



Panduan Developerr

Amazon Machine Learning



Versi Latest

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

Amazon Machine Learning: Panduan Developerr

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

Merek dagang dan tampilan dagang Amazon tidak boleh digunakan sehubungan dengan produk atau layanan apa pun yang bukan milik Amazon, dengan cara apa pun yang dapat menyebabkan kebingungan antara para pelanggan, atau dengan cara apa pun yang menghina atau mendiskreditkan Amazon. Semua merek dagang lain yang tidak dimiliki oleh Amazon merupakan hak milik masing-masing pemiliknya, yang mungkin atau mungkin tidak terafiliasi, terkait dengan, atau disponsori oleh Amazon.

Table of Contents

.....	ix
Apa itu Amazon Machine Learning?	1
Konsep Kunci Amazon Machine Learning	1
Sumber Data	1
Model ML	3
Evaluasi	4
Prediksi Batch	5
Prediksi Waktu Nyata	6
Mengakses Amazon Machine Learning	6
Wilayah dan titik akhir	7
Harga untuk Amazon ML	7
Memperkirakan Biaya Prediksi Batch	8
Memperkirakan Biaya Prediksi Waktu Nyata	10
Konsep Machine Learning	11
Memecahkan Masalah Bisnis dengan Amazon Machine Learning	11
Kapan Menggunakan Machine Learning	12
Membangun Aplikasi Machine Learning	13
Merumuskan Masalah	13
Mengumpulkan Data Berlabel	14
Menganalisis Data Anda	15
Pemrosesan Fitur	15
Memisahkan Data menjadi Data Pelatihan dan Evaluasi	17
Melatih Model	17
Mengevaluasi Akurasi Model	21
Meningkatkan Akurasi Model	25
Menggunakan Model untuk Membuat Prediksi	27
Melatih Ulang Model pada Data Baru	28
Proses Amazon Machine Learning	28
Menyiapkan Amazon Machine Learning	31
Mendaftar ke AWS	31
Tutorial: Menggunakan Amazon ML untuk Memprediksi Respons terhadap Penawaran	
Pemasaran	32
Prasyarat	32
Langkah-langkah	32

Langkah 1: Siapkan Data Anda	33
Langkah 2: Buat Datasource Pelatihan	35
Langkah 3: Buat Model ML	40
Langkah 4: Tinjau Kinerja Prediktif Model ML dan Tetapkan Ambang Skor	42
Langkah 5: Gunakan Model ML untuk Menghasilkan Prediksi	45
Langkah 6: Bersihkan	53
Membuat dan Menggunakan Sumber Data	55
Memahami Format Data untuk Amazon	55
Atribut	56
Persyaratan Format File Masukan	56
Menggunakan Beberapa File Sebagai Input Data ke Amazon	57
End-of-Line Karakter dalam Format CSV	57
Membuat Skema Data untuk Amazon ML	58
Contoh Skema	59
Menggunakan targetAttributeName Field	61
Menggunakan Bidang RowID	61
Menggunakan AttributeType Field	62
Menyediakan Skema ke Amazon ML	63
Memisahkan Data Anda	65
Pra-pemisahan Data Anda	65
Memisahkan Data Anda Secara Berurutan	65
Memisahkan Data Anda Secara Acak	66
Wawasan Data	68
Statistik Deskriptif	68
Mengakses Data Insights di konsol Amazon	69
Menggunakan Amazon S3 dengan Amazon ML	78
Mengunggah Data Anda ke Amazon S3	79
Izin	79
Membuat Sumber Data Amazon ML dari Data di Amazon Redshift	80
Parameter yang Diperlukan untuk Create Datasource Wizard	80
Membuat Sumber Data dengan Amazon Redshift Data (Konsol)	85
Memecahkan Masalah Amazon Redshift	88
Menggunakan Data dari Database Amazon RDS untuk Membuat Sumber Data Amazon Amazon	94
Pengidentifikasi Instans Database RDS	95
Nama Database MySQL	95

Kredensial Pengguna Database	96
Informasi Keamanan AWS Data Pipeline	96
Informasi Keamanan Amazon RDS	97
Kueri MySQL SQL	97
Lokasi Output S3	97
Pelatihan Model ML	98
Jenis Model ML	98
Model Klasifikasi Biner	98
Model Klasifikasi Multiclass	99
Model Regresi	99
Proses Pelatihan	99
Parameter Pelatihan	100
Ukuran Model Maksimum	100
Jumlah Maksimum Pass atas Data	101
Jenis Kocokan untuk Data Pelatihan	102
Jenis dan Jumlah Regularisasi	103
Parameter Pelatihan: Jenis dan Nilai Default	103
Membuat Model ML	105
Prasyarat	106
Membuat Model ML dengan Opsi Default	106
Membuat Model ML dengan Opsi Kustom	106
Transformasi Data untuk Machine Learning	109
Pentingnya Transformasi Fitur	109
Transformasi Fitur dengan Resep Data	110
Referensi Format Resep	110
Grup	111
Tugas	111
Output	112
Contoh Resep Lengkap	114
Resep yang Disarankan	115
Referensi Transformasi Data	116
Transformasi N-gram	117
Transformasi Bigram Jarang Ortogonal (OSB)	118
Transformasi Huruf Kecil	119
Hapus Transformasi Tanda Baca	119
Transformasi Binning Kuantil	120

Transformasi Normalisasi	120
Transformasi Produk Cartesian	121
Penataan Ulang Data	122
DataRearrangement Parameter	123
Mengevaluasi Model ML	127
Wawasan Model ML	128
Wawasan Model Biner	128
Menafsirkan Prediksi	128
Wawasan Model Multiclass	132
Menafsirkan Prediksi	132
Wawasan Model Regresi	135
Menafsirkan Prediksi	135
Mencegah Overfitting	137
Validasi Lintas	138
Menyesuaikan Model Anda	140
Peringatan Evaluasi	140
Menghasilkan dan Menafsirkan Prediksi	143
Membuat Prediksi Batch	143
Membuat Prediksi Batch (Konsol)	144
Membuat Prediksi Batch (API)	144
Meninjau Metrik Prediksi Batch	145
Meninjau Metrik Prediksi Batch (Konsol)	145
Meninjau Metrik dan Detail Prediksi Batch (API)	146
Membaca File Output Prediksi Batch	146
Menemukan File Manifes Prediksi Batch	146
Membaca File Manifest	147
Mengambil File Output Prediksi Batch	147
Menafsirkan Isi File Prediksi Batch untuk model ML Klasifikasi Biner	148
Menafsirkan Isi File Prediksi Batch untuk Model ML Klasifikasi Multiclass	149
Menafsirkan Isi File Prediksi Batch untuk Model Regresi	150
Meminta Prediksi Waktu Nyata	150
Mencoba Prediksi Real-Time	151
Membuat Endpoint Real-Time	153
Menemukan Titik Akhir Prediksi Real-time (Konsol)	155
Menemukan Titik Akhir Prediksi Real-time (API)	155
Membuat Permintaan Prediksi Real-time	156

Menghapus Titik Akhir Real-Time	158
Mengelola Objek Amazon Amazon	159
Daftar Objek	159
Daftar Objek (Konsol)	160
Daftar Objek (API)	161
Mengambil Deskripsi Objek	162
Deskripsi Terperinci di Konsol	162
Deskripsi Terperinci dari API	162
Memperbarui Objek	162
Menghapus Objek	163
Menghapus Objek (Konsol)	164
Menghapus Objek (API)	164
Memantau Amazon ML dengan Amazon CloudWatch Metrics	166
Mencatat Panggilan API Amazon ML dengan AWS CloudTrail	167
Informasi Amazon ML di CloudTrail	167
Contoh: Entri File Log Amazon	169
Menandai Objek Anda	173
Dasar-Dasar Tanda	173
Pembatasan Tag	174
Menandai Objek Amazon ML (Konsol)	175
Menandai Objek Amazon ML (API)	176
Referensi Amazon Machine Learning	178
Memberikan Izin Amazon ML untuk Membaca Data Anda dari Amazon S3	178
Memberikan Izin Amazon ML untuk Prediksi Output ke Amazon S3	180
Mengontrol Akses ke Sumber Daya Amazon ML-dengan IAM	183
Sintaks Kebijakan IAM	184
Menentukan Tindakan Kebijakan IAM untuk Amazon MLAmazon	185
Menentukan ARNs Sumber Daya Amazon Amazon dalam Kebijakan IAM	185
Contoh Kebijakan untuk Amazon MLs	186
Pencegahan "confused deputy" lintas layanan	189
Manajemen Ketergantungan Operasi Asinkron	191
Memeriksa Status Permintaan	192
Batas Sistem	193
Nama dan IDs untuk semua Objek	195
Objek Lifetimes	195
Sumber daya	196

Riwayat Dokumen 197

Kami tidak lagi memperbarui layanan Amazon Machine Learning atau menerima pengguna baru untuk itu. Dokumentasi ini tersedia untuk pengguna yang sudah ada, tetapi kami tidak lagi memperbaruinya. Untuk informasi selengkapnya, lihat [Apa itu Amazon Machine Learning](#).

Terjemahan disediakan oleh mesin penerjemah. Jika konten terjemahan yang diberikan bertentangan dengan versi bahasa Inggris aslinya, utamakan versi bahasa Inggris.

Apa itu Amazon Machine Learning?

Kami tidak lagi memperbarui layanan Amazon Machine Learning (Amazon ML) atau menerima pengguna baru untuk itu. Dokumentasi ini tersedia untuk pengguna yang sudah ada, tetapi kami tidak lagi memperbaruinya.

AWS sekarang menyediakan layanan berbasis cloud yang kuat — Amazon SageMaker AI — sehingga pengembang dari semua tingkat keahlian dapat menggunakan teknologi pembelajaran mesin. SageMaker AI adalah layanan pembelajaran mesin yang dikelola sepenuhnya yang membantu Anda membuat model pembelajaran mesin yang kuat. Dengan SageMaker AI, ilmuwan dan pengembang data dapat membangun dan melatih model pembelajaran mesin, dan kemudian langsung menerapkannya ke lingkungan host yang siap produksi.

Untuk informasi selengkapnya, lihat [dokumentasi SageMaker AI](#).

