ob alle zur Bewertung bereitgestellten Datensätze tatsächlich für die Bewertung des Modells verwendet wurden. Amazon ML warnt Sie, wenn einige Datensätze in der Bewertungsdatenquelle ungültig waren und nicht in die Berechnung der Genauigkeitsmetrik einbezogen wurden. Wenn beispielsweise die Zielvariable für einige der Beobachtungen in der Bewertungsdatenquelle fehlt, kann Amazon ML nicht überprüfen, ob die Vorhersagen des ML-

Modells für diese Beobachtungen korrekt sind. In diesem Fall beträgt werden die Datensätze mit fehlenden Zielwerten als ungültig betrachtet.

- Verteilung der Zielvariable

Amazon ML zeigt Ihnen die Verteilung des Zielattributs aus den Trainings- und Bewertungsdatenquellen, sodass Sie überprüfen können, ob das Ziel in beiden Datenquellen ähnlich verteilt ist. Wenn das Modell mit einer Schulungsdatenverteilung geschult wurde, die von der Verteilung des Ziels in den Auswertungsdaten abweicht, kann die Qualität der Auswertung leiden, da sie mithilfe von Daten mit sehr unterschiedlichen Statistiken berechnet wurde. Die Daten sollten in den Schulungs- und Auswertungsdaten ähnlich verteilt sein, und diese Datensets sollten so gut wie möglich den Daten des Modells beim Treffen von Voraussagen entsprechen.

Wenn diese Warnung ausgelöst wird, versuchen Sie, mit der zufälligen Verteilungsstrategie die Daten in Schulungs- und Auswertungsdatenquellen aufzuteilen. In seltenen Fällen warnt Sie diese Warnung möglicherweise fälschlicherweise vor Unterschieden bei der Zielverteilung, obwohl Sie Ihre Daten nach dem Zufallsprinzip aufgeteilt haben. Amazon ML verwendet ungefähre Datenstatistiken, um die Datenverteilungen auszuwerten, wodurch gelegentlich fälschlicherweise diese Warnung ausgelöst wird.

Generieren und Interpretieren von Voraussagen

Amazon ML bietet zwei Mechanismen für die Generierung von Prognosen: asynchron (stapelbasiert) und synchron (). one-at-a-time

Verwenden Sie asynchrone Voraussagen oder Stapelvoraussagen, wenn Sie eine Reihe von Beobachtungen haben und Voraussagen für alle Beobachtungen gleichzeitig erhalten möchten. Der Prozess verwendet eine Datenquelle als Eingabe und gibt Voraussagen in eine CSV-Datei aus, die in einem S3-Bucket Ihrer Wahl gespeichert wird. Sie müssen warten, bis der Stapelvoraussageprozess abgeschlossen ist, bevor Sie auf die Voraussageergebnisse zugreifen können. Die maximale Größe einer Datenquelle, die Amazon ML in einer Batch-Datei verarbeiten kann, beträgt 1 TB (ca. 100 Millionen Datensätze). Wenn Ihre Datenquelle größer als 1 TB ist, schlägt Ihr Job fehl und Amazon ML gibt einen Fehlercode zurück. Um dies zu verhindern, teilen Sie Ihre Daten in mehrere Batches auf. Wenn Ihre Datensätze in der Regel länger sind, erreichen Sie den Grenzwert von 1 TB, bevor 100 Millionen Datensätze verarbeitet wurden. In diesem Fall empfehlen wir Ihnen, sich an den [AWS-Support](#) zu wenden, um die Auftragsgröße für Ihre Stapelvoraussage zu erhöhen.

Verwenden Sie synchrone oder Echtzeit-Voraussagen, wenn Sie Voraussagen mit niedriger Latenz erhalten möchten. Die Echtzeit-Voraussage-API akzeptiert eine einzelne Eingabebeobachtung, serialisiert als JSON-Zeichenfolge, gibt die Voraussage und die zugehörigen Metadaten synchron als Teil der API-Antwort zurück. Sie können die API mehrmals gleichzeitig aufrufen, um synchrone Voraussagen parallel zu erhalten. Weitere Informationen zur Durchsatzkapazität der Echtzeit-Voraussage-API finden Sie unter den Echtzeit-Voraussage-Limits in der [Amazon ML-API-Referenz](#).

Themen

- [Erstellen einer Stapelvoraussage](#)
- [Überprüfen von Stapelvoraussage-Metriken](#)
- [Lesen der Ausgangsdateien für Stapelvoraussagen](#)
- [Anfordern von Echtzeitvoraussagen](#)

Erstellen einer Stapelvoraussage

Um eine Batch-Vorhersage zu erstellen, erstellen Sie ein BatchPrediction Objekt entweder mit der Amazon Machine Learning (Amazon ML) -Konsole oder der API. Ein BatchPrediction Objekt beschreibt eine Reihe von Vorhersagen, die Amazon ML mithilfe Ihres ML-Modells und einer Reihe

von Eingabebeobachtungen generiert. Wenn Sie ein `BatchPrediction` Objekt erstellen, startet Amazon ML einen asynchronen Workflow, der die Vorhersagen berechnet.

Sie müssen für die Datenquelle dasselbe Schema verwenden, das Sie verwendet haben, um Stapelvoraussagen zu erhalten, sowie dieselbe Datenquelle, die Sie verwendet haben, um das ML-Modell, mit dem Sie Voraussagen abfragen, zu schulen. Die einzige Ausnahme besteht darin, dass die Datenquelle für eine Batch-Vorhersage das Zielattribut nicht enthalten muss, da Amazon ML das Ziel vorhersagt. Wenn Sie das Zielattribut angeben, ignoriert Amazon ML seinen Wert.

Erstellen einer Stapelvoraussage (Konsole)

Um eine Batch-Vorhersage mit der Amazon ML-Konsole zu erstellen, verwenden Sie den Assistenten „Batch-Vorhersage erstellen“.

Erstellen einer Stapelvoraussage (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Amazon ML-Dashboard unter Objekte die Option Create new... , und wählen Sie dann Batch-Vorhersage aus.
3. Wählen Sie das Amazon ML-Modell aus, das Sie für die Erstellung der Batch-Vorhersage verwenden möchten.
4. Um zu bestätigen, dass Sie dieses Modell verwenden möchten, klicken Sie auf Fortfahren.
5. Wählen Sie die Datenquelle, für die Sie Voraussagen erstellen möchten. Die Datenquelle muss dasselbe Schema wie Ihr Modell besitzen, muss allerdings nicht das Zielattribut enthalten.
6. Klicken Sie auf Weiter.
7. Geben Sie unter S3-Ziel den Namen Ihres S3-Buckets ein.
8. Wählen Sie Überprüfen aus.
9. Überprüfen Sie die Einstellungen und klicken Sie auf Stapelvoraussage erstellen.

Erstellen einer Stapelvoraussage (API)

Um ein `BatchPrediction` Objekt mithilfe der Amazon ML-API zu erstellen, müssen Sie die folgenden Parameter angeben:

ID der Datenquelle

Die ID der Datenquelle, die auf die Beobachtungen hinweist, für die Voraussagen wünschen. Wenn Sie beispielsweise Voraussagen für Daten wünschen, die in einer Datei mit dem Namen `s3://examplebucket/input.csv` enthalten sind, erstellen Sie ein Datenquellenobjekt, das auf die Datendatei hinweist, und übergeben Sie dann die ID dieser Datenquelle mit diesem Parameter.

BatchPrediction ID (ID)

Die ID zur Zuweisung der Stapelvoraussage.

ML-Modell-ID

Die ID des ML-Modells, das Amazon ML für die Prognosen abfragen soll.

Ausgabe-Uri

Die URI des S3-Buckets, in dem die Ausgabe der Vorhersage gespeichert werden soll. Amazon ML muss über Berechtigungen verfügen, um Daten in diesen Bucket zu schreiben.

Der Parameter `OutputUri` muss sich auf einen S3-Pfad beziehen, der mit einem Schrägstrich ("/") endet, z. B.:

```
s3://examplebucket/examplepath/
```

Informationen zu S3-Berechtigungen finden Sie unter [Gewähren von Berechtigungen für Amazon ML zwecks Ausgabe von Voraussagen in Amazon S3](#).

(Optional) BatchPrediction Name

(Optional) Ein lesbarer Name für Ihre Stapelvoraussage.

Überprüfen von Stapelvoraussage-Metriken

Nachdem Amazon Machine Learning (Amazon ML) eine Batch-Vorhersage erstellt hat, werden zwei Metriken bereitgestellt: `Records seen` und `Records failed to process`. `Records seen` gibt an, wie viele Datensätze Amazon ML bei der Ausführung Ihrer Batch-Vorhersage betrachtet hat. `Records failed to process` gibt an, wie viele Datensätze Amazon ML nicht verarbeiten konnte.

Damit Amazon ML fehlgeschlagene Datensätze verarbeiten kann, überprüfen Sie die Formatierung der Datensätze in den Daten, die zur Erstellung Ihrer Datenquelle verwendet wurden, und stellen Sie

sicher, dass alle erforderlichen Attribute vorhanden und alle Daten korrekt sind. Nachdem Sie Ihre Daten berichtigt haben, können Sie entweder Ihre Stapelvoraussage erneut erstellen oder eine neue Datenquelle mit den fehlgeschlagenen Datensätzen erstellen, um dann eine neue Stapelvoraussage mit der neuen Datenquelle zu erstellen.

Überprüfen von Stapelvoraussage-Metriken (Konsole)

Um die Metriken in der Amazon ML-Konsole zu sehen, öffnen Sie die Seite mit der Zusammenfassung der Batch-Vorhersagen und suchen Sie im Abschnitt **Verarbeitete Informationen** nach.

Überprüfen von Stapelvoraussage-Metriken und -Details (API)

Sie können Amazon ML verwenden, um Details APIs zu `BatchPrediction` Objekten, einschließlich der Datensatzmetriken, abzurufen. Amazon ML bietet die folgenden API-Aufrufe für Batchvorhersagen:

- `CreateBatchPrediction`
- `UpdateBatchPrediction`
- `DeleteBatchPrediction`
- `GetBatchPrediction`
- `DescribeBatchPredictions`

Weitere Informationen finden Sie in der [Amazon ML API-Referenz](#).

Lesen der Ausgangsdateien für Stapelvoraussagen

Führen Sie die folgenden Schritte durch, um die Ausgangsdateien von Stapelvoraussagen abzurufen:

1. Suchen Sie die Manifestdatei für Stapelvoraussagen.
2. Lesen Sie die Manifestdatei, um die Speicherorte der Ausgabedateien zu ermitteln.
3. Rufen Sie die Ausgabedateien mit den Voraussagen ab.
4. Interpretieren Sie den Inhalt der Ausgabedateien. Der Inhalt variiert je nach Art des für die Erzeugung von Voraussagen verwendeten ML-Modells.

In den folgenden Abschnitte beschreiben diese Schritte ausführlicher.

Suchen der Manifestdatei für Stapelvoraussagen

Die Manifestdateien der Stapelvoraussagen enthalten Informationen, die Ihre Eingabedateien den Voraussage-Ausgabedateien zuordnen.

Um eine Manifestdatei zu suchen, starten Sie mit dem Ausgabespeicherort, den Sie beim Erstellen des Stapelvoraussageobjekts festgelegt haben. Sie können ein abgeschlossenes Batch-Vorhersageobjekt abfragen, um den S3-Speicherort dieser Datei abzurufen, indem Sie entweder die [Amazon ML-API](#) oder die verwenden <https://console.aws.amazon.com/machinelearning/>.

Die Manifestdatei befindet sich am Ausgabespeicherort unter einem Pfad, der aus der statischen Zeichenfolge `/batch-prediction/` angehängt an den Speicherort und den Namen der Manifestdatei besteht, der wiederum die ID der Stapelvoraussage mit der angehängten Erweiterung `.manifest` ist.

Wenn Sie beispielsweise eine Stapelvoraussageobjekt mit der ID `bp-example` erstellen und den S3-Speicherort `s3://examplebucket/output/` als Ausgabespeicherort angeben, finden Sie Ihre Manifestdatei hier:

```
s3://examplebucket/output/batch-prediction/bp-example.manifest
```

Lesen der Manifestdatei

Der Inhalt der Manifestdatei ist als JSON-Zuweisung codiert, deren Schlüssel eine Zeichenfolge mit dem Namen einer S3-Eingabedatendatei ist, und der Wert ist eine Zeichenfolge der zugehörigen Stapelvoraussageergebnisdatei. Für jedes input/output Dateipaar gibt es eine Zuordnungszeile. Wird nun das Beispiel oben weitergeführt und die Eingabe für die Erstellung des `BatchPrediction`-Objekts besteht aus einer einzelnen Datei mit dem Namen `data.csv`, die unter `s3://examplebucket/input/` gespeichert ist, sehen Sie möglicherweise eine Zuweisungszeichenfolge wie diese:

```
{"s3://examplebucket/input/data.csv": "s3://examplebucket/output/batch-prediction/result/bp-example-data.csv.gz"}
```

Wenn die Eingabe für die Erstellung des `BatchPrediction`-Objekts aus drei Dateien mit den Namen `data1.csv`, `data2.csv` und `data3.csv` besteht und alle am S3-Speicherort `s3://examplebucket/input/` gespeichert sind, sehen Sie möglicherweise eine Zuweisungszeichenfolge wie diese:

```
{"s3://examplebucket/input/data1.csv":"s3://examplebucket/output/batch-prediction/
result/bp-example-data1.csv.gz",

"s3://examplebucket/input/data2.csv": "
s3://examplebucket/output/batch-prediction/result/bp-example-data2.csv.gz",

"s3://examplebucket/input/data3.csv": "
s3://examplebucket/output/batch-prediction/result/bp-example-data3.csv.gz"}
```

Abrufen der Ausgangsdateien für Stapelvoraussagen

Sie können jede aus der Manifestzuweisung abgerufene Stapelvoraussagedatei herunterladen und lokal verarbeiten. Das Dateiformat ist CSV mit komprimiertem gzip-Algorithmus. In dieser Datei gibt es eine Zeile pro Eingangsbeobachtung in der entsprechenden Eingabedatei.

Um die Vorhersagen mit der Eingabedatei der Batch-Vorhersage zu verknüpfen, können Sie eine einfache record-by-record Zusammenführung der beiden Dateien durchführen. Die Ausgabedatei der Stapelvoraussage enthält immer dieselbe Anzahl Datensätze wie die Voraussage-Eingabedatei, und zwar in derselben Reihenfolge. Wenn eine Eingabebeobachtung bei der Verarbeitung versagt und keine Voraussage erstellt werden kann, enthält die Ausgabedatei der Stapelvoraussage an der entsprechenden Stelle eine Leerzeile.

Den Inhalt von Stapelvoraussagedateien für ein binäres ML-Klassifikationsmodell interpretieren

Die Spalten der Stapelvoraussagedatei für ein binäres Klassifikationsmodell heißen `bestAnswer` und `score`.

Die Spalte `bestAnswer` enthält das Voraussagekennzeichen ("1" oder "0"), das aus der Evaluation der Voraussagepunktzahl im Vergleich zur Grenzwertpunktzahl hervorgeht. Weitere Informationen zu Grenzwertpunktzahlen finden Sie unter [Anpassen des Ergebnisgrenzwerts](#). Sie legen einen Grenzwert für das ML-Modell fest, indem Sie entweder die Amazon ML-API oder die Modellevaluierungsfunktion auf der Amazon ML-Konsole verwenden. Wenn Sie keinen Grenzwert festlegen, verwendet Amazon ML den Standardwert 0,5.

Die Score-Spalte enthält den unformatierten Prognosewert, der vom ML-Modell für diese Vorhersage zugewiesen wurde. Amazon ML verwendet logistische Regressionsmodelle, sodass dieser Wert versucht, die Wahrscheinlichkeit der Beobachtung zu modellieren, die einem wahren Wert („1“)

entspricht. Beachten Sie, dass `score` in Exponentialschreibweise gemeldet wird, sodass in der ersten Zeile des folgenden Beispiels der Wert `8.7642E-3` gleich `0,0087642` entspricht.

Wenn die Grenzwertpunktzahl für das ML-Modell beispielsweise `0,75` beträgt, kann der Inhalt der Stapelvoraussageausgangsdatei eines binären Klassifikationsmodells folgendermaßen aussehen:

```
bestAnswer,score
0,8.7642E-3
1,7.899012E-1
0,6.323061E-3
0,2.143189E-2
1,8.944209E-1
```

Die zweite und fünfte Beobachtung in der Eingabedatei haben Voraussagepunktzahlen über `0,75` erhalten, sodass die Spalte `bestAnswer` für diese Beobachtungen den Wert `"1"` enthält, während andere Beobachtungen den Wert `"0"` haben.

Den Inhalt von Stapelvoraussagedateien für ein Multiclass-ML-Klassifikationsmodell interpretieren

Die Stapelvoraussagedatei für ein Multiclass-Modell enthält eine Spalte für jede Klasse in den Schulungsdaten. Die Spaltennamen werden in der Kopfzeile der Stapelvoraussagedatei angezeigt.

Wenn Sie Vorhersagen aus einem Mehrklassenmodell anfordern, berechnet Amazon ML mehrere Prognosewerte für jede Beobachtung in der Eingabedatei, einen für jede der im Eingabedatensatz definierten Klassen. Dies entspricht der Frage "Wie hoch ist die Wahrscheinlichkeit (gemessen zwischen 0 und 1), dass diese Beobachtung in diese Klasse und in keine der anderen Klassen fällt?" Jede Punktzahl kann als "Wahrscheinlichkeit, dass die Beobachtung zu dieser Klasse gehört" gelesen werden. Da Voraussagepunktzahlen die zugrunde liegenden Wahrscheinlichkeiten der Beobachtung modellieren, die einer Klasse angehören, beträgt die Summe aller Voraussagepunktzahlen in einer Zeile 1. Sie müssen eine Klasse als vorausgesagte Klasse für das Modell wählen. In den meisten Fällen würden Sie die Klasse mit der höchsten Wahrscheinlichkeit als beste Antwort wählen.

Nehmen wir beispielsweise an, Sie versuchen, die Bewertung eines Kunden für ein bestimmtes Produkt auf Grundlage einer Skala von 1 bis 5 vorzusagen. Wenn die Klassen `1_star`, `2_stars`, `3_stars`, `4_stars` und `5_stars` heißen, sieht die Multiclass-Voraussage-Ausgangsdatei möglicherweise folgendermaßen aus:

```
1_star, 2_stars, 3_stars, 4_stars, 5_stars  
  
8.7642E-3, 2.7195E-1, 4.77781E-1, 1.75411E-1, 6.6094E-2  
  
5.59931E-1, 3.10E-4, 2.48E-4, 1.99871E-1, 2.39640E-1  
  
7.19022E-1, 7.366E-3, 1.95411E-1, 8.78E-4, 7.7323E-2  
  
1.89813E-1, 2.18956E-1, 2.48910E-1, 2.26103E-1, 1.16218E-1  
  
3.129E-3, 8.944209E-1, 3.902E-3, 7.2191E-2, 2.6357E-2
```

In diesem Beispiel hat die erste Beobachtung die höchste Voraussagepunktzahl für die Klasse `3_stars` (Voraussagepunktzahl = $4.77781E-1$), sodass Sie die angezeigten Ergebnisse so interpretieren würden, dass Klasse `3_stars` die beste Antwort auf diese Beobachtung ist. Beachten Sie, dass Voraussagepunktzahlen in Exponentialschreibweise angegeben werden, eine Voraussagepunktzahl von $4.77781E-1$ entspricht also 0,477781.

Unter bestimmten Umständen kann es nützlich sein, wenn Sie nicht die Klasse mit der höchsten Wahrscheinlichkeit wählen. Wenn Sie beispielsweise einen Mindestgrenzwert festlegen möchten, unter dem Sie eine Klasse nicht mehr als beste Antwort erachten, auch wenn sie die höchste Voraussagepunktzahl hat. Nehmen wir an, Sie klassifizieren Filme in Genres, und Sie möchten, dass die Voraussagepunktzahl mindestens $5E-1$ beträgt, bevor Sie das Genre als beste Antwort erachten. Sie erhalten eine Voraussagepunktzahl von $3E-1$ für Komödien, $2.5E-1$ für Dramen, $2.5E-1$ für Dokumentationen und $2E-1$ für Action-Filme. In diesem Fall sagt ML-Modell voraus, das Komödie Ihre wahrscheinlichste Wahl ist, doch Sie entscheiden, dies nicht als beste Antwort zu wählen. Da keine der Voraussagepunktzahlen Ihre Basis-Voraussagepunktzahl von $5E-1$ überschritten hat, entscheiden Sie, dass die Voraussage nicht ausreicht, um das Genre souverän vorherzusagen, und Sie entscheiden sich für etwas anderes. Ihre Anwendung kann das Genre-Feld für diesen Film dann als "unbekannt" festlegen.

Den Inhalt von Stapelvoraussagedateien für ein Regressions-ML-Modell interpretieren

Die Stapelvoraussagedatei für ein Regressionsmodell enthält eine einzelne Spalte mit dem Namen `score`. Diese Spalte enthält die unformatierte numerische Voraussage für jede Beobachtung in den Eingabedaten. Die Werte werden in Exponentialschreibweise angegeben, sodass ein `score`-Wert von `-1.526385E1` in der ersten Reihe im folgenden Beispiel einem Wert von `-15.26835` entspricht.

Dieses Beispiel zeigt eine Ausgabedatei für eine Stapelvoraussage für ein Regressionsmodell:

```
score
-1.526385E1
-6.188034E0
-1.271108E1
-2.200578E1
8.359159E0
```

Anfordern von Echtzeitvoraussagen

Eine Vorhersage in Echtzeit ist ein synchroner Aufruf von Amazon Machine Learning (Amazon ML). Die Vorhersage wird getroffen, wenn Amazon ML die Anfrage erhält, und die Antwort wird sofort zurückgegeben. Echtzeitvoraussagen werden häufig verwendet, um Voraussagefunktionen in interaktiven Web-, Mobil- oder Desktopanwendungen zu ermöglichen. Mithilfe der `Predict` API mit niedriger Latenz können Sie ein mit Amazon ML erstelltes ML-Modell in Echtzeit nach Prognosen abfragen. Die `Predict`-Operation akzeptiert eine einzelne Input-Beobachtung in der Nutzlast der Anforderung und gibt die Voraussage synchron in der Antwort zurück. Dies unterscheidet sie von der `Batch-Prognose-API`, die mit der ID eines Amazon ML-Datenquellenobjekts aufgerufen wird, das auf den Standort der Eingabebeobachtungen verweist, und asynchron einen URI an eine Datei zurückgibt, die Vorhersagen für all diese Beobachtungen enthält. Amazon ML beantwortet die meisten Prognoseanfragen in Echtzeit innerhalb von 100 Millisekunden.

In der Amazon ML-Konsole können Sie Prognosen in Echtzeit testen, ohne dass Gebühren anfallen. Wenn Sie dann Echtzeitvoraussagen verwenden möchten, müssen Sie zuerst einen Endpunkt für die

Generierung von Echtzeitvoraussagen erstellen. Sie können dies in der Amazon ML-Konsole oder mithilfe der `CreateRealtimeEndpoint` API tun. Nachdem Sie einen Endpunkt haben, verwenden Sie die API für Echtzeitvoraussagen, um Echtzeitvoraussagen zu generieren.

Note

Nach dem Erstellen eines Echtzeitendpunkts für Ihr Modell fallen Gebühren für die Kapazitätsreservierung an, die auf der Größe des Modells basieren. Weitere Informationen finden Sie unter [– Preise](#). Wenn Sie den Echtzeitendpunkt in der Konsole erstellen, zeigt die Konsole eine Aufschlüsselung der geschätzten Kosten an, die sich für den Endpunkt fortlaufend anfallen werden. Damit Ihnen keine Kosten mehr berechnet werden, wenn Sie keine Echtzeitvoraussagen von diesem Modell mehr benötigen, entfernen Sie den Echtzeitendpunkt mithilfe der Konsole oder der `DeleteRealtimeEndpoint`-Operation.

Beispiele für `Predict` Anfragen und Antworten finden Sie unter [Predict](#) in der Amazon Machine Learning API-Referenz. Ein Beispiel für das exakte Antwortformat Ihres Modells finden Sie unter [Testen von Echtzeitvoraussagen](#).

Themen


- [Testen von Echtzeitvoraussagen](#)
- [Erstellen eines Echtzeitendpunkts](#)
- [Auffinden des Endpunkts für Echtzeitvoraussagen \(Konsole\)](#)
- [Auffinden des Endpunkts für Echtzeitvoraussagen \(API\)](#)
- [Erstellen einer Echtzeitvoraussage-Anforderung](#)
- [Löschen eines Echtzeitendpunkts](#)

Testen von Echtzeitvoraussagen

Um Ihnen bei der Entscheidung zu helfen, ob Sie Echtzeitprognosen aktivieren möchten, können Sie mit Amazon ML versuchen, Prognosen für einzelne Datensätze zu generieren, ohne dass zusätzliche Kosten anfallen, die mit der Einrichtung eines Echtzeit-Prognoseendpunkts verbunden sind. Um Echtzeitvoraussagen zu testen, müssen Sie über ein ML-Modell verfügen. Verwenden Sie die `Predict` API in der Amazon Machine Learning API-Referenz, um [Echtzeitvorhersagen](#) in größerem Maßstab zu erstellen.

Vorgehensweise zum Testen von Echtzeitvoraussagen

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Dropdownmenü Amazon Machine Learning in der Navigationsleiste die Option ML-Modelle aus.
3. Wählen Sie das Modell aus, das Sie zum Testen von Echtzeitvoraussagen verwenden möchten, beispielsweise das `Subscription propensity model` aus dem Tutorial.
4. Wählen Sie auf der ML-Modell-Berichtsseite unter Voraussagen die Option Übersicht und dann Try real-time predictions (Echtzeitvoraussagen ausprobieren) aus.



Amazon ML zeigt eine Liste der Variablen, aus denen sich die Datensätze zusammensetzen, die Amazon ML zum Trainieren Ihres Modells verwendet hat.

5. Sie können fortfahren, indem Sie Daten in die einzelnen Felder im Formular eingeben oder einen einzelnen Datensatz im CSV-Format in das Textfeld einfügen.

Geben Sie bei Verwendung des Formulars in jedes Wert-Feld die Daten ein, die Sie zum Testen Ihrer Echtzeitvoraussagen verwenden möchten. Wenn der Datensatz, den Sie eingeben, keine Werte für ein oder mehrere Datenattribut(e) enthält, lassen Sie die Eingabefelder leer.

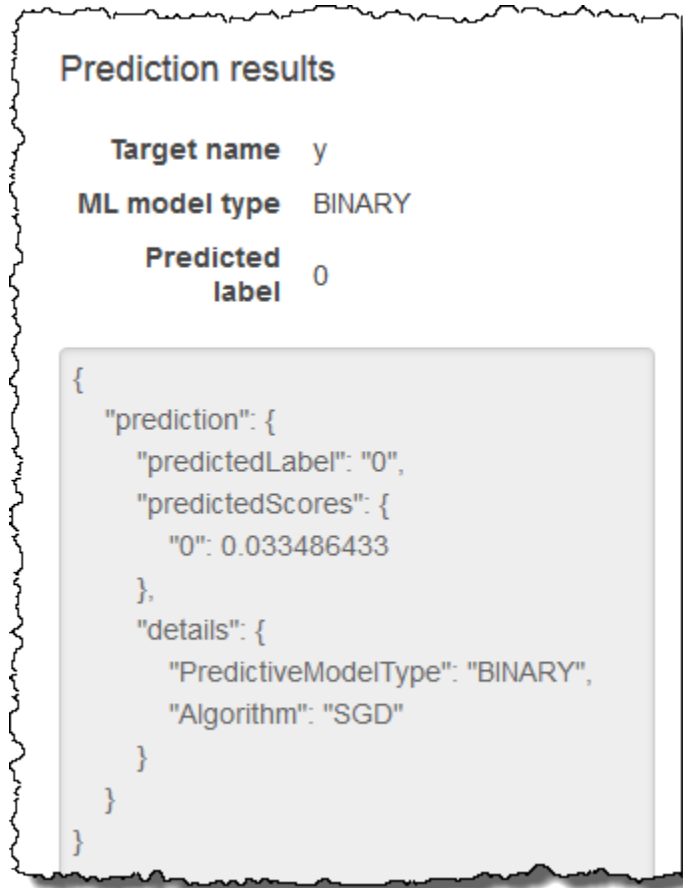
Wählen Sie die Option Paste a record, um einen Datensatz bereitzustellen. Fügen Sie eine einzelne CSV-formatierte Datenzeile in das Textfeld ein und wählen Sie Senden. Amazon ML füllt die Wertefelder automatisch für Sie aus.