Topik

- [Konsep Kunci Amazon Machine Learning](#)
- [Mengakses Amazon Machine Learning](#)
- [Wilayah dan titik akhir](#)
- [Harga untuk Amazon ML](#)

Konsep Kunci Amazon Machine Learning

Bagian ini merangkum konsep-konsep kunci berikut dan menjelaskan secara lebih rinci bagaimana mereka digunakan dalam Amazon ML:

- [Sumber Data](#) berisi metadata yang terkait dengan input data ke Amazon
- [Model ML](#) menghasilkan prediksi menggunakan pola yang diekstraksi dari data input
- [Evaluasi](#) mengukur kualitas model ML
- [Prediksi Batch](#) menghasilkan prediksi secara asinkron untuk beberapa pengamatan data input
- [Prediksi Waktu Nyata](#) secara sinkron menghasilkan prediksi untuk pengamatan data individu

Sumber Data

Sumber data adalah objek yang berisi metadata tentang data masukan Anda. Amazon ML membaca data input Anda, menghitung statistik deskriptif pada atributnya, dan menyimpan statistik—bersama

dengan skema dan informasi lainnya—sebagai bagian dari objek sumber data. Selanjutnya, Amazon ML menggunakan sumber data untuk melatih dan mengevaluasi model ML dan menghasilkan prediksi batch.

Important

Sumber data tidak menyimpan salinan data masukan Anda. Sebagai gantinya, ia menyimpan referensi ke lokasi Amazon S3 tempat data input Anda berada. Jika Anda memindahkan atau mengubah file Amazon S3, Amazon ML tidak dapat mengakses atau menggunakannya untuk membuat model ML, menghasilkan evaluasi, atau menghasilkan prediksi.

Tabel berikut mendefinisikan istilah yang terkait dengan sumber data.

Jangka Waktu	Definisi
Atribut	<p>Properti unik bernama dalam pengamatan. Dalam data berformat tabel seperti spreadsheet atau file nilai dipisahkan koma (CSV), judul kolom mewakili atribut, dan baris berisi nilai untuk setiap atribut.</p> <p>Sinonim: variabel, nama variabel, bidang, kolom</p>
Nama Data source	(Opsional) Memungkinkan Anda menentukan nama yang dapat dibaca manusia untuk sumber data. Nama-nama ini memungkinkan Anda menemukan dan mengelola sumber data Anda di konsol Amazon Amazon.
Masukan Data	Nama kolektif untuk semua pengamatan yang disebut oleh sumber data.
Lokasi	Lokasi data input. Saat ini, Amazon ML dapat menggunakan data yang disimpan dalam bucket Amazon S3, database Amazon Redshift, atau database MySQL di Amazon Relational Database Service (RDS).
Observasi	<p>Unit data input tunggal. Misalnya, jika Anda membuat model ML untuk mendeteksi transaksi penipuan, data input Anda akan terdiri dari banyak pengamatan, masing-masing mewakili transaksi individual.</p> <p>Sinonim: rekam, contoh, contoh, baris</p>

Jangka Waktu	Definisi
ID Baris	<p>(Opsional) Bendera yang, jika ditentukan, mengidentifikasi atribut dalam data input untuk dimasukkan dalam output prediksi. Atribut ini memudahkan untuk mengaitkan prediksi mana yang sesuai dengan pengamatan mana.</p> <p>Sinonim: pengidentifikasi baris</p>
Skema	Informasi yang diperlukan untuk menafsirkan data input, termasuk nama atribut dan tipe data yang ditetapkan, dan nama atribut khusus.
Statistik	<p>Ringkasan statistik untuk setiap atribut dalam data input. Statistik ini melayani dua tujuan:</p> <p>Konsol Amazon ML menampilkannya dalam grafik untuk membantu Anda memahami data at-a-glance dan mengidentifikasi penyimpangan atau kesalahan.</p> <p>Amazon ML menggunakannya selama proses pelatihan untuk meningkatkan kualitas model ML yang dihasilkan.</p>
Status	Menunjukkan status sumber data saat ini, seperti Sedang Berlangsung, Selesai, atau Gagal.
Atribut Target	<p>Dalam konteks pelatihan model ML, atribut target mengidentifikasi nama atribut dalam data input yang berisi jawaban “benar”. Amazon ML menggunakan ini untuk menemukan pola dalam data input dan menghasilkan model ML. Dalam konteks mengevaluasi dan menghasilkan prediksi, atribut target adalah atribut yang nilainya akan diprediksi oleh model ML terlatih.</p> <p>Sinonim: target</p>

Model ML

Model ML adalah model matematika yang menghasilkan prediksi dengan menemukan pola dalam data Anda. Amazon ML mendukung tiga jenis model ML: klasifikasi biner, klasifikasi multiclass dan regresi.

Tabel berikut mendefinisikan istilah yang terkait dengan model ML.

Jangka Waktu	Definisi
Regresi	Tujuan pelatihan model regresi ML adalah untuk memprediksi nilai numerik.
Multiclass	Tujuan pelatihan model ML multiclass adalah untuk memprediksi nilai-nilai yang termasuk dalam serangkaian nilai yang diizinkan yang terbatas dan telah ditentukan sebelumnya.
Biner	Tujuan pelatihan model ML biner adalah untuk memprediksi nilai yang hanya dapat memiliki satu dari dua keadaan, seperti benar atau salah.
Ukuran Model	Model ML menangkap dan menyimpan pola. Semakin banyak pola yang disimpan model ML, semakin besar jadinya. Ukuran model ML dijelaskan dalam Mbytes.
Jumlah Pass	Saat Anda melatih model ML, Anda menggunakan data dari sumber data. Terkadang bermanfaat untuk menggunakan setiap catatan data dalam proses pembelajaran lebih dari sekali. Berapa kali Anda membiarkan Amazon ML menggunakan catatan data yang sama disebut jumlah lintasan.
Regularisasi	Regularisasi adalah teknik pembelajaran mesin yang dapat Anda gunakan untuk mendapatkan model berkualitas lebih tinggi. Amazon ML menawarkan pengaturan default yang berfungsi dengan baik untuk sebagian besar kasus.

Evaluasi

Evaluasi mengukur kualitas model ML Anda dan menentukan apakah kinerjanya baik.

Tabel berikut mendefinisikan istilah yang terkait dengan evaluasi.

Jangka Waktu	Definisi
Wawasan Model	Amazon ML memberi Anda metrik dan sejumlah wawasan yang dapat Anda gunakan untuk mengevaluasi kinerja prediktif model Anda.
AUC	Area Di Bawah Kurva ROC (AUC) mengukur kemampuan model ML biner untuk memprediksi skor yang lebih tinggi untuk contoh positif dibandingkan dengan contoh negatif.

Jangka Waktu	Definisi
Skor F1 rata-rata makro	Skor F1 rata-rata makro digunakan untuk mengevaluasi kinerja prediktif model Multiclass Multiclass.
RMSE	Root Mean Square Error (RMSE) adalah metrik yang digunakan untuk mengevaluasi kinerja prediktif model regresi ML.
Cut-off	Model ML bekerja dengan menghasilkan skor prediksi numerik. Dengan menerapkan nilai cut-off, sistem mengubah skor ini menjadi 0 dan 1 label.
Akurasi	Akurasi mengukur persentase prediksi yang benar.
presisi	Presisi menunjukkan persentase contoh positif aktual (sebagai lawan dari positif palsu) di antara contoh-contoh yang telah diambil (yang diprediksi positif). Dengan kata lain, berapa banyak item yang dipilih yang positif?
Ingat	Ingat menunjukkan persentase positif aktual di antara jumlah total contoh yang relevan (positif aktual). Dengan kata lain, berapa banyak item positif yang dipilih?

Prediksi Batch

Prediksi Batch adalah untuk serangkaian pengamatan yang dapat dijalankan sekaligus. Ini sangat ideal untuk analisis prediktif yang tidak memiliki persyaratan waktu nyata.

Tabel berikut mendefinisikan istilah yang terkait dengan prediksi batch.

Jangka Waktu	Definisi
Lokasi Keluaran	Hasil prediksi batch disimpan di lokasi keluaran bucket S3.
Berkas Manifes	File ini menghubungkan setiap file data input dengan hasil prediksi batch terkait. Itu disimpan di lokasi output bucket S3.

Prediksi Waktu Nyata

Prediksi real-time adalah untuk aplikasi dengan persyaratan latensi rendah, seperti web interaktif, seluler, atau aplikasi desktop. Model ML apa pun dapat ditanyakan untuk prediksi dengan menggunakan API prediksi real-time latensi rendah.

Tabel berikut mendefinisikan istilah yang terkait dengan prediksi real-time.

Jangka Waktu	Definisi
API Prediksi Waktu Nyata	Real-time Prediction API menerima observasi input tunggal dalam payload permintaan dan mengembalikan prediksi dalam respons.
Titik Akhir Prediksi Waktu Nyata	Untuk menggunakan model ML dengan API prediksi real-time, Anda perlu membuat titik akhir prediksi real-time. Setelah dibuat, titik akhir berisi URL yang dapat Anda gunakan untuk meminta prediksi waktu nyata.

Mengakses Amazon Machine Learning

Anda dapat mengakses Amazon ML dengan menggunakan salah satu dari berikut ini:

Konsol Amazon ML

Anda dapat mengakses konsol Amazon dengan masuk ke AWS Management Console, dan membuka konsol Amazon ML di <https://console.aws.amazon.com/machinelearning/>.

AWS CLI

Untuk informasi tentang cara menginstal dan mengonfigurasi AWS CLI, lihat Mengatur dengan Antarmuka Baris Perintah AWS di [AWS Command Line Interface Panduan Pengguna](#).

Amazon ML API

Untuk informasi selengkapnya tentang Amazon ML API, lihat [Referensi API Amazon ML](#).

AWS SDKs

Untuk informasi selengkapnya tentang AWS SDKs, lihat [Alat untuk Amazon Web Services](#).

Wilayah dan titik akhir

Amazon Machine Learning (Amazon Learning) mendukung titik akhir prediksi real-time di dua wilayah berikut:

Nama Wilayah	Wilayah	Titik Akhir	Protokol
US East (N. Virginia)	us-east-1	machinelearning.us-east-1.amazonaws.com	HTTPS
Europe (Ireland)	eu-west-1	machinelearning.eu-west-1.amazonaws.com	HTTPS

Anda dapat meng-host kumpulan data, melatih dan mengevaluasi model, dan memicu prediksi di wilayah mana pun.

Kami menyarankan Anda menyimpan semua sumber daya Anda di wilayah yang sama. Jika data input Anda berada di wilayah yang berbeda dari sumber daya Amazon Amazon, Anda akan dikenakan biaya transfer data lintas regional. Anda dapat memanggil titik akhir prediksi real-time dari wilayah mana pun, tetapi memanggil titik akhir dari wilayah yang tidak memiliki titik akhir yang Anda panggil dapat memengaruhi latensi prediksi waktu nyata.

Harga untuk Amazon ML

Dengan AWS layanan, Anda hanya membayar untuk apa yang Anda gunakan. Tidak ada biaya minimum dan tidak ada komitmen di muka.