Note

Die Daten im Datensatz müssen die gleiche Anzahl von Spalten wie die Schulungsdaten haben und in der gleichen Reihenfolge angeordnet sein. Die einzige Ausnahme ist, dass Sie den Zielwert auslassen sollten. Wenn Sie einen Zielwert angeben, ignoriert Amazon ML ihn.

6. Klicken Sie unten auf der Seite auf Create prediction. Amazon ML gibt die Prognose sofort zurück.

Im Bereich Prediction results (Voraussageergebnisse) sehen Sie das Voraussageobjekt, das vom Predict-API-Aufruf zurückgegeben wird, sowie den ML-Modelltyp, den Namen der Zielvariable und die vorausgesagte Klasse oder den vorausgesagten Wert. Weitere Informationen zur Interpretation dieser Ergebnisse finden Sie unter [Den Inhalt von Stapelvorausagedateien für ein binäres ML-Klassifikationsmodell interpretieren](#).



Erstellen eines Echtzeitendpunkts


Um Echtzeitvoraussagen generieren zu können, müssen Sie einen Echtzeitendpunkt erstellen. Für die Erstellung eines Echtzeitendpunkt müssen Sie bereits über ein ML-Modell verfügen, für das Sie Echtzeitvoraussagen generieren möchten. Sie können einen Echtzeit-Endpunkt erstellen, indem Sie die Amazon ML-Konsole verwenden oder die `CreateRealtimeEndpoint` API aufrufen. Weitere Informationen zur Verwendung der `CreateRealtimeEndpoint` API finden Sie https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_CreateRealtimeEndpoint.html in der Amazon Machine Learning API-Referenz.

Vorgehensweise zum Erstellen eines Echtzeitendpunkts

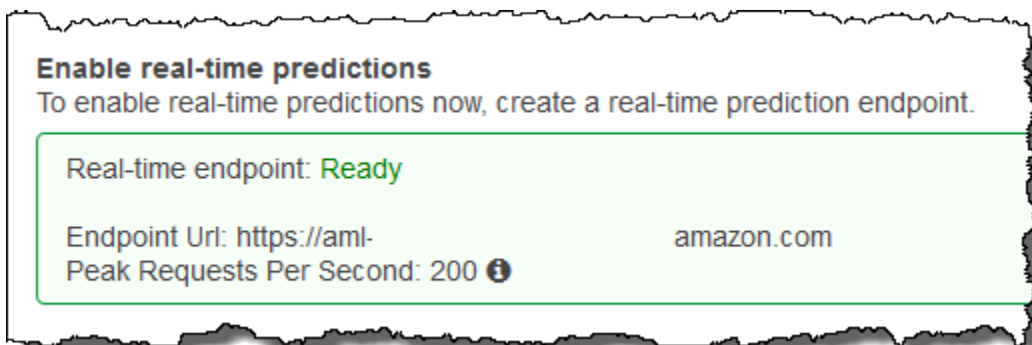
1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Dropdownmenü Amazon Machine Learning in der Navigationsleiste die Option ML-Modelle aus.
3. Wählen Sie das Modell aus, für das Sie die Echtzeitvoraussagen generieren möchten.
4. Wählen Sie auf der Seite ML model summary unter Predictions die Option Create real-time endpoint aus.

Es wird ein Dialogfeld mit Erläuterungen zur Preisberechnung für Echtzeitvoraussagen angezeigt.

5. Wählen Sie Erstellen aus. Die Echtzeit-Endpunktanfrage wird an Amazon ML gesendet und in eine Warteschlange aufgenommen. Der Status des Echtzeitendpunkts ist Wird aktualisiert.



6. Wenn der Echtzeit-Endpunkt bereit ist, ändert sich der Status in Bereit und Amazon ML zeigt die Endpunkt-URL an. Verwenden Sie die Endpunkt-URL, um Echtzeitvoraussagen mit der Predict-API zu erstellen. Weitere Informationen zur Verwendung der Predict API finden Sie https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_Predict.html in der Amazon Machine Learning API-Referenz.



Auffinden des Endpunkts für Echtzeitvoraussagen (Konsole)

Um die Amazon ML-Konsole zu verwenden, um die Endpunkt-URL für ein ML-Modell zu finden, navigieren Sie zur Übersichtsseite des ML-Modells.

Vorgehensweise zum Finden einer Echtzeitendpunkt-URL

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Dropdownmenü Amazon Machine Learning in der Navigationsleiste die Option ML-Modelle aus.
3. Wählen Sie das Modell aus, für das Sie die Echtzeitvoraussagen generieren möchten.
4. Scrollen Sie auf der Seite ML model summary nach unten, bis Sie den Abschnitt Predictions sehen.
5. Die Endpunkt-URL für das Modell wird unter Real-time prediction angezeigt. Verwenden Sie die URL als Endpoint Url-URL für Ihre Echtzeitvoraussage-Aufrufe. Informationen zur Verwendung des Endpunkts zur Generierung von Prognosen finden Sie https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_Predict.html in der Amazon Machine Learning API-Referenz.

Auffinden des Endpunkts für Echtzeitvoraussagen (API)

Wenn Sie mithilfe der `CreateRealtimeEndpoint`-Operation einen Echtzeitendpunkt erstellen, werden Ihnen in der Antwort die URL und der Status des Endpunkts mitgeteilt. Wenn Sie einen Echtzeitendpunkt mithilfe der Konsole erstellt haben oder die URL und den Status eines zuvor erstellten Endpunkts abrufen möchten, rufen Sie die `GetMLModel`-Operation mit der ID des Modells auf, das Sie für Echtzeitvoraussagen abfragen möchten. Die Endpunktinformationen sind im `EndpointInfo`-Abschnitt der Antwort enthalten. Bei einem Modell, dem ein Echtzeitendpunkt zugeordnet ist, können die `EndpointInfo` wie folgt aussehen:

```
"EndpointInfo":{
  "CreatedAt": 1427864874.227,
  "EndpointStatus": "READY",
  "EndpointUrl": "https://endpointUrl",
  "PeakRequestsPerSecond": 200
}
```

Ein Modell ohne Echtzeitendpunkt würde zu folgender Antwort führen:

```
EndpointInfo":{
  "EndpointStatus": "NONE",
  "PeakRequestsPerSecond": 0
}
```

Erstellen einer Echtzeitvoraussage-Anforderung

Eine Beispielnutzlast für eine Predict-Anforderung kann wie folgt aussehen:

```
{
  "MLModelId": "model-id",
  "Record":{
    "key1": "value1",
    "key2": "value2"
  },
  "PredictEndpoint": "https://endpointUrl"
}
```

Das PredictEndpoint Feld muss dem EndpointUrl Feld der EndpointInfo Struktur entsprechen. Amazon ML verwendet dieses Feld, um die Anfrage an die entsprechenden Server in der Echtzeit-Prognoseflotte weiterzuleiten.

Die MLModelId ist die ID eines zuvor geschulten Modells mit einem Echtzeitendpunkt.

Ein Record ist eine Zuordnung von Variablennamen zu Variablenwerten. Jedes Paar stellt eine Beobachtung dar. Die Record Map enthält die Eingaben für Ihr Amazon ML-Modell. Sie ist vergleichbar mit einer einzelnen Datenzeile in Ihrem Schulungsdatensatz, ohne die Zielvariable. Record enthält unabhängig von der Art der Werte in den Trainingsdaten eine string-to-string Zuordnung.

Note

Sie können Variablen auslassen, für die Sie keinen Wert haben. Das kann allerdings die Genauigkeit Ihrer Voraussage reduzieren. Je mehr Variablen Sie integrieren können, umso präziser wird Ihr Modell.

Das Format der Antwort von Predict-Anforderungen hängt von der Art des Modells ab, das für die Voraussage abgefragt wird. Das `details`-Feld enthält in jedem Fall Informationen über die Voraussage-Anforderung, darunter insbesondere das `PredictiveModelType`-Feld mit dem Modelltyp.

Das folgende Beispiel zeigt eine Antwort für eine Binärmodell:

```
{
  "Prediction":{
    "details":{
      "PredictiveModelType": "BINARY"
    },
    "predictedLabel": "0",
    "predictedScores":{
      "0": 0.47380468249320984
    }
  }
}
```

Beachten Sie das `predictedLabel` Feld, das die vorhergesagte Bezeichnung enthält, in diesem Fall 0. Amazon ML berechnet das vorhergesagte Label, indem es den Prognosewert mit dem Klassifizierungsgrenzwert vergleicht:

- Sie können den Klassifizierungsgrenzwert ermitteln, der derzeit einem ML-Modell zugeordnet ist, indem Sie das `ScoreThreshold` Feld als Antwort auf den `GetMLModel` Vorgang überprüfen oder indem Sie die Modellinformationen in der Amazon ML-Konsole aufrufen. Wenn Sie keinen Punktegrenzwert festlegen, verwendet Amazon ML den Standardwert 0,5.
- Die genaue Voraussagepunktzahl für ein binäres Klassifizierungsmodell erhalten Sie, indem Sie die `predictedScores`-Zuordnung überprüfen. Innerhalb dieser Zuordnung ist die Voraussagekennzeichnung mit der genauen Voraussagepunktzahl verknüpft.

Weitere Informationen zu Binärvoraussagen finden Sie unter [Interpretieren der Voraussagen](#).

Das folgende Beispiel zeigt eine Antwort für ein Regressionsmodell. Beachten Sie, dass der numerische Voraussagewert sich im Feld `predictedValue` befindet:

```
{
  "Prediction":{
    "details":{
```

```
    "PredictiveModelType": "REGRESSION"
  },
  "predictedValue": 15.508452415466309
}
}
```

Das folgende Beispiel zeigt eine Antwort für ein Multiclass-Modell:

```
{
  "Prediction":{
    "details":{
      "PredictiveModelType": "MULTICLASS"
    },
    "predictedLabel": "red",
    "predictedScores":{
      "red": 0.12923571467399597,
      "green": 0.08416014909744263,
      "orange": 0.22713537514209747,
      "blue": 0.1438363939523697,
      "pink": 0.184102863073349,
      "violet": 0.12816807627677917,
      "brown": 0.10336143523454666
    }
  }
}
```

Ähnlich wie bei binären Klassifikationsmodellen `label/class` wird das Vorhergesagte vor `predictedLabel` Ort gefunden. Die starke Verbindung zwischen der Voraussage und den einzelnen Klassen können Sie besser nachvollziehen, wenn Sie sich die `predictedScores`-Zuordnung ansehen. Je höher die Punktzahl ist, umso stärker ist die Voraussage mit der Klasse verbunden. Der höchste Wert wird schlussendlich als `predictedLabel` ausgewählt.

Weitere Informationen zu Multiclass-Voraussagen finden Sie unter [Einblicke in Mehrklassen-Modelle](#).

Löschen eines Echtzeitendpunkts

Wenn Sie Ihre Echtzeitvoraussagen abgeschlossen haben, löschen Sie den Echtzeitendpunkt, damit keine weiteren Gebühren anfallen. Sobald Sie den Endpunkt gelöscht haben, fallen keine Gebühren mehr an.

Vorgehensweise zum Löschen eines Echtzeitendpunkts

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie im Dropdownmenü Amazon Machine Learning in der Navigationsleiste die Option ML-Modelle aus.
3. Wählen Sie das Modell aus, für das keine Echtzeitvoraussagen mehr erforderlich sind.
4. Wählen Sie auf der ML-Modell-Berichtsseite unter Predictions die Option Summary aus.
5. Wählen Sie Delete real-time endpoint.
6. Klicken Sie im Dialogfeld Delete real-time endpoint auf Delete.

Amazon ML-Objekte verwalten

Amazon ML bietet vier Objekte, die Sie über die Amazon ML-Konsole oder die Amazon ML-API verwalten können:

- Datenquellen
- ML-Modelle
- Auswertungen
- Stapelvoraussagen

Jedes Objekt dient einem anderen Zweck im Lebenszyklus zum Erstellen einer maschinellen Lernanwendung, und jedes Objekt hat bestimmte Attribute und Funktionen, die nur für das jeweilige Objekt gelten. Trotz dieser Unterschiede verwalten Sie die Objekte auf ähnliche Weise. Beispielsweise verwenden Sie fast identische Prozesse zum Auflisten von Objekten, Abrufen von Beschreibungen und zum Aktualisieren oder Löschen.

In den folgenden Abschnitten werden die Verwaltungsvorgänge beschrieben, die für alle vier Objekte gelten, und Unterschiede hervorgehoben.

Themen

- [Auflisten von Objekten](#)
- [Das Abrufen von Objektbeschreibungen](#)
- [Aktualisieren von Objekten](#)
- [Löschen von Objekten](#)

Auflisten von Objekten

Ausführliche Informationen zu Ihren Amazon Machine Learning (Amazon ML) -Datenquellen, ML-Modellen, Bewertungen und Batch-Prognosen erhalten Sie, wenn Sie diese auflisten. Für jedes Objekt wird Ihnen der Name, der Typ, die ID, der Statuscode und der Zeitpunkt der Erstellung angezeigt. Sie können auch spezifische Details für einen bestimmten Objekttyp sehen. Sie können zum Beispiel die Dateneinblicke für eine Datenquelle sehen.