Amazon Machine Learning (Amazon ML) membebankan tarif per jam untuk waktu komputasi yang digunakan untuk menghitung statistik data serta melatih serta mengevaluasi model, lalu Anda membayar jumlah prediksi yang dihasilkan untuk aplikasi Anda. Untuk prediksi waktu nyata, Anda juga membayar biaya kapasitas cadangan per jam berdasarkan ukuran model Anda.

Amazon ML memperkirakan biaya untuk prediksi hanya di [konsol Amazon ML](#).

Untuk informasi selengkapnya tentang harga Amazon ML, lihat [Harga Amazon Machine Learning](#).

Topik

- [Memperkirakan Biaya Prediksi Batch](#)
- [Memperkirakan Biaya Prediksi Waktu Nyata](#)

Memperkirakan Biaya Prediksi Batch

Saat Anda meminta prediksi batch dari model Amazon ML menggunakan wizard Buat Prediksi Batch, Amazon ML memperkirakan biaya prediksi ini. Metode untuk menghitung estimasi bervariasi berdasarkan jenis data yang tersedia.

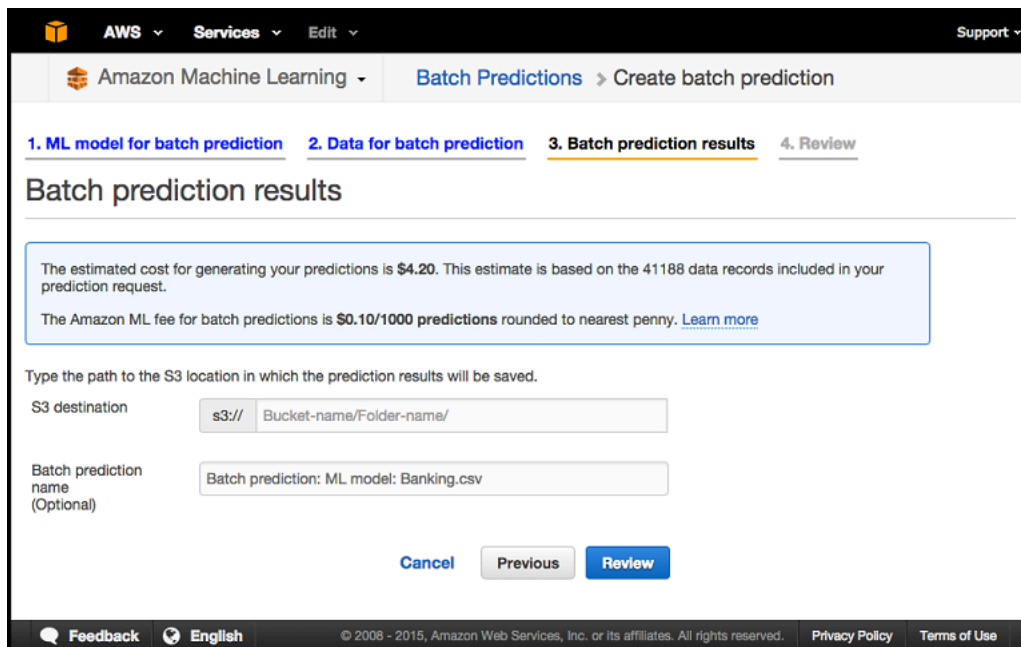
Memperkirakan Biaya Prediksi Batch Saat Statistik Data Tersedia

Perkiraan biaya yang paling akurat diperoleh ketika Amazon ML telah menghitung statistik ringkasan pada sumber data yang digunakan untuk meminta prediksi. Statistik ini selalu dihitung untuk sumber data yang telah dibuat menggunakan konsol Amazon ML. [Pengguna API harus menyetel `ComputeStatistics flag True` saat membuat sumber data secara terprogram menggunakan `CreateDataSourceFromS3`, atau `RDS.CreateDataSourceFromRedshiftCreateDataSourceFrom` APIs](#) Sumber data harus dalam READY keadaan agar statistik tersedia.

Salah satu statistik yang dihitung Amazon ML adalah jumlah catatan data. Ketika jumlah catatan data tersedia, wizard Amazon ML Create Batch Prediction memperkirakan jumlah prediksi dengan mengalikan jumlah catatan data dengan [biaya](#) untuk prediksi batch.

Biaya aktual Anda dapat bervariasi dari perkiraan ini karena alasan berikut:

- Beberapa catatan data mungkin gagal diproses. Anda tidak ditagih untuk prediksi dari catatan data yang gagal.
- Perkiraan tidak memperhitungkan kredit yang sudah ada sebelumnya atau penyesuaian lain yang diterapkan oleh AWS.



The screenshot shows the 'Batch prediction results' page in the Amazon Machine Learning console. The page is divided into four steps: 1. ML model for batch prediction, 2. Data for batch prediction, 3. Batch prediction results (highlighted), and 4. Review. A blue box contains the estimated cost: 'The estimated cost for generating your predictions is \$4.20. This estimate is based on the 41188 data records included in your prediction request.' Below this, it states 'The Amazon ML fee for batch predictions is \$0.10/1000 predictions rounded to nearest penny. [Learn more](#)'. The user is prompted to 'Type the path to the S3 location in which the prediction results will be saved.' The 'S3 destination' field contains 's3:// Bucket-name/Folder-name/'. The 'Batch prediction name (Optional)' field contains 'Batch prediction: ML model: Banking.csv'. At the bottom, there are three buttons: 'Cancel', 'Previous', and 'Review' (highlighted in blue). The footer includes 'Feedback', 'English', '© 2008 - 2015, Amazon Web Services, Inc. or its affiliates. All rights reserved.', 'Privacy Policy', and 'Terms of Use'.

Memperkirakan Biaya Prediksi Batch Ketika Hanya Ukuran Data yang Tersedia

Saat Anda meminta prediksi batch dan statistik data untuk sumber data permintaan tidak tersedia, Amazon ML memperkirakan biaya berdasarkan hal berikut:

- Ukuran data total yang dihitung dan dipertahankan selama validasi sumber data
- Ukuran catatan data rata-rata, yang diperkirakan Amazon ML dengan membaca dan mengurai 100 MB pertama file data Anda

Untuk memperkirakan biaya prediksi batch Anda, Amazon ML membagi ukuran data total dengan ukuran catatan data rata-rata. Metode prediksi biaya ini kurang tepat daripada metode yang digunakan ketika jumlah catatan data tersedia karena catatan pertama dari file data Anda mungkin tidak secara akurat mewakili ukuran catatan rata-rata.

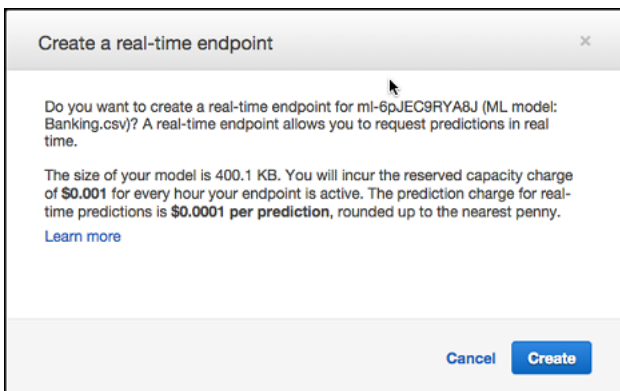
Memperkirakan Biaya Prediksi Batch Saat Statistik Data maupun Ukuran Data Tidak Tersedia

Ketika tidak ada statistik data maupun ukuran data yang tersedia, Amazon ML tidak dapat memperkirakan biaya prediksi batch Anda. Ini biasanya terjadi ketika sumber data yang Anda gunakan untuk meminta prediksi batch belum divalidasi oleh Amazon ML. Ini dapat terjadi ketika Anda telah membuat sumber data yang didasarkan pada kueri Amazon Redshift (Amazon Redshift) atau Amazon Relational Database Service (Amazon RDS), dan transfer data belum selesai, atau ketika pembuatan sumber data antri di belakang operasi lain di akun Anda. Dalam hal ini, konsol

Amazon memberi tahu Anda tentang biaya untuk prediksi batch. Anda dapat memilih untuk melanjutkan permintaan prediksi batch tanpa perkiraan, atau membatalkan wizard dan kembali setelah sumber data yang digunakan untuk prediksi berada dalam status INPROGRESS atau READY.

Memperkirakan Biaya Prediksi Waktu Nyata

Saat Anda membuat titik akhir prediksi real-time menggunakan konsol Amazon, Anda akan diperlihatkan perkiraan biaya kapasitas cadangan, yang merupakan biaya berkelanjutan untuk pemesanan titik akhir untuk pemrosesan prediksi. Biaya ini bervariasi berdasarkan ukuran model, seperti yang dijelaskan pada [halaman harga layanan](#). Anda juga akan diberi tahu tentang biaya prediksi real-time Amazon ML standar.



Konsep Machine Learning

Machine learning (ML) dapat membantu Anda menggunakan data historis untuk membuat keputusan bisnis yang lebih baik. Algoritma ML menemukan pola dalam data, dan membangun model matematika menggunakan penemuan-penemuan ini. Kemudian Anda dapat menggunakan model untuk membuat prediksi pada data future. Misalnya, salah satu kemungkinan penerapan model pembelajaran mesin adalah memprediksi seberapa besar kemungkinan pelanggan membeli produk tertentu berdasarkan perilaku masa lalu mereka.

Topik

- [Memecahkan Masalah Bisnis dengan Amazon Machine Learning](#)
- [Kapan Menggunakan Machine Learning](#)
- [Membangun Aplikasi Machine Learning](#)
- [Proses Amazon Machine Learning](#)

Memecahkan Masalah Bisnis dengan Amazon Machine Learning

Anda dapat menggunakan Amazon Machine Learning untuk menerapkan pembelajaran mesin pada masalah yang memiliki contoh jawaban aktual yang ada. Misalnya, jika Anda ingin menggunakan Amazon Machine Learning untuk memprediksi apakah email adalah spam, Anda perlu mengumpulkan contoh email yang diberi label dengan benar sebagai spam atau bukan spam. Anda kemudian dapat menggunakan pembelajaran mesin untuk menggeneralisasi dari contoh-contoh email ini untuk memprediksi seberapa besar kemungkinan email baru adalah spam atau tidak. Pendekatan pembelajaran dari data yang telah diberi label dengan jawaban aktual ini dikenal sebagai pembelajaran mesin yang diawasi.

Anda dapat menggunakan pendekatan ML yang diawasi untuk tugas-tugas pembelajaran mesin khusus ini: klasifikasi biner (memprediksi salah satu dari dua kemungkinan hasil), klasifikasi multikelas (memprediksi satu dari lebih dari dua hasil) dan regresi (memprediksi nilai numerik).

Contoh masalah klasifikasi biner:

- Apakah pelanggan akan membeli produk ini atau tidak membeli produk ini?
- Apakah email ini spam atau bukan spam?
- Apakah produk ini buku atau hewan ternak?

- Apakah ulasan ini ditulis oleh pelanggan atau robot?

Contoh masalah klasifikasi multiclass:

- Apakah produk ini buku, film, atau pakaian?
- Apakah film ini komedi romantis, dokumenter, atau thriller?
- Kategori produk mana yang paling menarik bagi pelanggan ini?

Contoh masalah klasifikasi regresi:

- Berapa suhu di Seattle besok?
- Untuk produk ini, berapa unit yang akan dijual?
- Berapa hari sebelum pelanggan ini berhenti menggunakan aplikasi?
- Berapa harga rumah ini akan dijual?

Kapan Menggunakan Machine Learning

Penting untuk diingat bahwa ML bukanlah solusi untuk setiap jenis masalah. Ada beberapa kasus di mana solusi yang kuat dapat dikembangkan tanpa menggunakan teknik ML. Misalnya, Anda tidak memerlukan ML jika Anda dapat menentukan nilai target dengan menggunakan aturan sederhana, perhitungan, atau langkah-langkah yang telah ditentukan sebelumnya yang dapat diprogram tanpa memerlukan pembelajaran berbasis data.

Gunakan pembelajaran mesin untuk situasi berikut:

- Anda tidak dapat membuat kode aturan: Banyak tugas manusia (seperti mengenali apakah email adalah spam atau bukan spam) tidak dapat diselesaikan secara memadai menggunakan solusi sederhana (deterministik) berbasis aturan. Sejumlah besar faktor dapat mempengaruhi jawabannya. Ketika aturan bergantung pada terlalu banyak faktor dan banyak dari aturan ini tumpang tindih atau perlu disetel dengan sangat halus, segera menjadi sulit bagi manusia untuk secara akurat mengkode aturan. Anda dapat menggunakan ML untuk mengatasi masalah ini secara efektif.
- Anda tidak dapat menskalakan: Anda mungkin dapat mengenali beberapa ratus email secara manual dan memutuskan apakah itu spam atau tidak. Namun, tugas ini menjadi membosankan bagi jutaan email. Solusi ML efektif dalam menangani masalah skala besar.

Membangun Aplikasi Machine Learning

Membangun aplikasi ML adalah proses berulang yang melibatkan urutan langkah. Untuk membangun aplikasi ML, ikuti langkah-langkah umum berikut:

1. Bingkai masalah inti dalam hal apa yang diamati dan jawaban apa yang Anda ingin model prediksi.
2. Kumpulkan, bersihkan, dan siapkan data agar sesuai untuk dikonsumsi oleh algoritma pelatihan model ML. Visualisasikan dan analisis data untuk menjalankan pemeriksaan kewarasan untuk memvalidasi kualitas data dan untuk memahami data.
3. Seringkali, data mentah (variabel input) dan jawaban (target) tidak direpresentasikan dengan cara yang dapat digunakan untuk melatih model yang sangat prediktif. Oleh karena itu, Anda biasanya harus mencoba membangun representasi input atau fitur yang lebih prediktif dari variabel mentah.
4. Masukkan fitur yang dihasilkan ke algoritma pembelajaran untuk membangun model dan mengevaluasi kualitas model pada data yang dipegang dari pembuatan model.
5. Gunakan model untuk menghasilkan prediksi jawaban target untuk instance data baru.

Merumuskan Masalah

Langkah pertama dalam pembelajaran mesin adalah memutuskan apa yang ingin Anda prediksi, yang dikenal sebagai label atau jawaban target. Bayangkan sebuah skenario di mana Anda ingin memproduksi produk, tetapi keputusan Anda untuk memproduksi setiap produk tergantung pada jumlah penjualan potensial. Dalam skenario ini, Anda ingin memprediksi berapa kali setiap produk akan dibeli (memprediksi jumlah penjualan). Ada beberapa cara untuk mendefinisikan masalah ini dengan menggunakan pembelajaran mesin. Memilih cara mendefinisikan masalah tergantung pada kasus penggunaan atau kebutuhan bisnis Anda.

Apakah Anda ingin memprediksi jumlah pembelian yang akan dilakukan pelanggan Anda untuk setiap produk (dalam hal ini targetnya numerik dan Anda memecahkan masalah regresi)? Atau apakah Anda ingin memprediksi produk mana yang akan mendapatkan lebih dari 10 pembelian (dalam hal ini targetnya adalah biner dan Anda memecahkan masalah klasifikasi biner)?

Penting untuk menghindari masalah yang terlalu rumit dan membingkai solusi paling sederhana yang memenuhi kebutuhan Anda. Namun, penting juga untuk menghindari kehilangan informasi, terutama informasi dalam jawaban historis. Di sini, mengubah angka penjualan masa lalu yang sebenarnya menjadi variabel biner “lebih dari 10” versus “lebih sedikit” akan kehilangan informasi

berharga. Menginvestasikan waktu dalam memutuskan target mana yang paling masuk akal untuk Anda prediksi akan menyelamatkan Anda dari membangun model yang tidak menjawab pertanyaan Anda.

Mengumpulkan Data Berlabel

Masalah ML dimulai dengan data—sebaiknya, banyak data (contoh atau pengamatan) yang sudah Anda ketahui jawabannya. Data yang sudah Anda ketahui jawabannya disebut data berlabel. Dalam ML yang diawasi, algoritme mengajarkan dirinya untuk belajar dari contoh berlabel yang kami berikan.

Masing-masing example/observation dalam data Anda harus berisi dua elemen:

- **Target** — Jawaban yang ingin Anda prediksi. Anda memberikan data yang diberi label dengan target (jawaban yang benar) ke algoritma ML untuk dipelajari. Kemudian, Anda akan menggunakan model ML terlatih untuk memprediksi jawaban ini pada data yang Anda tidak tahu jawaban targetnya.
- **Variabel/fitur** — Ini adalah atribut dari contoh yang dapat digunakan untuk mengidentifikasi pola untuk memprediksi jawaban target.

Misalnya, untuk masalah klasifikasi email, targetnya adalah label yang menunjukkan apakah email itu spam atau bukan spam. Contoh variabel adalah pengirim email, teks di badan email, teks di baris subjek, waktu email dikirim, dan adanya korespondensi sebelumnya antara pengirim dan penerima.

Seringkali, data tidak tersedia dalam bentuk berlabel. Mengumpulkan dan menyiapkan variabel dan target seringkali merupakan langkah terpenting dalam memecahkan masalah ML. Contoh data harus mewakili data yang akan Anda miliki saat Anda menggunakan model untuk membuat prediksi. Misalnya, jika Anda ingin memprediksi apakah email itu spam atau bukan, Anda harus mengumpulkan positif (email spam) dan negatif (email non-spam) agar algoritme pembelajaran mesin dapat menemukan pola yang akan membedakan antara kedua jenis email tersebut.

Setelah Anda memiliki data berlabel, Anda mungkin perlu mengubahnya menjadi format yang dapat diterima oleh algoritme atau perangkat lunak Anda. Misalnya, untuk menggunakan Amazon ML, Anda perlu mengonversi data ke format dipisahkan koma (CSV) dengan setiap contoh membentuk satu baris file CSV, setiap kolom berisi satu variabel input, dan satu kolom yang berisi jawaban target.

Menganalisis Data Anda

Sebelum memasukkan data berlabel Anda ke algoritme ML, sebaiknya periksa data Anda guna mengidentifikasi masalah dan mendapatkan wawasan tentang data yang Anda gunakan. Kekuatan prediksi model Anda hanya akan sebagus data yang Anda berikan.

Saat menganalisis data Anda, Anda harus mengingat pertimbangan berikut:

- Ringkasan data variabel dan target — Sangat berguna untuk memahami nilai yang diambil variabel Anda dan nilai mana yang dominan dalam data Anda. Anda dapat menjalankan ringkasan ini oleh ahli materi pelajaran untuk masalah yang ingin Anda pecahkan. Tanyakan pada diri sendiri atau ahli materi pelajaran: Apakah data sesuai dengan harapan Anda? Apakah sepertinya Anda memiliki masalah pengumpulan data? Apakah satu kelas di target Anda lebih sering daripada kelas lainnya? Apakah ada lebih banyak nilai yang hilang atau data yang tidak valid dari yang Anda harapkan?
- Korelasi variabel-target — Mengetahui korelasi antara setiap variabel dan kelas target sangat membantu karena korelasi yang tinggi menyiratkan bahwa ada hubungan antara variabel dan kelas target. Secara umum, Anda ingin memasukkan variabel dengan korelasi tinggi karena mereka adalah variabel dengan daya prediksi (sinyal) yang lebih tinggi, dan mengabaikan variabel dengan korelasi rendah karena kemungkinan besar tidak relevan.

Di Amazon, Anda dapat menganalisis data Anda dengan membuat sumber data dan dengan meninjau laporan data yang dihasilkan.

Pemrosesan Fitur

Setelah mengetahui data Anda melalui ringkasan dan visualisasi data, Anda mungkin ingin mengubah variabel Anda lebih jauh untuk membuatnya lebih bermakna. Ini dikenal sebagai pemrosesan fitur. Misalnya, Anda memiliki variabel yang menangkap tanggal dan waktu di mana suatu peristiwa terjadi. Tanggal dan waktu ini tidak akan pernah terjadi lagi dan karenanya tidak akan berguna untuk memprediksi target Anda. Namun, jika variabel ini diubah menjadi fitur yang mewakili jam dalam sehari, hari dalam seminggu, dan bulan, variabel-variabel ini dapat berguna untuk mengetahui apakah peristiwa tersebut cenderung terjadi pada jam, hari kerja, atau bulan tertentu. Pemrosesan fitur tersebut untuk membentuk titik data yang lebih dapat digeneralisasikan untuk dipelajari dapat memberikan peningkatan yang signifikan pada model prediktif.