Auflisten von Objekten (Konsole)

Um eine Liste der letzten 1.000 Objekte zu sehen, die Sie erstellt haben, öffnen Sie in der Amazon ML-Konsole das Objects-Dashboard. Um das Objects-Dashboard anzuzeigen, melden Sie sich bei der Amazon ML-Konsole an.

Objects ?

Create new... Actions Refresh

Filter: All types Items per page: 10 << < 1 - 5 of 5 Objects > >>

Name	Type	ID	Status	Creation time	Completion time
<input type="checkbox"/> ▶ Evaluation: ML m...	Evaluation	ev-	Completed	Aug 1, 2016 12:44:48 PM	3 mins.
<input type="checkbox"/> ▶ ML model: Examl...	ML model	ml-	Completed	Aug 1, 2016 12:44:47 PM	2 mins.
<input type="checkbox"/> ▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	3 mins.
<input type="checkbox"/> ▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	4 mins.
<input type="checkbox"/> ▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:23 PM	3 mins.

Um weitere Details zu einem Objekt sehen zu können, einschließlich spezifischer Details für diesen Objekttyp, wählen Sie den Namen oder die ID des Objekts aus. Wenn Sie beispielsweise Data insights für eine Datenquelle anzeigen möchten, wählen Sie den Namen der Datenquelle aus.

Die Spalten auf dem Dashboard Objekte zeigen die folgenden Informationen zu den einzelnen Objekten.

Name

Der Name des Objekts.

Typ

Der Typ des Objekts. Gültige Werte sind unter anderem Datenquelle, ML-Modell, Auswertung und Stapelvoraussage.

Note

Um zu sehen, ob ein Modell zur Unterstützung von Echtzeitvoraussagen eingerichtet ist, wechseln Sie zur Seite ML model summary (ML-Modellzusammenfassung), indem Sie den Namen oder die Modell-ID auswählen.

ID (ID)

Die ID des Objekts.

Status

Der Status des Objekts. Gültige Werte sind Schwebend, In Bearbeitung, Abgeschlossen und Fehlgeschlagen. Wenn der Status Fehlgeschlagen ist, prüfen Sie Ihre Daten und versuchen Sie es erneut.

Zeitpunkt der Erstellung

Datum und Uhrzeit, an dem Amazon ML die Erstellung dieses Objekts abgeschlossen hat.

Fertigstellungszeit

Die Zeit, die Amazon ML benötigt hat, um dieses Objekt zu erstellen. Sie können die Fertigstellungszeit eines Modells nutzen, um die Schulungszeit für ein neues Modell einzuschätzen.

ID der Datenquelle

Die ID der Datenquelle für Objekte, die unter Verwendung einer Datenquelle erstellt wurde, wie z. B. Modelle und Evaluierungen. Wenn Sie die Datenquelle löschen, können Sie ML-Modelle, die mit dieser Datenquelle erstellt wurden, nicht mehr für die Erstellung von Voraussagen verwenden.

Sie können nach jeder beliebigen Spalte sortieren, indem Sie das doppelte Dreieckssymbol neben der Spaltenüberschrift anklicken.

Auflisten von Objekten (API)

In der [Amazon ML-API](#) können Sie Objekte mithilfe der folgenden Operationen nach Typ auflisten:

- DescribeDataSources
- DescribeMLModels
- DescribeEvaluations
- DescribeBatchPredictions

Jede Operation beinhaltet Parameter für Filterung, Sortierung und Paginierung durch eine lange Liste von Objekten. Es gibt keine Beschränkungen in Bezug auf die Anzahl an Objekten, auf die Sie über die API zugreifen können. Verwenden Sie den Limit-Parameter, um die Größe der Liste zu begrenzen. Der Maximalwert für diesen Parameter ist 100.

Die API-Antwort auf einen `Describe*`-Befehl umfasst ein Paginierungs-Token (`nextPageToken`), sofern zutreffend, sowie kurze Beschreibungen der einzelnen Objekte. Die Objektbeschreibungen enthalten die gleichen Informationen für alle Objekttypen, die in der Konsole angezeigt werden, einschließlich spezifischer Details für einen bestimmten Objekttyp.

Note

Auch wenn die Antwort weniger Objekte als der angegebene Grenzwert umfasst, kann sie ein `nextPageToken` enthalten, das angibt, dass weitere Ergebnisse verfügbar sind. Auch eine Antwort, die 0 Elemente enthält, kann ein `nextPageToken` enthalten.

Weitere Informationen finden Sie in der [Amazon ML API-Referenz](#).

Das Abrufen von Objektbeschreibungen

Sie können detaillierte Beschreibungen eines Objekts über die Konsole oder über die API anzeigen.

Detaillierte Beschreibungen in der Konsole

Um Beschreibungen auf der Konsole anzuzeigen, navigieren Sie zu einem bestimmten Objekttyp (Datenquelle, ML-Modell, Bewertung oder Stapelvoraussage). Als Nächstes suchen Sie entweder mithilfe der Liste oder durch Suchen des Namens oder der ID die Zeile in der Tabelle, die dem Objekt entspricht.

Detaillierte Beschreibungen von der API

Jeder Objekttyp verfügt über eine Funktion, welche die vollständigen Details eines Amazon ML-Objekts abrufen:

- `GetDataSource`
- `Holen MLModel`
- `GetEvaluation`
- `GetBatchPrediction`

Jeder Vorgang dauert genau zwei Parameter: die Objekt-ID und ein boolesches Flag mit dem Namen `Verbose`. Abrufe mit `Verbose` auf `"true"` enthalten zusätzliche Details über das Objekt, was zu höherer

Latenzen und umfassenderen Antworten führt. Weitere Informationen zu den Feldern, die durch Setzen des Verbose Flag enthalten sind, finden Sie unter [Amazon ML-API-Referenz](#).

Aktualisieren von Objekten

Jeder Objekttyp hat einen Vorgang, der die Details eines Amazon ML-Objekts aktualisiert (siehe [Amazon ML API-Referenz](#)):

- UpdateDataSource
- Aktualisieren MLModel
- UpdateEvaluation
- UpdateBatchPrediction

Jeder Vorgang erfordert die Objekt-ID, um anzugeben, welches Objekt aktualisiert wird. Sie können die Namen aller Objekte aktualisieren. Sie können jedoch keine anderen Eigenschaften von Objekten für Datenquellen, Auswertungen und Stapelvoraussagen aktualisieren. Bei ML-Modellen können Sie das ScoreThreshold Feld aktualisieren, sofern dem ML-Modell kein Endpunkt für Echtzeitprognosen zugeordnet ist.

Löschen von Objekten

Wenn Sie Ihre Datenquellen, ML-Modelle, Evaluierungen und Stapelvoraussagen nicht mehr benötigen, können Sie sie löschen. Es fallen zwar keine zusätzlichen Kosten für die Aufbewahrung von Amazon ML-Objekten an, mit Ausnahme von Batch-Vorhersagen, nachdem Sie mit ihnen fertig sind, aber das Löschen von Objekten sorgt dafür, dass Ihr Workspace übersichtlich bleibt und einfacher zu verwalten ist. Sie können einzelne oder mehrere Objekte mithilfe der Amazon Machine Learning (Amazon ML) -Konsole oder der API löschen.

Warning

Wenn Sie Amazon ML-Objekte löschen, ist der Effekt sofort, dauerhaft und irreversibel.

Objects ?

Create new... Actions Refresh



Filter: All types Items per page: 10 << < 1 - 5 of 5 Objects > >>

Name	Type	ID	Status	Creation time	Completion time
<input type="checkbox"/> Evaluation: ML m...	Evaluation	ev-	Completed	Aug 1, 2016 12:44:48 PM	3 mins.
<input type="checkbox"/> ML model: Examl...	ML model	ml-	Completed	Aug 1, 2016 12:44:47 PM	2 mins.
<input type="checkbox"/> Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	3 mins.
<input type="checkbox"/> Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	4 mins.
<input type="checkbox"/> Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:23 PM	3 mins.

Löschen von Objekten (Konsole)

Sie können die Amazon ML-Konsole verwenden, um Objekte, einschließlich Modelle, zu löschen. Die Vorgehensweise zum Löschen eines Modells hängt davon ab, ob Sie das Modell für die Generierung von Echtzeitvoraussagen verwenden oder nicht. Wenn Sie ein Modell löschen möchten, das zum Generieren von Echtzeitvoraussagen verwendet wird, müssen Sie zuerst den Echtzeitendpunkt löschen.

Um Amazon ML-Objekte zu löschen (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie die Amazon ML-Objekte aus, die Sie löschen möchten. Verwenden Sie die UMSCHALTTASTE, um mehr als ein Objekt auszuwählen. Verwenden Sie die Schaltflächen  oder  um die Auswahl aller ausgewählten Objekte aufzuheben.
3. Klicken Sie bei Actions auf Delete.
4. Klicken Sie im Dialogfeld auf Löschen, um das Modell zu löschen.

Um ein Amazon ML-Modell mit einem Echtzeit-Endpunkt (Konsole) zu löschen

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Wählen Sie das Modell aus, das Sie löschen möchten.
3. Wählen Sie unter Aktionen die Option Delete real-time endpoint (Echtzeitendpunkt löschen).

4. Wählen Sie Löschen, um den Endpunkt zu löschen.
5. Wählen Sie das Modell erneut aus.
6. Klicken Sie bei Actions auf Delete.
7. Wählen Sie Löschen, um das Modell zu löschen.

Löschen von Objekten (API)

Sie können Amazon ML-Objekte mit den folgenden API-Aufrufen löschen:

- `DeleteDataSource`: Nutzt den Parameter `DataSourceId`.
- `DeleteMLModel`: Nutzt den Parameter `MLModelId`.
- `DeleteEvaluation`: Nutzt den Parameter `EvaluationId`.
- `DeleteBatchPrediction`: Nutzt den Parameter `BatchPredictionId`.

Weitere Informationen finden Sie unter [Amazon Machine Learning API Reference](#).

Überwachung von Amazon ML mit Amazon CloudWatch Metrics

Amazon ML sendet automatisch Metriken an Amazon, CloudWatch sodass Sie Nutzungsstatistiken für Ihre ML-Modelle sammeln und analysieren können. Um beispielsweise den Überblick über Batch- und Echtzeitprognosen zu behalten, können Sie die PredictCount Metrik je nach RequestMode Dimension überwachen. Die Metriken werden automatisch erfasst und CloudWatch alle fünf Minuten an Amazon gesendet. Sie können diese Metriken mithilfe der CloudWatch Amazon-Konsole, der AWS-CLI oder AWS überwachen SDKs.

Für die Amazon ML-Metriken, die über gemeldet werden, fallen keine Gebühren an CloudWatch. Wenn Sie Alarme für die Metriken einrichten, werden Ihnen die [CloudWatch Standardpreise](#) in Rechnung gestellt.

Weitere Informationen finden Sie in der Amazon ML-Metrikenliste unter [Amazon CloudWatch Namespaces, Dimensions, and Metrics Reference](#) im Amazon CloudWatch Developer Guide.

Protokollieren von Amazon ML-API-Aufrufen mit AWS CloudTrail

Amazon Machine Learning (Amazon ML) ist in einen Service integriert AWS CloudTrail, der eine Aufzeichnung der Aktionen bereitstellt, die von einem Benutzer, einer Rolle oder einem AWS Service in Amazon ML ausgeführt wurden. CloudTrail erfasst alle API-Aufrufe für Amazon ML als Ereignisse. Zu den erfassten Aufrufen gehören Aufrufe von der Amazon ML-Konsole und Code-Aufrufe der Amazon ML-API-Operationen. Wenn Sie einen Trail erstellen, können Sie die kontinuierliche Bereitstellung von CloudTrail Ereignissen an einen Amazon S3 S3-Bucket aktivieren, einschließlich Ereignissen für Amazon ML. Wenn Sie keinen Trail konfigurieren, können Sie die neuesten Ereignisse trotzdem in der CloudTrail Konsole im Ereignisverlauf anzeigen. Anhand der von gesammelten Informationen können Sie die Anfrage CloudTrail, die an Amazon ML gestellt wurde, die IP-Adresse, von der aus die Anfrage gestellt wurde, wer die Anfrage gestellt hat, wann sie gestellt wurde, und weitere Details ermitteln.

Weitere Informationen darüber CloudTrail, einschließlich der Konfiguration und Aktivierung, finden Sie im [AWS CloudTrail Benutzerhandbuch](#).

Amazon ML-Informationen in CloudTrail

CloudTrail ist für Ihr AWS Konto aktiviert, wenn Sie das Konto erstellen. Wenn unterstützte Ereignisaktivitäten in Amazon ML auftreten, wird diese Aktivität zusammen mit anderen AWS Serviceereignissen in der CloudTrail Ereignishistorie in einem Ereignis aufgezeichnet. Sie können aktuelle Ereignisse in Ihrem AWS Konto ansehen, suchen und herunterladen. Weitere Informationen finden Sie unter [Ereignisse mit CloudTrail Ereignisverlauf anzeigen](#).