Contoh lain dari pemrosesan fitur umum:

- Mengganti data yang hilang atau tidak valid dengan nilai yang lebih bermakna (misalnya, jika Anda tahu bahwa nilai yang hilang untuk variabel tipe produk sebenarnya berarti itu adalah buku, Anda kemudian dapat mengganti semua nilai yang hilang dalam tipe produk dengan nilai untuk buku). Strategi umum yang digunakan untuk menghitung nilai yang hilang adalah mengganti nilai yang hilang dengan nilai rata-rata atau median. Penting untuk memahami data Anda sebelum memilih strategi untuk mengganti nilai yang hilang.
- Membentuk produk Cartesian dari satu variabel dengan variabel lainnya. Misalnya, jika Anda memiliki dua variabel, seperti kepadatan penduduk (perkotaan, pinggiran kota, pedesaan) dan negara bagian (Washington, Oregon, California), mungkin ada informasi berguna dalam fitur yang dibentuk oleh produk Cartesian dari dua variabel ini yang menghasilkan fitur (Urban_Washington, Suburban_Washington, Rural_Washington, Urban_Oregon, Urban_Oregon, Urban_California, Pinggiran kota_California, Rural_California).
- Transformasi non-linear seperti binning variabel numerik ke kategori. Dalam banyak kasus, hubungan antara fitur numerik dan target tidak linier (nilai fitur tidak meningkat atau menurun secara monoton dengan target). Dalam kasus seperti itu, mungkin berguna untuk memasukkan fitur numerik ke dalam fitur kategoris yang mewakili rentang fitur numerik yang berbeda. Setiap fitur kategoris (bin) kemudian dapat dimodelkan sebagai memiliki hubungan liniernya sendiri dengan target. Misalnya, Anda tahu bahwa usia fitur numerik kontinu tidak berkorelasi linier dengan kemungkinan untuk membeli buku. Anda dapat memasukkan usia ke dalam fitur kategoris yang mungkin dapat menangkap hubungan dengan target dengan lebih akurat. Jumlah optimal naman untuk variabel numerik tergantung pada karakteristik variabel dan hubungannya dengan target, dan ini paling baik ditentukan melalui eksperimen. Amazon ML menyarankan nomor bin optimal untuk fitur numerik berdasarkan statistik data dalam resep yang disarankan. Lihat Panduan Pengembang untuk detail tentang resep yang disarankan.
- Fitur khusus domain (misalnya, Anda memiliki panjang, lebar, dan tinggi sebagai variabel terpisah; Anda dapat membuat fitur volume baru untuk menjadi produk dari ketiga variabel ini).
- Fitur khusus variabel. Beberapa jenis variabel seperti fitur teks, fitur yang menangkap struktur halaman web, atau struktur kalimat memiliki cara pemrosesan generik yang membantu mengekstrak struktur dan konteks. Misalnya, membentuk n-gram dari teks “rubah melompati pagar” dapat diwakili dengan unigram: , rubah, melompat, di atas, pagar atau bigram: rubah, rubah melompat, melompati, melewati, pagar.

Termasuk fitur yang lebih relevan membantu meningkatkan daya prediksi. Jelas, tidak selalu mungkin untuk mengetahui fitur dengan “sinyal” atau pengaruh prediktif terlebih dahulu. Jadi ada baiknya untuk memasukkan semua fitur yang berpotensi terkait dengan label target dan membiarkan

algoritma pelatihan model memilih fitur dengan korelasi terkuat. Di Amazon ML, pemrosesan fitur dapat ditentukan dalam resep saat membuat model. Lihat Panduan Pengembang untuk daftar prosesor fitur yang tersedia.

Memisahkan Data menjadi Data Pelatihan dan Evaluasi

Tujuan mendasar dari ML adalah untuk menggeneralisasi di luar instance data yang digunakan untuk melatih model. Kami ingin mengevaluasi model untuk memperkirakan kualitas generalisasi polanya untuk data yang belum dilatih model. Namun, karena instance future memiliki nilai target yang tidak diketahui dan kami tidak dapat memeriksa keakuratan prediksi kami untuk instance future sekarang, kami perlu menggunakan beberapa data yang sudah kami ketahui jawabannya sebagai proxy untuk data future. Mengevaluasi model dengan data yang sama yang digunakan untuk pelatihan tidak berguna, karena memberi penghargaan kepada model yang dapat “mengingat” data pelatihan, sebagai lawan dari generalisasi darinya.

Strategi umum adalah mengambil semua data berlabel yang tersedia, dan membaginya menjadi subset pelatihan dan evaluasi, biasanya dengan rasio 70-80 persen untuk pelatihan dan 20-30 persen untuk evaluasi. Sistem ML menggunakan data pelatihan untuk melatih model untuk melihat pola, dan menggunakan data evaluasi untuk mengevaluasi kualitas prediktif dari model terlatih. Sistem ML mengevaluasi kinerja prediktif dengan membandingkan prediksi pada kumpulan data evaluasi dengan nilai sebenarnya (dikenal sebagai kebenaran dasar) menggunakan berbagai metrik. Biasanya, Anda menggunakan model “terbaik” pada subset evaluasi untuk membuat prediksi pada instans masa depan yang Anda tidak tahu jawaban targetnya.

Amazon ML membagi data yang dikirim untuk melatih model melalui konsol Amazon ML menjadi 70 persen untuk pelatihan dan 30 persen untuk evaluasi. Secara default, Amazon ML menggunakan 70 persen pertama dari data input dalam urutan yang muncul dalam data sumber untuk sumber data pelatihan dan 30 persen sisanya dari data untuk sumber data evaluasi. Amazon ML juga memungkinkan Anda memilih 70 persen data sumber acak untuk pelatihan alih-alih menggunakan 70 persen pertama, dan menggunakan pelengkap subset acak ini untuk evaluasi. Anda dapat menggunakan Amazon ML APIs untuk menentukan rasio pemisahan kustom dan untuk memberikan data pelatihan dan evaluasi yang dibagi di luar Amazon ML. Amazon ML juga menyediakan strategi untuk membagi data Anda. Untuk informasi lebih lanjut tentang strategi pemisahan, lihat [Memisahkan Data Anda](#).

Melatih Model

Anda sekarang siap memberikan algoritme ML (yaitu, algoritme pembelajaran) dengan data pelatihan. Algoritma akan belajar dari pola data pelatihan yang memetakan variabel ke target, dan

akan menghasilkan model yang menangkap hubungan ini. Model ML kemudian dapat digunakan untuk mendapatkan prediksi pada data baru yang Anda tidak tahu jawaban targetnya.

Model Linear

Ada sejumlah besar model ML yang tersedia. Amazon ML mempelajari satu jenis model ML: model linier. Istilah model linier menyiratkan bahwa model ditentukan sebagai kombinasi linier fitur. Berdasarkan data pelatihan, proses pembelajaran menghitung satu bobot untuk setiap fitur untuk membentuk model yang dapat memprediksi atau memperkirakan nilai target. Misalnya, jika target Anda adalah jumlah asuransi yang akan dibeli pelanggan dan variabel Anda adalah usia dan pendapatan, model linier sederhana adalah sebagai berikut:

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

Algoritma Pembelajaran

Tugas algoritma pembelajaran adalah mempelajari bobot untuk model. Bobot menggambarkan kemungkinan bahwa pola yang dipelajari model mencerminkan hubungan aktual dalam data. Algoritma pembelajaran terdiri dari fungsi kerugian dan teknik optimasi. Kerugian adalah penalti yang terjadi ketika estimasi target yang diberikan oleh model ML tidak sama persis dengan target. Fungsi kerugian mengukur penalti ini sebagai nilai tunggal. Teknik optimasi berupaya meminimalkan kerugian. Di Amazon Machine Learning, kami menggunakan tiga fungsi kerugian, satu untuk masing-masing dari tiga jenis masalah prediksi. Teknik optimasi yang digunakan di Amazon ML adalah Stochastic Gradient Descent (SGD) online. SGD membuat lintasan berurutan atas data pelatihan, dan selama setiap lintasan, pembaruan menampilkan bobot satu contoh pada satu waktu dengan tujuan mendekati bobot optimal yang meminimalkan kerugian.

Amazon ML menggunakan algoritme pembelajaran berikut:

- Untuk klasifikasi biner, Amazon ML menggunakan regresi logistik (fungsi kerugian logistik+SGD).
- Untuk klasifikasi multiclass, Amazon ML menggunakan regresi logistik multinomial (kerugian logistik multinomial+SGD).
- Untuk regresi, Amazon ML menggunakan regresi linier (fungsi kerugian kuadrat+SGD).

Parameter Pelatihan

Algoritma pembelajaran Amazon ML menerima parameter, yang disebut hyperparameters atau parameter pelatihan, yang memungkinkan Anda mengontrol kualitas model yang dihasilkan. Bergantung pada hyperparameter, Amazon ML secara otomatis memilih pengaturan atau

menyediakan default statis untuk hyperparameters. Meskipun pengaturan hyperparameter default umumnya menghasilkan model yang berguna, Anda mungkin dapat meningkatkan kinerja prediktif model Anda dengan mengubah nilai hyperparameter. Bagian berikut menjelaskan hiperparameter umum yang terkait dengan algoritma pembelajaran untuk model linier, seperti yang dibuat oleh Amazon ML.

Tingkat Pembelajaran

Tingkat pembelajaran adalah nilai konstan yang digunakan dalam algoritma Stochastic Gradient Descent (SGD). Tingkat pembelajaran mempengaruhi kecepatan algoritma mencapai (konvergen ke) bobot optimal. Algoritma SGD membuat pembaruan pada bobot model linier untuk setiap contoh data yang dilihatnya. Ukuran pembaruan ini dikendalikan oleh tingkat pembelajaran. Tingkat belajar yang terlalu besar dapat mencegah bobot mendekati solusi optimal. Nilai yang terlalu kecil menghasilkan algoritme yang membutuhkan banyak lintasan untuk mendekati bobot optimal.

Di Amazon ML, tingkat pembelajaran dipilih secara otomatis berdasarkan data Anda.

Ukuran Model

Jika Anda memiliki banyak fitur input, jumlah pola yang mungkin dalam data dapat menghasilkan model yang besar. Model besar memiliki implikasi praktis, seperti membutuhkan lebih banyak RAM untuk menahan model saat pelatihan dan saat menghasilkan prediksi. Di Amazon ML, Anda dapat mengurangi ukuran model dengan menggunakan regularisasi L1 atau dengan secara khusus membatasi ukuran model dengan menentukan ukuran maksimum. Perhatikan bahwa jika Anda mengurangi ukuran model terlalu banyak, Anda dapat mengurangi daya prediksi model Anda.

Untuk informasi tentang ukuran model default, lihat [Parameter Pelatihan: Jenis dan Nilai Default](#). Untuk informasi lebih lanjut tentang regularisasi, lihat [Regularisasi](#)

Jumlah Pass

Algoritma SGD membuat lintasan berurutan atas data pelatihan. `Number of passes` Parameter mengontrol jumlah lintasan yang dibuat algoritme atas data pelatihan. Lebih banyak lintasan menghasilkan model yang lebih sesuai dengan data (jika tingkat pembelajaran tidak terlalu besar), tetapi manfaatnya berkurang dengan meningkatnya jumlah lintasan. Untuk kumpulan data yang lebih kecil, Anda dapat secara signifikan meningkatkan jumlah lintasan, yang memungkinkan algoritme pembelajaran menyesuaikan data secara efektif lebih dekat. Untuk kumpulan data yang sangat besar, satu pass mungkin cukup.

Untuk informasi tentang jumlah default pass, lihat [Parameter Pelatihan: Jenis dan Nilai Default](#).

Pengocokan Data

Di Amazon ML, Anda harus mengacak data Anda karena algoritma SGD dipengaruhi oleh urutan baris dalam data pelatihan. Mengacak data pelatihan Anda menghasilkan model ML yang lebih baik karena membantu algoritma SGD menghindari solusi yang optimal untuk jenis data pertama yang dilihatnya, tetapi tidak untuk rentang data lengkap. Pengocokan mencampur urutan data Anda sehingga algoritma SGD tidak menemukan satu jenis data untuk terlalu banyak pengamatan berturut-turut. Jika hanya melihat satu jenis data untuk banyak pembaruan bobot berturut-turut, algoritme mungkin tidak dapat memperbaiki bobot model untuk tipe data baru karena pembaruan mungkin terlalu besar. Selain itu, ketika data tidak disajikan secara acak, sulit bagi algoritme untuk menemukan solusi optimal untuk semua tipe data dengan cepat; dalam beberapa kasus, algoritme mungkin tidak akan pernah menemukan solusi optimal. Mengacak data pelatihan membantu algoritme untuk menyatu pada solusi optimal lebih cepat.

Misalnya, Anda ingin melatih model ML untuk memprediksi jenis produk, dan data pelatihan Anda mencakup jenis produk film, mainan, dan video game. Jika Anda mengurutkan data berdasarkan kolom tipe produk sebelum mengunggah data ke Amazon S3, maka algoritme akan melihat data menurut abjad berdasarkan jenis produk. Algoritma melihat semua data Anda untuk film terlebih dahulu, dan model ML Anda mulai mempelajari pola untuk film. Kemudian, ketika model Anda menemukan data tentang mainan, setiap pembaruan yang dibuat algoritme akan sesuai dengan model dengan jenis produk mainan, bahkan jika pembaruan tersebut menurunkan pola yang sesuai dengan film. Peralihan tiba-tiba dari jenis film ke mainan ini dapat menghasilkan model yang tidak belajar bagaimana memprediksi jenis produk secara akurat.

Untuk informasi tentang jenis pengocokan default, lihat [Parameter Pelatihan: Jenis dan Nilai Default](#)

Regularisasi

Regularisasi membantu mencegah model linier agar tidak menyesuaikan contoh data pelatihan (yaitu, menghafal pola alih-alih menggeneralisasikannya) dengan menghukum nilai bobot ekstrem. Regularisasi L1 memiliki efek mengurangi jumlah fitur yang digunakan dalam model dengan mendorong ke nol bobot fitur yang seharusnya memiliki bobot kecil. Akibatnya, regularisasi L1 menghasilkan model yang jarang dan mengurangi jumlah noise dalam model. Regularisasi L2 menghasilkan nilai bobot keseluruhan yang lebih kecil, dan menstabilkan bobot ketika ada korelasi tinggi antara fitur input. Anda mengontrol jumlah regularisasi L1 atau L2 yang diterapkan dengan menggunakan parameter `Regularization type` dan `Regularization amount`. Nilai regularisasi yang sangat besar dapat menghasilkan semua fitur yang memiliki bobot nol, mencegah model dari pola pembelajaran.

Untuk informasi tentang nilai regularisasi default, lihat. [Parameter Pelatihan: Jenis dan Nilai Default](#)


Mengevaluasi Akurasi Model

Tujuan dari model ML adalah untuk mempelajari pola yang menggeneralisasi dengan baik untuk data yang tidak terlihat, bukan hanya menghafal data yang ditampilkan selama pelatihan. Setelah Anda memiliki model, penting untuk memeriksa apakah model Anda berkinerja baik pada contoh tak terlihat yang belum Anda gunakan untuk melatih model. Untuk melakukan ini, Anda menggunakan model untuk memprediksi jawaban pada kumpulan data evaluasi (data yang dipegang) dan kemudian membandingkan target yang diprediksi dengan jawaban sebenarnya (kebenaran dasar).

Sejumlah metrik digunakan dalam ML untuk mengukur akurasi prediktif suatu model. Pilihan metrik akurasi tergantung pada tugas ML. Penting untuk meninjau metrik ini untuk memutuskan apakah model Anda berkinerja baik.

Klasifikasi Biner

Output aktual dari banyak algoritma klasifikasi biner adalah skor prediksi. Skor menunjukkan kepastian sistem bahwa pengamatan yang diberikan termasuk dalam kelas positif. Untuk membuat keputusan tentang apakah pengamatan harus diklasifikasikan sebagai positif atau negatif, sebagai konsumen skor ini, Anda akan menafsirkan skor dengan memilih ambang klasifikasi (cut-off) dan membandingkan skor terhadapnya. Setiap pengamatan dengan skor lebih tinggi dari ambang batas kemudian diprediksi sebagai kelas positif dan skor lebih rendah dari ambang batas diprediksi sebagai kelas negatif.



Gambar 1: Distribusi Skor untuk Model Klasifikasi Biner

Prediksi sekarang dibagi menjadi empat kelompok berdasarkan jawaban yang diketahui aktual dan jawaban yang diprediksi: prediksi positif yang benar (positif benar), prediksi negatif yang benar (negatif benar), prediksi positif salah (positif palsu) dan prediksi negatif yang salah (negatif palsu).

Metrik akurasi klasifikasi biner mengukur dua jenis prediksi yang benar dan dua jenis kesalahan. Metrik tipikal adalah akurasi (ACC), presisi, ingatan, tingkat positif palsu, pengukuran F1. Setiap metrik mengukur aspek yang berbeda dari model prediktif. Akurasi (ACC) mengukur fraksi prediksi yang benar. Presisi mengukur fraksi positif aktual di antara contoh-contoh yang diprediksi positif. Ingat mengukur berapa banyak positif aktual yang diprediksi sebagai positif. F1-measure adalah mean harmonik presisi dan recall.

AUC adalah jenis metrik yang berbeda. Ini mengukur kemampuan model untuk memprediksi skor yang lebih tinggi untuk contoh positif dibandingkan dengan contoh negatif. Karena AUC tidak tergantung pada ambang batas yang dipilih, Anda bisa merasakan kinerja prediksi model Anda dari metrik AUC tanpa memilih ambang batas.

Bergantung pada masalah bisnis Anda, Anda mungkin lebih tertarik pada model yang berkinerja baik untuk subset tertentu dari metrik ini. Misalnya, dua aplikasi bisnis mungkin memiliki persyaratan yang sangat berbeda untuk model ML-nya:


- Satu aplikasi mungkin perlu sangat yakin tentang prediksi positif yang sebenarnya positif (presisi tinggi) dan mampu salah mengklasifikasikan beberapa contoh positif sebagai negatif (ingatan sedang).
- Aplikasi lain mungkin perlu memprediksi dengan benar sebanyak mungkin contoh positif (ingatan tinggi) dan akan menerima beberapa contoh negatif yang salah diklasifikasikan sebagai positif (presisi sedang).

Di Amazon ML, pengamatan mendapatkan skor yang diprediksi dalam kisaran [0,1]. Ambang skor untuk membuat keputusan mengklasifikasikan contoh sebagai 0 atau 1 ditetapkan secara default menjadi 0,5. Amazon ML memungkinkan Anda meninjau implikasi memilih ambang batas skor yang berbeda dan memungkinkan Anda memilih ambang batas yang sesuai dengan kebutuhan bisnis Anda.

Klasifikasi Multiclass

Berbeda dengan proses untuk masalah klasifikasi biner, Anda tidak perlu memilih ambang skor untuk membuat prediksi. Jawaban yang diprediksi adalah kelas (yaitu, label) dengan skor prediksi tertinggi. Dalam beberapa kasus, Anda mungkin ingin menggunakan jawaban yang diprediksi hanya jika diprediksi dengan skor tinggi. Dalam hal ini, Anda dapat memilih ambang batas pada skor yang diprediksi berdasarkan mana Anda akan menerima jawaban yang diprediksi atau tidak.

Metrik tipikal yang digunakan dalam multiclass sama dengan metrik yang digunakan dalam kasus klasifikasi biner. Metrik dihitung untuk setiap kelas dengan memperlakukannya sebagai masalah klasifikasi biner setelah mengelompokkan semua kelas lain sebagai milik kelas kedua. Kemudian metrik biner dirata-ratakan di semua kelas untuk mendapatkan metrik rata-rata makro (perlakukan setiap kelas sama) atau rata-rata tertimbang (tertimbang berdasarkan frekuensi kelas). Di Amazon ML, ukuran F1 rata-rata makro digunakan untuk mengevaluasi keberhasilan prediktif pengklasifikasi multiclass.




Gambar 2: Matriks Kebingungan untuk model klasifikasi multikelas

Hal ini berguna untuk meninjau matriks kebingungan untuk masalah multiclass. Matriks kebingungan adalah tabel yang menunjukkan setiap kelas dalam data evaluasi dan jumlah atau persentase prediksi yang benar dan prediksi yang salah.

Regresi

Untuk tugas regresi, metrik akurasi tipikal adalah root mean square error (RMSE) dan mean absolute percentage error (MAPE). Metrik ini mengukur jarak antara target numerik yang diprediksi dan jawaban numerik aktual (kebenaran dasar). Di Amazon ML, metrik RMSE digunakan untuk mengevaluasi akurasi prediktif model regresi.



Gambar 3: Distribusi residu untuk model Regresi

Merupakan praktik umum untuk meninjau residu untuk masalah regresi. Sisa untuk pengamatan dalam data evaluasi adalah perbedaan antara target sebenarnya dan target yang diprediksi. Residu mewakili bagian target yang tidak dapat diprediksi oleh model. Sisa positif menunjukkan bahwa model meremehkan target (target sebenarnya lebih besar dari target yang diprediksi). Sisa negatif menunjukkan perkiraan yang terlalu tinggi (target sebenarnya lebih kecil dari target yang diprediksi). Histogram residu pada data evaluasi ketika didistribusikan dalam bentuk lonceng dan berpusat pada nol menunjukkan bahwa model membuat kesalahan secara acak dan tidak secara sistematis di atas atau di bawah memprediksi rentang nilai target tertentu. Jika residu tidak membentuk bentuk lonceng berpusat nol, ada beberapa struktur dalam kesalahan prediksi model. Menambahkan lebih banyak variabel ke model dapat membantu model menangkap pola yang tidak ditangkap oleh model saat ini.