Für eine fortlaufende Aufzeichnung von Ereignissen in Ihrem AWS Konto, einschließlich Ereignissen für Amazon ML, erstellen Sie einen Trail. Ein Trail ermöglicht CloudTrail die Übermittlung von Protokolldateien an einen Amazon S3 S3-Bucket. Wenn Sie einen Pfad in der Konsole anlegen, gilt dieser für alle AWS-Regionen. Der Trail protokolliert Ereignisse aus allen Regionen der AWS Partition und übermittelt die Protokolldateien an den von Ihnen angegebenen Amazon S3 S3-Bucket. Darüber hinaus können Sie andere AWS Dienste konfigurieren, um die in den CloudTrail Protokollen gesammelten Ereignisdaten weiter zu analysieren und darauf zu reagieren. Weitere Informationen finden Sie hier:

- [Übersicht zum Erstellen eines Trails](#)

- [CloudTrail Unterstützte Dienste und Integrationen](#)
- [Konfiguration von Amazon SNS SNS-Benachrichtigungen für CloudTrail](#)
- [Empfangen von CloudTrail Protokolldateien aus mehreren Regionen](#) und [Empfangen von CloudTrail Protokolldateien von mehreren Konten](#)

Amazon ML unterstützt die Protokollierung der folgenden Aktionen als Ereignisse in CloudTrail Protokolldateien:

- [AddTags](#)
- [CreateBatchPrediction](#)
- [CreateDataSourceFromRDS](#)
- [CreateDataSourceFromRedshift](#)
- [CreateDataSourceFromS3](#)
- [CreateEvaluation](#)
- [CreateMLModel](#)
- [CreateRealtimeEndpoint](#)
- [DeleteBatchPrediction](#)
- [DeleteDataSource](#)
- [DeleteEvaluation](#)
- [LöschenMLModel](#)
- [DeleteRealtimeEndpoint](#)
- [DeleteTags](#)
- [DescribeTags](#)
- [UpdateBatchPrediction](#)
- [UpdateDataSource](#)
- [UpdateEvaluation](#)
- [AktualisierenMLModel](#)

Die folgenden Amazon ML-Operationen verwenden Anforderungsparameter, die Anmeldeinformationen enthalten. Bevor diese Anfragen an CloudTrail gesendet werden, werden die Anmeldeinformationen durch drei Sternchen („***“) ersetzt:

- [CreateDataSourceFromRDS](#)
- [CreateDataSourceFromRedshift](#)

Wenn die folgenden Amazon ML-Operationen mit der Amazon ML-Konsole ausgeführt werden, `ComputeStatistics` ist das Attribut nicht in der `RequestParameters` Komponente des CloudTrail Protokolls enthalten:

- [CreateDataSourceFromRedshift](#)
- [CreateDataSourceFromS3](#)

Jeder Ereignis- oder Protokolleintrag enthält Informationen zu dem Benutzer, der die Anforderung generiert hat. Die Identitätsinformationen unterstützen Sie bei der Ermittlung der folgenden Punkte:

- Ob die Anfrage mit Root- oder AWS Identity and Access Management (IAM-) Benutzeranmeldedaten gestellt wurde.
- Gibt an, ob die Anforderung mit temporären Sicherheitsanmeldeinformationen für eine Rolle oder einen Verbundbenutzer gesendet wurde.
- Ob die Anfrage von einem anderen AWS Dienst gestellt wurde.

Weitere Informationen finden Sie unter [CloudTrail userIdentity-Element](#).

Beispiel: Amazon ML-Protokolldateieinträge

Ein Trail ist eine Konfiguration, die die Übertragung von Ereignissen als Protokolldateien an einen von Ihnen angegebenen Amazon S3 S3-Bucket ermöglicht. CloudTrail Protokolldateien enthalten einen oder mehrere Protokolleinträge. Ein Ereignis stellt eine einzelne Anforderung aus einer beliebigen Quelle dar und enthält Informationen über die angeforderte Aktion, Datum und Uhrzeit der Aktion, Anforderungsparameter usw. CloudTrail Protokolldateien sind kein geordneter Stack-Trace der öffentlichen API-Aufrufe, sodass sie nicht in einer bestimmten Reihenfolge angezeigt werden.

Das folgende Beispiel zeigt einen CloudTrail Protokolleintrag, der die Aktion demonstriert.

```
{
  "Records": [
    {
      "eventVersion": "1.03",
```

```

    "userIdentity": {
      "type": "IAMUser",
      "principalId": "EX_PRINCIPAL_ID",
      "arn": "arn:aws:iam::012345678910:user/Alice",
      "accountId": "012345678910",
      "accessKeyId": "EXAMPLE_KEY_ID",
      "userName": "Alice"
    },
    "eventTime": "2015-11-12T15:04:02Z",
    "eventSource": "machinelearning.amazonaws.com",
    "eventName": "CreateDataSourceFromS3",
    "awsRegion": "us-east-1",
    "sourceIPAddress": "127.0.0.1",
    "userAgent": "console.amazonaws.com",
    "requestParameters": {
      "data": {
        "dataLocationS3": "s3://aml-sample-data/banking-batch.csv",
        "dataSchema": "{\"version\":\"1.0\",\"rowId\":null,\"rowWeight
\":null,
          \"targetAttributeName\":null,\"dataFormat\":\"CSV\",
          \"dataFileContainsHeader\":false,\"attributes\":[
            {\"attributeName\":\"age\",\"attributeType\":\"NUMERIC\"},
            {\"attributeName\":\"job\",\"attributeType\":\"CATEGORICAL
\"},
            {\"attributeName\":\"marital\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"education\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"default\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"housing\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"loan\",\"attributeType\":\"CATEGORICAL
\"},
            {\"attributeName\":\"contact\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"month\",\"attributeType\":\"CATEGORICAL
\"},
            {\"attributeName\":\"day_of_week\",\"attributeType\":
\"CATEGORICAL\"},
            {\"attributeName\":\"duration\",\"attributeType\":\"NUMERIC
\"},
            {\"attributeName\":\"campaign\",\"attributeType\":\"NUMERIC
\"},

```

```

        {"attributeName": "pdays", "attributeType": "NUMERIC"},
        {"attributeName": "previous", "attributeType": "NUMERIC
    },
        {"attributeName": "poutcome", "attributeType":
    "CATEGORICAL"},
        {"attributeName": "emp_var_rate", "attributeType":
    "NUMERIC"},
        {"attributeName": "cons_price_idx", "attributeType":
    "NUMERIC"},
        {"attributeName": "cons_conf_idx", "attributeType":
    "NUMERIC"},
        {"attributeName": "euribor3m", "attributeType": "NUMERIC
    },
        {"attributeName": "nr_employed", "attributeType":
    "NUMERIC"}
    ], "excludedAttributeNames": []}
  },
  "dataSourceId": "exampleDataSourceId",
  "dataSourceName": "Banking sample for batch prediction"
},
"responseElements": {
  "dataSourceId": "exampleDataSourceId"
},
"requestID": "9b14bc94-894e-11e5-a84d-2d2deb28fdec",
"eventID": "f1d47f93-c708-495b-bff1-cb935a6064b2",
"eventType": "AwsApiCall",
"recipientAccountId": "012345678910"
},
{
  "eventVersion": "1.03",
  "userIdentity": {
    "type": "IAMUser",
    "principalId": "EX_PRINCIPAL_ID",
    "arn": "arn:aws:iam::012345678910:user/Alice",
    "accountId": "012345678910",
    "accessKeyId": "EXAMPLE_KEY_ID",
    "userName": "Alice"
  },
  "eventTime": "2015-11-11T15:24:05Z",
  "eventSource": "machinelearning.amazonaws.com",
  "eventName": "CreateBatchPrediction",
  "awsRegion": "us-east-1",
  "sourceIPAddress": "127.0.0.1",
  "userAgent": "console.amazonaws.com",

```

```
    "requestParameters": {
      "batchPredictionName": "Batch prediction: ML model: Banking sample",
      "batchPredictionId": "exampleBatchPredictionId",
      "batchPredictionDataSourceId": "exampleDataSourceId",
      "outputUri": "s3://EXAMPLE_BUCKET/BatchPredictionOutput/",
      "mLModelId": "exampleModelId"
    },
    "responseElements": {
      "batchPredictionId": "exampleBatchPredictionId"
    },
    "requestID": "3e18f252-8888-11e5-b6ca-c9da3c0f3955",
    "eventID": "db27a771-7a2e-4e9d-bfa0-59deee9d936d",
    "eventType": "AwsApiCall",
    "recipientAccountId": "012345678910"
  }
]
}
```

Kennzeichnen Ihrer Amazon ML-Objekte

Organisieren und verwalten Sie Ihre Amazon Machine Learning (Amazon ML) -Objekte, indem Sie ihnen Metadaten mit Tags zuweisen. Ein Tag ist ein Schlüssel-Wert-Paar, das Sie für ein Objekt definieren.

Sie können nicht nur Tags verwenden, um Ihre Amazon ML-Objekte zu organisieren und zu verwalten, sondern auch, um Ihre AWS-Kosten zu kategorisieren und zu verfolgen. Wenn Sie Tags auf AWS-Objekte, einschließlich ML-Modellen, anwenden, enthält der AWS-Kostenzuordnungsbericht mit Tags aggregierte Nutzungs- und Kostendaten. Sie können Tags anwenden, die geschäftliche Kategorien (wie Kostenstellen, Anwendungsnamen oder Eigentümer) darstellen, um die Kosten für mehrere Services zu organisieren. Weitere Informationen finden Sie unter [Verwenden von Kostenzuordnungs-Tags für benutzerdefinierte Fakturierungsberichte](#) im AWS Billing - Benutzerhandbuch.

Inhalt

- [Grundlagen zu Tags](#)
- [Tag-Einschränkungen](#)
- [Taggen von Amazon ML-Objekten \(Konsole\)](#)
- [Taggen von Amazon ML-Objekten \(API\)](#)

Grundlagen zu Tags

Verwenden Sie Tags, um Ihre Objekte zu kategorisieren und somit einfacher zu verwalten. Sie können Objekte beispielsweise nach Zweck, Inhaber oder Umgebung kategorisieren. Sie könnten dann zum Beispiel eine Reihe von Tags definieren, mit der Sie Modelle nach Inhaber und zugehöriger Anwendung nachverfolgen können. Im Folgenden finden Sie einige Beispiele:

- Projekt: Projektname
- Inhaber: Name
- Zweck: Marketing-Voraussagen
- Anwendung: Anwendungsname
- Umgebung: Produktion

Sie verwenden die Amazon ML-Konsole oder API, um die folgenden Aufgaben zu erledigen:

- Hinzufügen von Tags zu einem Objekt
- Anzeigen der Tags für Ihre Objekte
- Bearbeiten der Tags für Ihre Objekte
- Löschen von Tags von einem Objekt

Standardmäßig werden Tags, die auf ein Amazon ML-Objekt angewendet wurden, in Objekte kopiert, die mit diesem Objekt erstellt wurden. Wenn beispielsweise eine Amazon Simple Storage Service (Amazon S3) -Datenquelle das Tag „Marketingkosten: Gezielte Marketingkampagne“ hat, hätte ein mit dieser Datenquelle erstelltes Modell auch das Tag „Marketingkosten: Gezielte Marketingkampagne“, ebenso wie die Bewertung für das Modell. Auf diese Weise können Sie Tags verwenden, um verwandte Objekte nachzuverfolgen, wie z. B. alle Objekte für eine Marketingkampagne. Wenn es einen Konflikt zwischen Tag-Quellen gibt, z. B. einem Modell mit dem Tag „Marketingkosten: Gezielte Marketingkampagne“ und einer Datenquelle mit dem Tag „Marketingkosten: Zielmarketingkunden“, wendet Amazon ML das Tag aus dem Modell an.

Tag-Einschränkungen

Für Tags gelten die folgenden Einschränkungen.

Grundlegende Einschränkungen:

- Die maximale Anzahl von Tags pro Objekt ist 50.
- Bei Tag-Schlüsseln und -Werten muss die Groß- und Kleinschreibung beachtet werden.
- Sie können Tags für ein gelöschttes Objekt nicht ändern oder bearbeiten.

Einschränkungen für Tag-Schlüssel:

- Jeder Tag-Schlüssel muss einmalig sein. Wenn Sie einen Tag mit einem Schlüssel hinzufügen, der bereits verwendet wird, wird das vorhandene Schlüssel-Wert-Paar durch den neuen Tag für dieses Objekt überschrieben.
- Sie können einen Tag-Schlüssel nicht mit `aws:` starten, da dieses Präfix für die Verwendung durch AWS reserviert ist. AWS erstellt zwar in Ihrem Namen Tags, die mit diesem Präfix beginnen, Sie können diese jedoch nicht bearbeiten oder löschen.
- Tag-Schlüssel müssen zwischen 1 und 128 Unicode-Zeichen lang sein.

- Tag-Schlüssel müssen die folgenden Zeichen enthalten: Unicode-Zeichen, Ziffern, Leerzeichen sowie die folgenden Sonderzeichen: `_ . / = + - @`.

Einschränkungen für den Tag-Wert:

- Tag-Werte müssen zwischen 0 und 255 Unicode-Zeichen lang sein.
- Tag-Werte können leer sein. Ansonsten müssen sie die folgenden Zeichen enthalten: Unicode-Zeichen, Ziffern, Leerzeichen und eines der folgenden Sonderzeichen: `_ . / = + - @`.

Taggen von Amazon ML-Objekten (Konsole)

Mit der Amazon ML-Konsole können Sie Tags anzeigen, hinzufügen, bearbeiten und löschen.

Anzeigen der Tags eines Objekts (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Erweitern Sie in der Navigationsleiste die Regionsauswahl und wählen Sie eine aus.
3. Wählen Sie auf der Seite Objekte ein Objekt.
4. Scrollen Sie zum Abschnitt Tags des gewählten Objekts. Die Tags für dieses Objekt sind im unteren Bereich des Abschnitts aufgeführt.

Hinzufügen eines Tags zu einem Objekt (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Erweitern Sie in der Navigationsleiste die Regionsauswahl und wählen Sie eine aus.
3. Wählen Sie auf der Seite Objekte ein Objekt.
4. Scrollen Sie zum Abschnitt Tags des gewählten Objekts. Die Tags für dieses Objekt sind im unteren Bereich des Abschnitts aufgeführt.
5. Wählen Sie Hinzufügen und Bearbeiten von Tags.
6. Geben Sie unter Tag hinzufügen in das Feld Schlüssel den Tag-Schlüssel ein. Optional können Sie auch einen Tag-Wert in das Feld Wert eingeben und dann Änderungen anwenden wählen.

Wenn die Schaltfläche Änderungen anwenden nicht aktiviert ist, entspricht entweder der angegebene Tag-Schlüssel oder Tag-Wert nicht den Tag-Einschränkungen. Weitere Informationen finden Sie unter [Tag-Einschränkungen](#).