Meningkatkan Akurasi Model


Memperoleh model ML yang sesuai dengan kebutuhan Anda biasanya melibatkan iterasi melalui proses ML ini dan mencoba beberapa variasi. Anda mungkin tidak mendapatkan model yang

sangat prediktif pada iterasi pertama, atau Anda mungkin ingin meningkatkan model Anda untuk mendapatkan prediksi yang lebih baik. Untuk meningkatkan kinerja, Anda dapat mengulangi langkah-langkah ini:

1. Kumpulkan data: Tingkatkan jumlah contoh pelatihan
2. Pemrosesan fitur: Tambahkan lebih banyak variabel dan pemrosesan fitur yang lebih baik
3. Penyetelan parameter model: Pertimbangkan nilai alternatif untuk parameter pelatihan yang digunakan oleh algoritme pembelajaran Anda

Model Fit: Underfitting vs. Overfitting

Memahami kecocokan model penting untuk memahami akar penyebab akurasi model yang buruk. Pemahaman ini akan memandu Anda untuk mengambil langkah-langkah korektif. Kita dapat menentukan apakah model prediktif tidak sesuai atau tidak sesuai dengan data pelatihan dengan melihat kesalahan prediksi pada data pelatihan dan data evaluasi.



Model Anda tidak sesuai dengan data pelatihan saat model berkinerja buruk pada data pelatihan. Ini karena model tidak dapat menangkap hubungan antara contoh input (sering disebut X) dan nilai target (sering disebut Y). Model Anda terlalu sesuai dengan data pelatihan Anda ketika Anda melihat bahwa model berkinerja baik pada data pelatihan tetapi tidak berkinerja baik pada data evaluasi. Ini karena model menghafal data yang telah dilihatnya dan tidak dapat menggeneralisasi ke contoh yang tidak terlihat.

Kinerja yang buruk pada data pelatihan bisa jadi karena modelnya terlalu sederhana (fitur input tidak cukup ekspresif) untuk menggambarkan target dengan baik. Kinerja dapat ditingkatkan dengan meningkatkan fleksibilitas model. Untuk meningkatkan fleksibilitas model, coba yang berikut ini:

- Tambahkan fitur khusus domain baru dan lebih banyak fitur produk Cartesian, dan ubah jenis pemrosesan fitur yang digunakan (misalnya, meningkatkan ukuran n-gram)
- Kurangi jumlah regularisasi yang digunakan

Jika model Anda terlalu sesuai dengan data pelatihan, masuk akal untuk mengambil tindakan yang mengurangi fleksibilitas model. Untuk mengurangi fleksibilitas model, coba yang berikut ini:

- Pemilihan fitur: pertimbangkan untuk menggunakan lebih sedikit kombinasi fitur, kurangi ukuran n-gram, dan kurangi jumlah nampan atribut numerik.
- Tingkatkan jumlah regularisasi yang digunakan.

Akurasi pada data pelatihan dan pengujian bisa buruk karena algoritma pembelajaran tidak memiliki cukup data untuk dipelajari. Anda dapat meningkatkan kinerja dengan melakukan hal berikut:

- Tingkatkan jumlah contoh data pelatihan.
- Tingkatkan jumlah lintasan pada data pelatihan yang ada.

Menggunakan Model untuk Membuat Prediksi

Sekarang setelah Anda memiliki model ML yang berkinerja baik, Anda akan menggunakannya untuk membuat prediksi. Di Amazon Machine Learning, ada dua cara untuk menggunakan model untuk membuat prediksi:

Prediksi Batch

Prediksi Batch berguna ketika Anda ingin menghasilkan prediksi untuk serangkaian pengamatan sekaligus, dan kemudian mengambil tindakan pada persentase atau jumlah pengamatan tertentu. Biasanya, Anda tidak memiliki persyaratan latensi rendah untuk aplikasi semacam itu. Misalnya, ketika Anda ingin memutuskan pelanggan mana yang akan ditargetkan sebagai bagian dari kampanye iklan untuk suatu produk, Anda akan mendapatkan skor prediksi untuk semua pelanggan, mengurutkan prediksi model Anda untuk mengidentifikasi pelanggan mana yang paling mungkin membeli, dan kemudian menargetkan mungkin 5% pelanggan teratas yang paling mungkin membeli.

Prediksi Online

Skenario prediksi online adalah untuk kasus ketika Anda ingin menghasilkan prediksi one-by-one berdasarkan untuk setiap contoh terlepas dari contoh lain, dalam lingkungan latensi rendah.

Misalnya, Anda dapat menggunakan prediksi untuk membuat keputusan segera tentang apakah transaksi tertentu kemungkinan merupakan transaksi penipuan.

Melatih Ulang Model pada Data Baru

Agar model dapat memprediksi secara akurat, data yang diprediksi harus memiliki distribusi yang sama dengan data di mana model dilatih. Karena distribusi data dapat diharapkan melayang dari waktu ke waktu, menerapkan model bukanlah latihan satu kali melainkan proses yang berkelanjutan. Merupakan praktik yang baik untuk terus memantau data yang masuk dan melatih kembali model Anda pada data yang lebih baru jika Anda menemukan bahwa distribusi data telah menyimpang secara signifikan dari distribusi data pelatihan asli. Jika pemantauan data untuk mendeteksi perubahan dalam distribusi data memiliki overhead yang tinggi, maka strategi yang lebih sederhana adalah melatih model secara berkala, misalnya harian, mingguan, atau bulanan. Untuk melatih kembali model di Amazon, Anda perlu membuat model baru berdasarkan data pelatihan baru Anda.

Proses Amazon Machine Learning

Tabel berikut menjelaskan cara menggunakan konsol Amazon ML untuk melakukan proses ML yang diuraikan dalam dokumen ini.

Proses ML	Tugas Amazon ML
Analisis data Anda	Untuk menganalisis data Anda di Amazon, buat sumber data dan tinjau halaman wawasan data.
Pisahkan data menjadi sumber data pelatihan dan evaluasi	<p>Amazon ML dapat membagi sumber data untuk menggunakan 70% data untuk pelatihan model dan 30% untuk mengevaluasi kinerja prediktif model Anda.</p> <p>Saat Anda menggunakan wizard Buat Model ML dengan pengaturan default, Amazon ML membagi data untuk Anda.</p> <p>Jika Anda menggunakan wizard Buat Model ML dengan pengaturan kustom, dan memilih untuk mengevaluasi model ML, Anda akan melihat opsi untuk mengizinkan Amazon ML membagi data untuk Anda dan menjalankan evaluasi pada 30% data.</p>

Proses ML	Tugas Amazon ML
Kocokkan data latihan Anda	Saat Anda menggunakan wizard Buat Model ML dengan setelan default, Amazon ML akan mengacak data Anda untuk Anda. Anda juga dapat mengacak data Anda sebelum mengimpornya ke Amazon ML.
Fitur proses	<p>Proses penyusunan data pelatihan dalam format optimal untuk pembelajaran dan generalisasi dikenal sebagai transformasi fitur. Saat Anda menggunakan wizard Buat Model ML dengan setelan default, Amazon ML menyarankan pengaturan pemrosesan fitur untuk data Anda.</p> <p>Untuk menentukan pengaturan pemrosesan fitur, gunakan opsi Kustom Create Model Model Wizard dan berikan resep pemrosesan fitur.</p>
Latih modelnya	Saat Anda menggunakan wizard Buat Model ML untuk membuat model di Amazon, Amazon ML melatih model Anda.
Pilih parameter model	Di Amazon ML, Anda dapat menyetel empat parameter yang memengaruhi kinerja prediktif model Anda: ukuran model, jumlah lintasan, jenis pengocokan, dan regularisasi. Anda dapat mengatur parameter ini saat menggunakan wizard Buat Model ML untuk membuat model ML dan memilih opsi Kustom.
Evaluasi kinerja model	Gunakan wizard Buat Evaluasi untuk menilai kinerja prediktif model Anda.
Pemilihan fitur	Algoritma pembelajaran Amazon Amazon dapat menghapus fitur yang tidak berkontribusi banyak pada proses pembelajaran. Untuk menunjukkan bahwa Anda ingin menghapus fitur tersebut, pilih L1 regularization parameter saat Anda membuat model ML.
Tetapkan ambang skor untuk akurasi prediksi	Tinjau kinerja prediktif model dalam laporan evaluasi pada ambang skor yang berbeda, dan kemudian tetapkan ambang skor berdasarkan aplikasi bisnis Anda. Ambang skor menentukan bagaimana model mendefinisikan kecocokan prediksi. Sesuaikan nomor untuk mengontrol positif palsu dan negatif palsu.

Proses ML	Tugas Amazon ML
Gunakan modelnya	<p>Gunakan model Anda untuk mendapatkan prediksi untuk sejumlah pengamatan dengan menggunakan wizard Buat Prediksi Batch.</p> <p>Atau, dapatkan prediksi untuk pengamatan individu sesuai permintaan dengan mengaktifkan model ML untuk memproses prediksi waktu nyata menggunakan API. <code>Predict</code></p>

Menyiapkan Amazon Machine Learning

Anda memerlukan akun AWS sebelum dapat menggunakan Amazon Machine Learning untuk pertama kalinya. Jika Anda tidak memiliki akun, lihat Mendaftar untuk AWS.

Mendaftar ke AWS

Saat Anda mendaftar ke Amazon Web Services (AWS), akun AWS Anda secara otomatis mendaftar untuk semua layanan di AWS, termasuk Amazon ML. Anda hanya membayar biaya layanan yang Anda gunakan. Jika Anda sudah memiliki akun AWS, lewati langkah ini. Jika Anda tidak memiliki akun AWS, gunakan prosedur berikut untuk membuatnya.

Untuk mendaftar akun AWS

1. Buka <http://aws.amazon.com> dan pilih Daftar.
2. Ikuti petunjuk di layar.

Bagian dari prosedur pendaftaran melibatkan menerima panggilan telepon dan memasukkan PIN menggunakan keypad telepon.

Tutorial: Menggunakan Amazon ML untuk Memprediksi Respons terhadap Penawaran Pemasaran

Dengan Amazon Machine Learning (Amazon ML), Anda dapat membuat dan melatih model prediktif serta meng-host aplikasi Anda dalam solusi cloud yang dapat diskalakan. Dalam tutorial ini, kami menunjukkan kepada Anda cara menggunakan konsol Amazon Amazon untuk membuat sumber data, membangun model pembelajaran mesin (ML), dan menggunakan model untuk menghasilkan prediksi yang dapat Anda gunakan dalam aplikasi Anda.

Contoh latihan kami menunjukkan cara mengidentifikasi calon pelanggan untuk kampanye pemasaran yang ditargetkan, tetapi Anda dapat menerapkan prinsip yang sama untuk membuat dan menggunakan berbagai model ML. Untuk menyelesaikan latihan sampel, Anda akan menggunakan kumpulan data perbankan dan pemasaran yang tersedia untuk umum dari [University of California di Irvine \(UCI\) Machine Learning Repository](#). Kumpulan data ini berisi informasi umum tentang pelanggan, dan informasi tentang bagaimana mereka menanggapi kontak pemasaran sebelumnya. Anda akan menggunakan data ini untuk mengidentifikasi pelanggan mana yang paling mungkin berlangganan produk baru Anda, setoran berjangka bank, juga dikenal sebagai sertifikat setoran (CD).