7. Um Ihren neuen Tag in der Liste im Abschnitt Tags anzuzeigen, aktualisieren Sie die Seite.

So bearbeiten Sie ein Tag (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Erweitern Sie in der Navigationsleiste die Regionsauswahl und wählen Sie eine Region aus.
3. Wählen Sie auf der Seite Objekte ein Objekt.
4. Scrollen Sie zum Abschnitt Tags des gewählten Objekts. Die Tags für dieses Objekt sind im unteren Bereich des Abschnitts aufgeführt.
5. Wählen Sie Hinzufügen und Bearbeiten von Tags.
6. Bearbeiten Sie unter Angewandte Tags den Tag-Wert im Feld Wert und klicken Sie dann auf Änderungen anwenden.

Wenn die Schaltfläche Änderungen anwenden nicht aktiviert ist, entspricht der angegebene Tag-Wert nicht den Tag-Einschränkungen. Weitere Informationen finden Sie unter [Tag-Einschränkungen](#).

7. Um Ihr neues Tag in der Liste im Abschnitt Tags anzuzeigen, aktualisieren Sie die Seite.

Löschen eines Tags von einem Objekt (Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon Machine Learning Learning-Konsole unter <https://console.aws.amazon.com/machinelearning/>.
2. Erweitern Sie in der Navigationsleiste die Regionsauswahl und wählen Sie eine aus.
3. Wählen Sie auf der Seite Objekte ein Objekt.
4. Scrollen Sie zum Abschnitt Tags des gewählten Objekts. Die Tags für dieses Objekt sind im unteren Bereich des Abschnitts aufgeführt.
5. Wählen Sie Hinzufügen und Bearbeiten von Tags.
6. Klicken Sie unter Angewandte Tags auf das Tag, das Sie löschen möchten, und klicken Sie dann auf Änderungen anwenden.

Taggen von Amazon ML-Objekten (API)

Mit der Amazon ML-API können Sie Tags hinzufügen, auflisten und löschen. Beispiele finden Sie in der folgenden Dokumentation:

[AddTags](#)

Fügt Tags für das angegebene Objekt hinzu oder bearbeitet diese.

[DescribeTags](#)

Listet die Tags für das angegebene Objekt auf.

[DeleteTags](#)

Löscht Tags aus dem angegebenen Objekt.

Amazon Machine Learning-Referenz

Themen

- [Gewähren von Amazon ML-Berechtigungen zum Lesen von Daten aus Amazon S3](#)
- [Gewähren von Berechtigungen für Amazon ML zwecks Ausgabe von Voraussagen in Amazon S3](#)
- [Steuern des Zugriffs auf Amazon ML-Ressourcen – mit IAM](#)
- [Serviceübergreifende Confused-Deputy-Prävention](#)
- [Dependency Management von asynchrone Operationen](#)
- [Das Überprüfen des Status einer Anfrage](#)
- [Systemeinschränkungen](#)
- [Namen und IDs für alle Objekte](#)
- [Objektlebensdauer](#)

Gewähren von Amazon ML-Berechtigungen zum Lesen von Daten aus Amazon S3

Um aus Ihren Eingabedaten in Amazon S3 ein Datenquellenobjekt zu erstellen, müssen Sie Amazon ML die folgenden Berechtigungen für den S3-Speicherort erteilen, an dem Ihre Eingabedaten gespeichert sind:

- `GetObject`Berechtigung für den S3-Bucket und das Präfix.
- `ListBucket`Erlaubnis für den S3-Bucket. Im Gegensatz zu anderen Aktionen `ListBucket`müssen Berechtigungen für den gesamten Bucket erteilt werden (und nicht für das Präfix). Sie können die Berechtigungen jedoch auf ein bestimmtes Präfix einschränken, indem Sie eine `Condition`-Klausel verwenden.

Wenn Sie die Amazon ML-Konsole zum Erstellen der Datenquelle verwenden, können diese Berechtigungen für Sie dem Bucket hinzugefügt werden. Sie werden aufgefordert, zu bestätigen, ob Sie sie hinzufügen möchten, wenn Sie die Schritte im Assistenten ausführen. Die folgende Beispielrichtlinie zeigt, wie Sie Amazon ML die Erlaubnis erteilen, Daten vom Beispielspeicherort `s3://examplebucket/`zu lesen `exampleprefix`, während die `ListBucket`Berechtigung nur auf den Eingabepfad beschränkt wird. `exampleprefix`

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": "s3:GetObject",
      "Resource": "arn:aws:s3:::examplebucket/exampleprefix/*",
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "123456789012"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:*"
        }
      }
    },
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": "s3:ListBucket",
      "Resource": "arn:aws:s3:::examplebucket",
      "Condition": {
        "StringLike": {
          "s3:prefix": "exampleprefix/*"
        },
        "StringEquals": {
          "aws:SourceAccount": "123456789012"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:*"
        }
      }
    }
  ]
}
```

}

Um diese Richtlinie für Ihre Daten anzuwenden, müssen Sie die Richtlinienanweisung in Zusammenhang mit dem S3-Bucket, in dem Sie Ihre Daten gespeichert haben, bearbeiten.

Vorgehensweise zum Bearbeiten der Berechtigungsrichtlinie für einen S3-Bucket (unter Verwendung der alten Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Wählen Sie den Namen des Buckets aus, on dem sich Ihre daten befinden.
3. Wählen Sie Properties (Eigenschaften).
4. Wählen Sie Edit bucket policy.
5. Geben Sie die oben gezeigte Richtlinie ein, die Sie an Ihre Anforderungen anpassen sollten, und wählen Sie dann Save aus.
6. Wählen Sie Speichern.

Vorgehensweise zum Bearbeiten der Berechtigungsrichtlinie für einen S3-Bucket (unter Verwendung der neuen Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Wählen Sie den Bucket-Namen und dann Berechtigungen aus.
3. Wählen Sie Bucket Policy aus.
4. Geben Sie die oben gezeigte Richtlinie ein, die Sie an Ihre Anforderungen anpassen sollten.
5. Wählen Sie Speichern.

Gewähren von Berechtigungen für Amazon ML zwecks Ausgabe von Voraussagen in Amazon S3

Um die Ergebnisse der Stapelvoraussage-Operation in Amazon S3 auszugeben, müssen Sie Amazon ML die folgenden Berechtigungen für den Ausgabeort gewähren, die als Input bei der Operation zum Erstellen von Stapelvoraussagen bereitgestellt werden:

- getObjectErlaubnis für Ihren S3-Bucket und Ihr Präfix.
- PutObjectErlaubnis für Ihren S3-Bucket und Ihr Präfix.
- PutObjectAclauf Ihrem S3-Bucket und Präfix.
 - Amazon ML benötigt diese Berechtigung, um sicherzustellen, dass Ihrem AWS-Konto die [vorgemerkte bucket-owner-full-control ACL-Berechtigung](#) erteilt werden kann, nachdem Objekte erstellt wurden.
- ListBucketErlaubnis für den S3-Bucket. Im Gegensatz zu anderen Aktionen ListBucketmüssen Berechtigungen für den gesamten Bucket erteilt werden (und nicht für das Präfix). Sie können die Berechtigungen jedoch auf ein bestimmtes Präfix einschränken, indem Sie eine Bedingungsklausel verwenden.

Wenn Sie die Amazon ML-Konsole zum Erstellen der Stapelvoraussageanforderung verwenden, können diese Berechtigungen für Sie dem Bucket hinzugefügt werden. Sie werden aufgefordert, zu bestätigen, ob Sie diese hinzufügen möchten, wenn Sie die Schritte im Assistenten ausführen.

Die folgende Beispielrichtlinie zeigt, wie Amazon ML die Erlaubnis erteilt wird, Daten an den Beispielspeicherort `s3://examplebucket/exampleprefix` zu schreiben, wobei die ListBucketBerechtigung nur auf den Beispielpräfix-Eingabepfad beschränkt wird und Amazon ML die Erlaubnis erteilt wird, das Put-Objekt ACLs auf das Ausgabepräfix zu setzen:

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": [
        "s3:GetObject",
        "s3:PutObject"
      ],
      "Resource": "arn:aws:s3:::examplebucket/exampleprefix/*",
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "123456789012"
        }
      }
    }
  ]
}
```

```

        "ArnLike": {
            "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:*"
        }
    },
    {
        "Effect": "Allow",
        "Principal": {
            "Service": "machinelearning.amazonaws.com"
        },
        "Action": "s3:PutObjectAcl",
        "Resource": "arn:aws:s3:::examplebucket/exampleprefix/*",
        "Condition": {
            "StringEquals": {
                "aws:SourceAccount": "123456789012"
            },
            "ArnLike": {
                "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:*"
            }
        }
    },
    {
        "Effect": "Allow",
        "Principal": {
            "Service": "machinelearning.amazonaws.com"
        },
        "Action": "s3:ListBucket",
        "Resource": "arn:aws:s3:::examplebucket",
        "Condition": {
            "StringLike": {
                "s3:prefix": "exampleprefix/*"
            },
            "StringEquals": {
                "aws:SourceAccount": "123456789012"
            },
            "ArnLike": {
                "aws:SourceArn": "arn:aws:machinelearning:us-
east-1:123456789012:*"
            }
        }
    }
}
]

```

}

Um diese Richtlinie für Ihre Daten anzuwenden, müssen Sie die Richtlinienanweisung in Zusammenhang mit dem S3-Bucket, in dem Sie Ihre Daten gespeichert haben, bearbeiten.

Vorgehensweise zum Bearbeiten der Berechtigungsrichtlinie für einen S3-Bucket (unter Verwendung der alten Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Wählen Sie den Namen des Buckets aus, on dem sich Ihre daten befinden.
3. Wählen Sie Properties (Eigenschaften).
4. Wählen Sie Edit bucket policy.
5. Geben Sie die oben gezeigte Richtlinie ein, die Sie an Ihre Anforderungen anpassen sollten, und wählen Sie dann Save aus.
6. Wählen Sie Speichern.

Vorgehensweise zum Bearbeiten der Berechtigungsrichtlinie für einen S3-Bucket (unter Verwendung der neuen Konsole)

1. Melden Sie sich bei der an AWS-Managementkonsole und öffnen Sie die Amazon S3 S3-Konsole unter <https://console.aws.amazon.com/s3/>.
2. Wählen Sie den Bucket-Namen und dann Berechtigungen aus.
3. Wählen Sie Bucket Policy aus.
4. Geben Sie die oben gezeigte Richtlinie ein, die Sie an Ihre Anforderungen anpassen sollten.
5. Wählen Sie Speichern.

Steuern des Zugriffs auf Amazon ML-Ressourcen – mit IAM

AWS Identity and Access Management (IAM) ermöglicht es Ihnen, den Zugriff Ihrer Benutzer auf AWS-Services und -Ressourcen sicher zu kontrollieren. Mit IAM können Sie AWS-Benutzer, -Gruppen und -Rollen erstellen und verwalten und ihnen mithilfe von Berechtigungen den Zugriff auf AWS-Ressourcen gewähren oder verweigern. Durch die Verwendung von IAM mit Amazon Machine Learning (Amazon ML) können Sie steuern, ob Benutzer in Ihrer Organisation bestimmte

AWS-Ressourcen verwenden können und ob sie eine Aufgabe mithilfe bestimmter Amazon ML-API-Aktionen ausführen können.

IAM ermöglicht Ihnen:

- Erstellen von Benutzern und Gruppen für Ihr AWS-Konto
- Zuweisen eindeutiger Sicherheitsanmeldeinformationen zu jedem Benutzer in Ihrem AWS-Konto
- Steuern der Berechtigungen der einzelnen Benutzer zum Durchführen von Aufgaben mit AWS-Ressourcen
- Einfache Freigabe Ihrer AWS-Ressourcen unter den Benutzern Ihres AWS-Kontos
- Erstellen von Rollen für Ihr AWS-Konto und Verwalten ihrer Berechtigungen, um festzulegen, welche Benutzer oder Services sie übernehmen können
- Sie können Rollen in IAM erstellen und Berechtigungen verwalten, um zu steuern, welche Operationen von einer Entität oder einem AWS-Service mit der Rolle ausgeführt werden können. Sie können auch bestimmen, welcher Entität die Rolle zugeordnet werden darf.

Wenn Ihre Organisation bereits über IAM-Identitäten verfügt, können Sie diese für die Gewährung von Berechtigungen zur Ausführung von Aufgaben mit AWS-Ressourcen verwenden.

Weitere Informationen zu IAM finden Sie im [IAM-Benutzerhandbuch](#).

Syntax der IAM-Richtlinie

Eine IAM-Richtlinie ist ein JSON-Dokument, das eine oder mehrere Anweisungen enthält. Jeder Anweisung hat die folgende Struktur:

```
{
  "Statement": [{
    "Effect": "effect",
    "Action": "action",
    "Resource": "arn",
    "Condition": {
      "condition operator": {
        "key": "value"
      }
    }
  }]
}
```

Eine Richtlinienanweisung umfasst die folgenden Elemente:

- **Wirkung:** Steuert die Berechtigung zur Verwendung von Ressourcen und API-Aktionen, die Sie später in der Anweisung angeben. Gültige Werte sind `Allow` und `Deny`. IAM-Benutzer verfügen standardmäßig nicht über die Berechtigung zur Verwendung von Ressourcen und API-Aktionen. Daher werden alle Anfragen abgelehnt. Der Standardwert wird durch eine explizite Erlaubnis (`Allow`) überschrieben. Eine explizite Verweigerung (`Deny`) überschreibt alle Erlaubnisse (`Allows`).
- **Aktion:** Die spezifische(n) API-Aktion oder -Aktionen, für die Sie eine Berechtigung gewähren oder verweigern.
- **Resource:** Die von einer Aktion betroffene Ressource. Um eine Ressource in der Anweisung anzugeben, verwenden Sie deren Amazon-Ressourcennamen (ARN).
- **Bedingung (optional):** Steuert, wann Ihre Richtlinie in Kraft tritt.

Um die Erstellung und Verwaltung von IAM-Richtlinien zu vereinfachen, können Sie den AWS Policy Generator und den IAM Policy Simulator verwenden.

Spezifizieren von IAM-Richtlinienaktionen für Amazon ML MLAmazon

In einer IAM-Richtlinienerklärung können Sie eine API-Aktion für jeden Service angeben, der IAM unterstützt. Wenn Sie eine Richtlinienerklärung für Amazon ML-API-Aktionen erstellen, stellen Sie `machinelearning:` sie dem Namen der API-Aktion voran, wie in den folgenden Beispielen gezeigt:

- `machinelearning:CreateDataSourceFromS3`
- `machinelearning:DescribeDataSources`
- `machinelearning>DeleteDataSource`
- `machinelearning:GetDataSource`

Um mehrere Aktionen in einer einzigen Anweisung anzugeben, trennen Sie sie mit Kommata:

```
"Action": ["machinelearning:action1", "machinelearning:action2"]
```

Sie können auch mehrere Aktionen mittels Platzhaltern angeben. Beispielsweise können Sie alle Aktionen festlegen, deren Name mit dem Wort "Get" beginnt:

```
"Action": "machinelearning:Get*"
```

Um alle Amazon ML-Aktionen anzugeben, verwenden Sie den Platzhalter `*`:

```
"Action": "machinelearning:*"
```

Die vollständige Liste der Amazon ML-API-Aktionen finden Sie in der [Amazon Machine Learning API-Referenz](#).

Angabe von ARNs Amazon ML-Ressourcen in IAM-Richtlinien

IAM-Richtlinienerklärungen gelten für eine oder mehrere Ressourcen. Sie spezifizieren die Ressourcen für Ihre Richtlinien anhand ihrer ARNs.

Verwenden Sie das folgende Format, um die ARNs für Amazon ML-Ressourcen anzugeben:

```
"Ressource": arn:aws:machinelearning:region:account:resource-type/identifizier
```

Die folgenden Beispiele zeigen, wie „common“ angegeben wird ARNs.

Datenquellen-ID: my-s3-datasource-id

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:datasource/my-s3-datasource-id
```

ML-Modell-ID: my-ml-model-id

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:mlmodel/my-ml-model-id
```

Stapelvoraussage-ID: my-batchprediction-id

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:batchprediction/my-batchprediction-  
id
```

Evaluierungs-ID: my-evaluation-id

```
"Resource": arn:aws:machinelearning:<region>:<your-account-id>:evaluation/my-  
evaluation-id
```

Beispielrichtlinien für Amazon MLs

Beispiel 1: Benutzern das Lesen der Metadaten von Ressourcen für maschinelles Lernen erlauben

Die folgende Richtlinie ermöglicht es einem Benutzer oder einer Gruppe, die Metadaten von Datenquellen, ML-Modellen, Batch-Vorhersagen und Evaluierungen zu lesen

[DescribeDataSources](#), indem sie Aktionen MLModels [DescribeBatchPredictions](#), [DescribeDescribeEvaluationsGetDataSource](#), MLModel, [Get GetBatchPrediction](#), und [GetEvaluation](#) Aktionen für die angegebenen Ressourcen ausführen. Die Describe *-Operationsberechtigungen können nicht auf eine bestimmte Ressource beschränkt werden.

JSON

```
{ "Version": "2012-10-17",      "Statement": [ { "Effect": "Allow", "Action": [
  "machinelearning:Get*" ], "Resource": [
    "arn:aws:machinelearning:us-east-1:123456789012:datasource/S3-DS-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:datasource/REDSHIFT-DS-
ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:mlmodel/ML-MODEL-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:batchprediction/BP-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:evaluation/EV-ID1"
  ] }, { "Effect": "Allow", "Action": [ "machinelearning:Describe*" ],
  "Resource": [ "*" ] } ]
}
```

Beispiel 2: Benutzern das Erstellen von Ressourcen für maschinelles Lernen erlauben

Die folgende Richtlinie erlaubt es einem Benutzer oder einer Gruppe, Machine Learning-Datenquellen, ML-Modelle, Stapelvorhersagen und Evaluierungen durch Ausführung der `CreateDataSourceFromS3`-, `CreateDataSourceFromRedshift`-, `CreateDataSourceFromRDS`-, `CreateMLModel`-, `CreateBatchPrediction`- und `CreateEvaluation`-Aktionen zu erstellen. Sie können die Berechtigungen für diese Aktionen nicht auf eine bestimmte Ressource einschränken.

JSON

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

```

    {
      "Effect": "Allow",
      "Action": [
        "machinelearning:CreateDataSourceFrom*",
        "machinelearning:CreateMLModel",
        "machinelearning:CreateBatchPrediction",
        "machinelearning:CreateEvaluation"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}

```

Beispiel 3: Benutzer das Erstellen und Löschen von Echtzeitendpunkten sowie das Ausführen von Echtzeitvoraussagen mit einem ML-Modell erlauben

Die folgende Richtlinie erlaubt es Benutzern oder Gruppen, Echtzeitendpunkte zu erstellen und zu löschen sowie Echtzeitvoraussagen für ein bestimmtes ML-Modell zu generieren, indem sie `CreateRealtimeEndpoint`-, `DeleteRealtimeEndpoint`- und `Predict`-Aktionen für dieses Modell ausführen.

JSON

```

{ "Version":"2012-10-17",      "Statement": [ { "Effect": "Allow", "Action": [
  "machinelearning:CreateRealtimeEndpoint",
  "machinelearning>DeleteRealtimeEndpoint",
  "machinelearning:Predict" ], "Resource": [
    "arn:aws:machinelearning:us-east-1:123456789012:mlmodel/ML-MODEL"
  ] } ] }

```

Beispiel 4: Benutzern das Aktualisieren und Löschen bestimmter Ressourcen erlauben

Die folgende Richtlinie erlaubt es einem Benutzer oder einer Gruppe, bestimmte Ressourcen in Ihrem AWS-Konto zu aktualisieren oder zu löschen, indem die Berechtigungen zum Ausführen von `UpdateDataSource`-, `UpdateMLModel`-, `UpdateBatchPrediction`-, `UpdateEvaluation`-, `DeleteDataSource`-, `DeleteMLModel`-, `DeleteBatchPrediction`- und `DeleteEvaluation`-Aktionen für diese Ressourcen in Ihrem Konto gewährt werden.

JSON

```
{ "Version":"2012-10-17",      "Statement": [ { "Effect": "Allow", "Action": [
    "machinelearning:Update*", "machinelearning:DeleteDataSource",
    "machinelearning:DeleteMLModel",
    "machinelearning:DeleteBatchPrediction",
    "machinelearning:DeleteEvaluation" ], "Resource": [
    "arn:aws:machinelearning:us-east-1:123456789012:datasource/S3-DS-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:datasource/REDSHIFT-DS-
ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:mlmodel/ML-MODEL-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:batchprediction/BP-ID1",
    "arn:aws:machinelearning:us-east-1:123456789012:evaluation/EV-ID1"
    ] } ] }
```

Beispiel 5: Beliebiges Amazon zulassen MLAction

Die folgende Richtlinie ermöglicht es einem Benutzer oder einer Gruppe, jede Amazon ML-Aktion zu verwenden. Da diese Richtlinie vollen Zugriff auf alle Ihre Ressourcen für maschinelles Lernen gewährt, sollten Sie sie auf Administratoren beschränken.

JSON

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

Serviceübergreifende Confused-Deputy-Prävention

Das Confused-Deputy-Problem ist ein Sicherheitsproblem, bei dem eine juristische Stelle, die nicht über die Berechtigung zum Ausführen einer Aktion verfügt, eine privilegiertere juristische Stelle zwingen kann, die Aktion auszuführen. Ein AWS dienstübergreifender Identitätswechsel kann zu einem Problem mit dem verwirrten Stellvertreter führen. Ein dienstübergreifender Identitätswechsel kann auftreten, wenn ein Dienst (der Anruf-Dienst) einen anderen Dienst anruft (den aufgerufenen Dienst). Der aufrufende Service kann manipuliert werden, um seine Berechtigungen zu verwenden, um Aktionen auf die Ressourcen eines anderen Kunden auszuführen, für die er sonst keine Zugriffsberechtigung haben sollte. Um dies zu verhindern, bietet AWS Tools, mit denen Sie Ihre Daten für alle Services mit Serviceprinzipalen schützen können, die Zugriff auf Ressourcen in Ihrem Konto erhalten haben.

Wir empfehlen, die Kontextschlüssel `aws:SourceArn` und die `aws:SourceAccount` globalen Bedingungsschlüssel in Ressourcenrichtlinien zu verwenden, um die Berechtigungen einzuschränken, die Amazon Machine Learning einem anderen Service für die Ressource erteilt. Wenn der `aws:SourceArn`-Wert die Konto-ID nicht enthält, z. B. einen Amazon-S3-Bucket-ARN, müssen Sie beide globale Bedingungskontextschlüssel verwenden, um Berechtigungen einzuschränken. Wenn Sie beide globale Bedingungskontextschlüssel verwenden und der `aws:SourceArn`-Wert die Konto-ID enthält, müssen der `aws:SourceAccount`-Wert und das Konto im `aws:SourceArn`-Wert dieselbe Konto-ID verwenden, wenn sie in der gleichen Richtlinienanweisung verwendet wird. Verwenden Sie `aws:SourceArn`, wenn Sie nur eine Ressource mit dem betriebsübergreifenden Zugriff verknüpfen möchten. Verwenden Sie `aws:SourceAccount`, wenn Sie zulassen möchten, dass Ressourcen in diesem Konto mit der betriebsübergreifenden Verwendung verknüpft werden.

Der effektivste Weg, um sich vor dem Confused-Deputy-Problem zu schützen, ist die Verwendung des globalen Bedingungskontext-Schlüssels `aws:SourceArn` mit dem vollständigen ARN der Ressource. Wenn Sie den vollständigen ARN der Ressource nicht kennen oder wenn Sie mehrere Ressourcen angeben, verwenden Sie den globalen Bedingungskontext-Schlüssel `aws:SourceArn` mit Platzhaltern (*) für die unbekanntenen Teile des ARN. Beispiel, `arn:aws:service:*:123456789012:*`.

Das folgende Beispiel zeigt, wie Sie die Kontextschlüssel `aws:SourceArn` und die `aws:SourceAccount` globalen Bedingungsschlüssel in Amazon ML verwenden können, um das Problem des verwirrten Stellvertreters beim Lesen von Daten aus einem Amazon S3 S3-Bucket zu vermeiden.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": "s3:GetObject",
      "Resource": "arn:aws:s3:::examplebucket/exampleprefix/*",
      "Condition": {
        "StringEquals": {
          "aws:SourceAccount": "123456789012"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:machinelearning:us-east-1:123456789012:*"
        }
      }
    },
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "machinelearning.amazonaws.com"
      },
      "Action": "s3:ListBucket",
      "Resource": "arn:aws:s3:::examplebucket",
      "Condition": {
        "StringLike": {
          "s3:prefix": "exampleprefix/*"
        },
        "StringEquals": {
          "aws:SourceAccount": "123456789012"
        },
        "ArnLike": {
          "aws:SourceArn": "arn:aws:machinelearning:us-east-1:123456789012:*"
        }
      }
    }
  ]
}
```

}

Dependency Management von asynchrone Operationen

Batch-Operationen in Amazon ML hängen von anderen Operationen ab, um erfolgreich abgeschlossen werden zu können. Um diese Abhängigkeiten zu verwalten, identifiziert Amazon ML Anfragen, die Abhängigkeiten aufweisen, und prüft, ob die Operationen abgeschlossen wurden. Wenn die Operationen nicht abgeschlossen wurden, wird die entsprechende Anfrage von Amazon ML so lange zurückgestellt, bis die Operationen, von denen sie abhängen, abgeschlossen wurden.

Es gibt einige Abhängigkeiten zwischen Batch-Operationen. Bevor Sie beispielsweise ein ML-Modell erstellen können, müssen Sie eine Datenquelle erstellt haben, mit der Sie das ML-Modell schulen können. Amazon ML kann ein ML-Modell nicht ohne verfügbare Datenquelle schulen.

Amazon ML unterstützt jedoch das Abhängigkeiten-Management für asynchrone Operationen. Beispielsweise müssen Sie nicht warten, bis die Statistiken berechnet wurden, bevor Sie eine Anforderung senden können, um ein ML-Modell für die Datenquelle zu schulen. Stattdessen können Sie, sobald die Datenquelle erstellt wurde, eine Anforderung senden, um ein ML-Modell mit der Datenquelle zu schulen. Amazon ML startet den Schulungsvorgang erst, nachdem die Datenquellenstatistiken berechnet wurden. Die MLModel Erstellungsanforderung wird in eine Warteschlange gestellt, bis die Statistiken berechnet wurden. Sobald dies erledigt ist, versucht Amazon ML sofort, den MLModel Erstellungsvorgang auszuführen. Ebenso können Sie Anfragen für Stapelvoraussagen und Überprüfungen für ML-Modelle senden, welche die Schulung noch nicht beendet haben.

Die folgende Tabelle zeigt die Anforderungen zur Weiterverarbeitung von verschiedenen AmazonML Aktionen

Um ...	Muss ...
Erstellen Sie ein ML-Modell (createMLModel)	Eine Datenquelle mit berechneten Datenstatistiken vorhanden sein
Erstellen Sie eine Batch-Vorhersage (createBatchPrediction)	Eine Datenquelle vorhanden sein ML-Modell

Um ...	Muss ...
Erstellen Sie eine Batch-Auswertung (createBatchEvaluation)	Eine Datenquelle vorhanden sein ML-Modell

Das Überprüfen des Status einer Anfrage

Wenn Sie eine Anfrage einreichen, können Sie ihren Status mit der Amazon Machine Learning (Amazon ML) API überprüfen. Wenn Sie beispielsweise eine `createMLModel` Anfrage einreichen, können Sie ihren Status mithilfe des `describeMLModel` Anrufs überprüfen. Amazon ML antwortet mit einem der folgenden Status.

Status	Definition
PENDING	<p>Amazon ML validiert die Anfrage.</p> <p>ODER</p> <p>Amazon ML wartet vor der Ausführung der Anfrage auf freiwerdende Rechenressourcen. Dies kann auftreten, wenn Ihr Konto die maximale Anzahl gleichzeitig ausgeführter Batch-Operation-Anfragen überschreitet. Wenn dies der Fall ist, wechselt der Status zu dem <code>InProgressZeitpunkt</code>, zu dem andere laufende Anfragen abgeschlossen wurden oder storniert wurden.</p> <p>ODER</p> <p>Amazon ML wartet eine Batch-Operation, die Ihre Anfrage benötigt, um abgeschlossen zu werden.</p>
INPROGRESS	Ihre Anfrage wird noch ausgeführt.
COMPLETED	Die Anfrage wurde abgeschlossen, und das Objekt ist bereit zur Verwendung (ML-Modelle und Datenquellen) oder Überprüfung (Stapelvoraussagen und -Auswertungen).

Status	Definition
FEHLGESCHLAGEN	Es besteht ein Problem mit den Daten, die Sie zur Verfügung gestellt haben, oder Sie haben den Vorgang abgebrochen. Wenn Sie beispielsweise versuchen, Datenstatistiken auf einer Datenquelle zu berechnen, die nicht abgeschlossen wurde, erhalten Sie möglicherweise die Statusmeldung Invalid oder Failed. Die Fehlermeldung erklärt, warum der Vorgang nicht erfolgreich abgeschlossen wurde.
GELÖSCHT	Das Objekt wurde bereits gelöscht.

Amazon ML stellt auch Informationen zu einem Objekt bereit, z. B. wann Amazon ML die Erstellung dieses Objekts abgeschlossen hat. Weitere Informationen finden Sie unter [Auflisten von Objekten](#).

Systemeinschränkungen

Um einen robuste, zuverlässigen Service bereitzustellen, gelten Amazon ML bestimmte Einschränkungen hinsichtlich der Anfragen, die an das System gestellt werden. Ein Großteil der ML-Probleme fällt in diese Einschränkungen. Wenn Sie jedoch der Ansicht sind, dass Ihre Nutzung von Amazon ML durch diese Einschränkungen eingeschränkt wird, können Sie sich an den [AWS-Kundenservice](#) wenden und die Anfrage stellen, dass eine Einschränkung gelockert wird. Vielleicht gibt es beispielsweise eine Begrenzung von 5 für die Anzahl von Aufträgen, die Sie gleichzeitig ausführen können. Wenn Sie feststellen, dass sich häufig Aufträge in der Warteschlange befinden, die aufgrund dieser Einschränkung auf Ressourcen warten, so ist es wahrscheinlich sinnvoller, diese Einschränkung für Ihr Konto zu lockern.

In der folgenden Tabelle sind standardmäßige Einschränkungen pro Konto in Amazon ML aufgeführt. Nicht all diese Einschränkungen können vom AWS-Kundenservice gelockert werden.

Einschränkungstyp	Systemeinschränkungen
Größe der einzelnen Beobachtungen	100 KB
Größe der Schulungsdaten*	100 GB

Einschränkungstyp	Systemeinschränkungen
Eingabegröße für Stapelvoraussage	1 TB
Eingabegröße für Stapelvoraussage (Anzahl Datensätze)	100 Mio.
Anzahl der Variablen in einer Datendatei (Schema)	1.000
Rezeptkomplexität (Anzahl verarbeiteter Ausgabevariablen)	10.000
TPS für jeden Echtzeitvoraussage-Endpunkt	200
TPS insgesamt für alle Echtzeitvoraussage-Endpunkte	10.000
RAM insgesamt für alle Echtzeitprognose-Endpunkte	10 GB
Anzahl gleichzeitiger Aufträge	25
Längste Laufzeit für jeden Auftrag	7 Tage
Anzahl Klassen für Mehrklassen-ML-Modelle	100
Größe ML-Modell	Mindestens 1 MB, maximal 2 GB
Anzahl von Tags pro Objekt	50

- Die Größe Ihrer Datendateien ist begrenzt, um sicherzustellen, dass Aufträge rechtzeitig abgeschlossen werden. Aufträge, die seit mehr als sieben Tagen ausgeführt werden, werden automatisch mit dem Status FEHLGESCHLAGEN beendet.

Namen und IDs für alle Objekte

Alle Objekte in Amazon ML müssen über eine ID verfügen. Die Amazon ML-Konsole generiert ID-Werte für Sie. Wenn Sie die API verwenden, müssen Sie jedoch Ihre eigenen generieren. Jede ID muss eindeutig innerhalb der Amazon ML-Objekte desselben Typs in Ihrem AWS-Konto sein. Sie können also nicht zwei Evaluierungen mit derselben ID haben. Es ist möglich, eine Evaluierung und eine Datenquelle mit der gleichen ID zu haben, dies wird aber nicht empfohlen.

Wir empfehlen, dass Sie zufällig generierte IDs für Ihre Objekte verwenden, mit einer kurzen Zeichenfolge zur Identifizierung des Typs als Präfix. Wenn die Amazon ML-Konsole beispielsweise eine Datenquelle generiert, weist sie der Datenquelle eine zufällige, eindeutige ID wie „ds-Zsc F“ zu. Wlu WiOx Diese ID ist ausreichend zufällig, um Kollisionen für einen einzelnen Benutzer zu vermeiden, und gleichzeitig kompakt und lesbar. Das Präfix "ds" ist aus praktischen Gründen und für die Klarheit vorhanden, aber nicht erforderlich. Wenn Sie sich nicht sicher sind, was Sie für Ihre ID-Strings verwenden sollen, empfehlen wir die Verwendung von hexadezimalen UUID-Werten (wie 28b1e915-57e5-4e6c-a7bd-6fb4e729cb23), die in modernen Programmierungsumgebungen problemlos verfügbar sind.

ID-Zeichenfolgen können ASCII-Buchstaben, Ziffern, Bindestriche und Unterstriche enthalten und bis zu 64 Zeichen lang sein. Es ist möglich und vielleicht auch praktisch, Metadaten in eine ID-Zeichenfolge zu codieren. Es wird aber nicht empfohlen, da nach Erstellung eines Objekts seine ID nicht geändert werden kann.

Objektnamen bieten eine einfache Möglichkeit für Sie, den einzelnen Objekten benutzerfreundliche Metadaten zuzuordnen. Namen könne nach der Erstellung eines Objekts geändert werden. Dadurch ist es möglich, einige Aspekte Ihres ML-Workflows im Namen eines Objekts wiederzugeben. Sie können einem ML-Modell beispielsweise zu Beginn den Namen "Experiment 3" geben und es dann in "Finales Produktionsmodell" umbenennen. Namen können aus einer beliebigen Zeichenfolge mit bis zu 1 024 Zeichen bestehen.

Objektlebensdauer

Sie können von Ihnen mit Amazon ML erstellte Datenquellen, ML-Modelle, Auswertungen oder Batch-Voraussageobjekte mindestens zwei Jahre lang verwenden. Amazon ML entfernt möglicherweise automatisch Objekte, auf die länger als zwei Jahre nicht zugegriffen wurde bzw. die in diesem Zeitraum nicht verwendet wurden.

Ressourcen

Die folgenden verwandten Ressourcen bieten Ihnen nützliche Informationen für die Arbeit mit diesem Service.

- [Amazon ML-Produktinformationen](#) — Erfasst alle relevanten Produktinformationen zu Amazon ML an einem zentralen Ort.
- [Amazon ML FAQs](#) — Behandelt die wichtigsten Fragen, die Entwickler zu diesem Produkt gestellt haben.
- [Amazon ML-Beispielcode](#) — Beispielanwendungen, die Amazon ML verwenden. Sie können den Beispielcode als Ausgangspunkt zur Erstellung Ihrer eigenen ML-Anwendungen verwenden.
- [Amazon ML API-Referenz](#) — Beschreibt alle API-Operationen für Amazon ML im Detail. Enthält darüber hinaus Beispiele für Anforderungen und Antworten für die unterstützten Web-Service-Protokolle.
- [AWS Developer Resource Center](#) — Bietet einen zentralen Ausgangspunkt für die Suche nach Dokumentation, Codebeispielen, Versionshinweisen und anderen Informationen, die Sie bei der Entwicklung innovativer Anwendungen mit AWS unterstützen.
- [AWS-Schulungen und -Kurse](#) — Links zu rollen- und Spezialkursen sowie Übungen zum Selbststudium, mit denen Sie Ihre AWS-Fähigkeiten verbessern und praktische Erfahrung sammeln können.
- [AWS-Entwicklertools](#) – Links zu Entwicklertools und -Ressourcen mit Dokumentationen, Codebeispielen, Versionshinweisen und sonstigen Informationen für die Entwicklung innovativer Anwendungen mit AWS.
- [AWS Support Center](#) — Die zentrale Anlaufstelle für die Erstellung und Verwaltung Ihrer AWS-Supportfälle. Enthält auch Links zu anderen hilfreichen Ressourcen wie Foren, technischen Informationen FAQs, Service Health Status und AWS Trusted Advisor.
- [AWS Support](#) — Die wichtigste Webseite mit Informationen zu AWS Support, einem Support-Kanal mit schnellen Reaktionszeiten one-on-one, der Sie bei der Entwicklung und Ausführung von Anwendungen in der Cloud unterstützt.
- [Kontaktieren Sie uns](#) — Eine zentrale Anlaufstelle für Anfragen zu AWS-Rechnungen, Ihrem Konto, Ereignissen, Missbrauch und anderen Problemen.
- [Nutzungsbedingungen für die AWS-Website](#) – Detaillierte Informationen zu unseren Copyright- und Markenbestimmungen, Ihrem Konto, den Lizenzen und anderen Themen.

Dokumentverlauf

In der folgenden Tabelle werden die wichtigen Änderungen an der Dokumentation in dieser Version von Amazon Machine Learning (Amazon ML) beschrieben.

- API-Version: 2015-04-09
- Letzte Aktualisierung der Dokumentation: 02.08.2016

Änderung	Beschreibung	Änderungsdatum
Metriken hinzugefügt	Diese Version von Amazon ML fügt neue Metriken für Amazon ML-Objekte hinzu. Weitere Informationen finden Sie unter Auflisten von Objekten .	2. August 2016
Mehrere Objekte löschen	Diese Version von Amazon ML bietet die Möglichkeit, mehrere Amazon ML-Objekte zu löschen. Weitere Informationen finden Sie unter Löschen von Objekten .	20. Juli 2016
Tagging hinzugefügt	Diese Version von Amazon ML bietet die Möglichkeit, Tags auf Amazon ML-Objekte anzuwenden. Weitere Informationen finden Sie unter Kennzeichnen Ihrer Amazon ML-Objekte .	23. Juni 2016
Amazon Redshift Redshift-Datenquellen kopieren	Diese Version von Amazon ML bietet die Möglichkeit, Amazon Redshift Redshift-Datenquelleneinstellungen in eine neue Amazon Redshift Redshift-Datenquelle zu kopieren. Weitere Informationen zum Kopieren von Amazon Redshift Redshift-Datenquelleneinstellungen finden Sie unter Kopieren einer Datenquelle (Konsole)	11. April 2016
Shuffling hinzugefügt	Diese Version von Amazon ML bietet die Möglichkeit, Ihre Eingabedaten zu mischen.	5. April 2016

Änderung	Beschreibung	Änderungsdatum
	<p>Weitere Informationen zur Verwendung des Parameters <code>Art der Mischung</code> finden Sie unter Art der Mischung von Schulungsdaten.</p>	
<p>Verbesserte Erstellung von Datenquellen mit Amazon Redshift</p>	<p>Diese Version von Amazon ML bietet die Möglichkeit, Ihre Amazon Redshift Redshift-Einstellungen zu testen, wenn Sie eine Amazon ML-Datenquelle in der Konsole erstellen, um zu überprüfen, ob die Verbindung funktioniert. Weitere Informationen finden Sie unter Erstellen einer Datenquelle mit Amazon Redshift Redshift-Daten (Konsole).</p>	<p>21. März 2016</p>
<p>Verbesserte Amazon Redshift Redshift-Datenschemakonvertierung</p>	<p>Diese Version von Amazon ML verbessert die Konvertierung von Amazon Redshift (Amazon Redshift) -Datenschemas in Amazon ML-Datenschemas.</p> <p>Weitere Informationen zur Verwendung von Amazon Redshift mit Amazon ML finden Sie unter Erstellen einer Amazon ML-Datenquelle aus Daten in Amazon Redshift.</p>	<p>9. Februar 2016</p>
<p>CloudTrail Protokollierung hinzugefügt</p>	<p>Diese Version von Amazon ML bietet die Möglichkeit, Anfragen mit AWS CloudTrail (CloudTrail) zu protokollieren.</p> <p>Weitere Informationen zur Verwendung der CloudTrail Protokollierung finden Sie unter Protokollieren von Amazon ML-API-Aufrufen mit AWS CloudTrail.</p>	<p>10. Dezember 2015</p>
<p>Zusätzliche DataRearrangement Optionen wurden hinzugefügt</p>	<p>Diese Version von Amazon ML bietet die Möglichkeit, Ihre Eingabedaten nach dem Zufallsprinzip aufzuteilen und ergänzende Datenquellen zu erstellen.</p> <p>Weitere Informationen zur Verwendung des <code>DataRearrangement</code> Parameters finden Sie unter Neuordnung von Daten Weitere Informationen zur Verwendung der neuen Optionen für die Kreuzvalidierung finden Sie unter Kreuzvalidierung.</p>	<p>3. Dezember 2015</p>

Änderung	Beschreibung	Änderungsdatum
Testen von Echtzeitvoraussagen	<p>Diese Version von Amazon ML bietet die Möglichkeit, Vorhersagen in Echtzeit in der Servicekonsole auszuprobieren.</p> <p>Weitere Informationen zum Testen von Prognosen in Echtzeit finden Sie Anfordern von Echtzeitvoraussagen im Amazon Machine Learning Developer Guide.</p>	19. November 2015
Neue -Region	<p>Diese Version von Amazon ML bietet Unterstützung für die Region EU (Irland).</p> <p>Weitere Informationen zu Amazon ML in der Region EU (Irland) finden Sie Regionen und Endpunkte im Amazon Machine Learning Developer Guide.</p>	20. August 2015
Erstversion	Dies ist die erste Version des Amazon ML Developer Guide.	9. April 2015