Warning

Tutorial ini tidak termasuk dalam AWS tingkat gratis. Untuk informasi selengkapnya tentang harga Amazon ML, lihat [Harga Amazon Machine Learning](#).

Prasyarat

Untuk melakukan tutorial, Anda harus memiliki akun AWS. Jika Anda tidak memiliki akun AWS, lihat [Menyiapkan Amazon Machine Learning](#).

Langkah-langkah

- [Langkah 1: Siapkan Data Anda](#)
- [Langkah 2: Buat Datasource Pelatihan](#)
- [Langkah 3: Buat Model ML](#)

- [Langkah 4: Tinjau Kinerja Prediktif Model ML dan Tetapkan Ambang Skor](#)
- [Langkah 5: Gunakan Model ML untuk Menghasilkan Prediksi](#)
- [Langkah 6: Bersihkan](#)

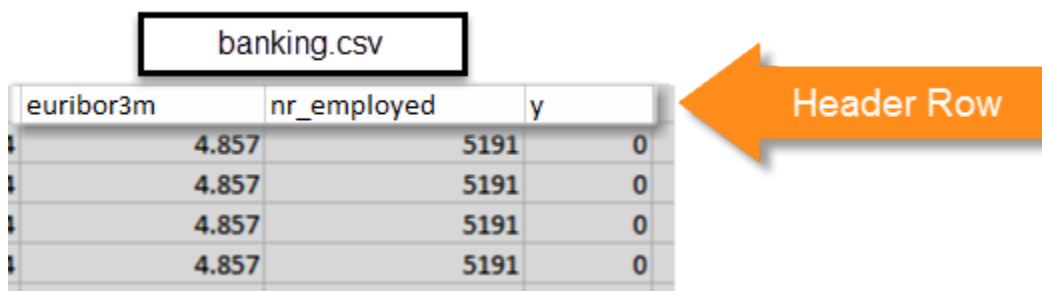
Langkah 1: Siapkan Data Anda

Dalam pembelajaran mesin, Anda biasanya mendapatkan data dan memastikan bahwa itu diformat dengan baik sebelum memulai proses pelatihan. Untuk keperluan tutorial ini, kami memperoleh kumpulan data sampel dari [UCI Machine Learning Repository](#), memformatnya agar sesuai dengan pedoman Amazon, dan membuatnya tersedia untuk Anda unduh. Unduh kumpulan data dari lokasi penyimpanan Amazon Simple Storage Service (Amazon S3) kami dan unggah ke bucket S3 Anda sendiri dengan mengikuti prosedur dalam topik ini.

Untuk persyaratan pemformatan Amazon ML, lihat [Memahami Format Data untuk Amazon](#).

Untuk mengunduh kumpulan data

1. Unduh file yang berisi data historis untuk pelanggan yang telah membeli produk yang mirip dengan deposito berjangka bank Anda dengan mengklik [banking.zip](#). Buka zip folder dan simpan file `banking.csv` ke komputer Anda.
2. Unduh file yang akan Anda gunakan untuk memprediksi apakah calon pelanggan akan menanggapi penawaran Anda dengan mengklik [banking-batch.zip](#). Buka zip folder dan simpan file `banking-batch.csv` ke komputer Anda.
3. Buka `banking.csv`. Anda akan melihat baris dan kolom data. Baris header berisi nama atribut untuk setiap kolom. Atribut adalah properti unik bernama yang menggambarkan karakteristik tertentu dari setiap pelanggan; misalnya, `nr_employed` menunjukkan status pekerjaan pelanggan. Setiap baris mewakili kumpulan pengamatan tentang satu pelanggan.



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

Anda ingin model ML Anda menjawab pertanyaan “Apakah pelanggan ini akan berlangganan produk baru saya?”. Dalam `banking.csv` dataset, jawaban untuk pertanyaan ini adalah atribut

y, yang berisi nilai 1 (untuk ya) atau 0 (untuk no). Atribut yang Anda inginkan Amazon ML. untuk mempelajari cara memprediksi dikenal sebagai atribut target.

Note

Atribut y adalah atribut biner. Ini hanya dapat berisi satu dari dua nilai, dalam hal ini 0 atau 1. Dalam kumpulan data UCI asli, atribut y adalah Ya atau Tidak. Kami telah mengedit dataset asli untuk Anda. Semua nilai atribut y yang berarti ya sekarang 1, dan semua nilai yang berarti tidak sekarang 0. Jika Anda menggunakan data Anda sendiri, Anda dapat menggunakan nilai lain untuk atribut biner. Untuk informasi selengkapnya tentang nilai yang valid, lihat [Menggunakan AttributeType Field](#).

Contoh berikut menunjukkan data sebelum dan sesudah kita mengubah nilai dalam atribut y ke atribut biner 0 dan 1.

Before transformation

banking.csv			
euribor3m	nr_employed	y	
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	

banking-batch.csvFile tidak berisi atribut y. Setelah Anda membuat model ML, Anda akan menggunakan model untuk memprediksi y untuk setiap catatan dalam file itu.

Selanjutnya, unggah banking-batch.csv file banking.csv dan ke Amazon S3.

Untuk mengunggah file ke lokasi Amazon S3

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Dalam daftar Semua Bucket, buat bucket atau pilih lokasi tempat Anda ingin mengunggah file.
3. Di bilah navigasi, pilih Unggah.
4. Pilih Tambahkan File.
5. Di kotak dialog, navigasikan ke desktop Anda, pilih banking.csv dan banking-batch.csv, lalu pilih Buka.

Sekarang Anda siap untuk [membuat sumber data pelatihan Anda](#).

Langkah 2: Buat Datasource Pelatihan

Setelah mengunggah banking.csv kumpulan data ke lokasi Amazon Simple Storage Service (Amazon S3), Anda menggunakannya untuk membuat sumber data pelatihan. Sumber data adalah objek Amazon Machine Learning (Amazon ML) yang berisi lokasi data input dan metadata penting tentang data input Anda. Amazon ML menggunakan sumber data untuk operasi seperti pelatihan dan evaluasi model ML.

Untuk membuat sumber data, berikan yang berikut ini:

- Lokasi Amazon S3 dari data Anda dan izin untuk mengakses data
- Skema, yang mencakup nama-nama atribut dalam data dan jenis setiap atribut (Numerik, Teks, Kategori, atau Biner)
- Nama atribut yang berisi jawaban yang Anda ingin Amazon ML pelajari untuk memprediksi, atribut target

Note

Sumber data tidak benar-benar menyimpan data Anda, itu hanya mereferensikannya. Hindari memindahkan atau mengubah file yang disimpan di Amazon S3. Jika Anda memindahkan

atau mengubahnya, Amazon ML tidak dapat mengaksesnya untuk membuat model ML, menghasilkan evaluasi, atau menghasilkan prediksi.


Untuk membuat sumber data pelatihan

1. Buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Pilih Mulai.

Note

Tutorial ini mengasumsikan bahwa ini adalah pertama kalinya Anda menggunakan Amazon ML. Jika Anda pernah menggunakan Amazon ML sebelumnya, Anda dapat menggunakan Create new... daftar drop-down di dasbor Amazon Amazon untuk membuat sumber data baru.

3. Pada halaman Memulai Amazon Machine Learning, pilih Luncurkan.



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. Pada halaman Input Data, untuk Di mana data Anda berada? , pastikan bahwa S3 dipilih.


Where is your data located? S3 Redshift

- Untuk Lokasi S3, ketik lokasi lengkap `banking.csv` file dari Langkah 1: Siapkan Data Anda. Sebagai contoh: *your-bucket*/**banking.csv**. Amazon ML menambahkan `s3://` ke nama bucket Anda untuk Anda.
- Untuk nama Datasource, ketik. **Banking Data 1**

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. 

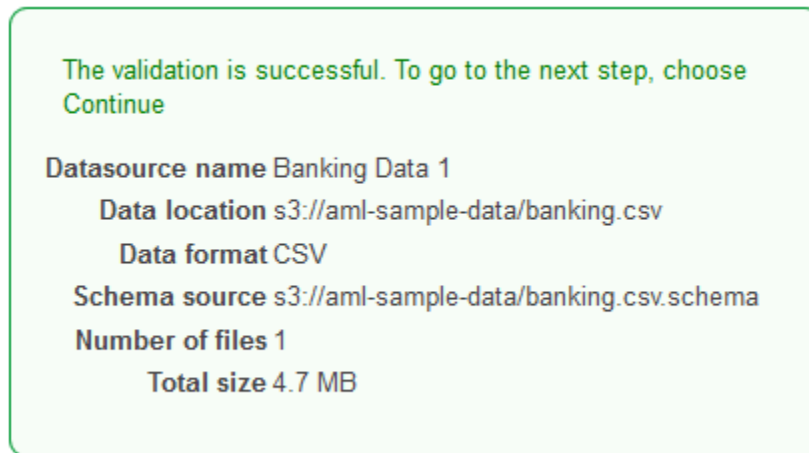
Datasource name

Banking Data 1

- Pilih Verifikasi.
- Di kotak dialog izin S3, pilih Ya.



- Jika Amazon ML dapat mengakses dan membaca file data di lokasi S3, Anda akan melihat halaman yang mirip dengan berikut ini. Tinjau properti, lalu pilih Lanjutkan.



Selanjutnya, Anda membuat skema. Skema adalah informasi yang dibutuhkan Amazon MLL untuk menafsirkan data input untuk model ML, termasuk nama atribut dan tipe data yang ditetapkan, dan nama atribut khusus. Ada dua cara untuk menyediakan Amazon ML dengan skema:

- Berikan file skema terpisah saat Anda mengunggah data Amazon S3 Anda.
- Izinkan Amazon ML menyimpulkan jenis atribut dan membuat skema untuk Anda.

Dalam tutorial ini, kita akan meminta Amazon ML untuk menyimpulkan skema.

Untuk informasi tentang membuat file skema terpisah, lihat [Membuat Skema Data untuk Amazon ML](#).

Untuk memungkinkan Amazon ML menyimpulkan skema

1. Pada halaman Skema, Amazon ML menunjukkan skema yang disimpulkan. Tinjau tipe data yang disimpulkan Amazon ML untuk atribut. Penting bahwa atribut diberikan tipe data yang benar untuk membantu Amazon ML mencerna data dengan benar dan untuk mengaktifkan pemrosesan fitur yang benar pada atribut.
 - Atribut yang hanya memiliki dua kemungkinan status, seperti ya atau tidak, harus ditandai sebagai Biner.
 - Atribut yang merupakan angka atau string yang digunakan untuk menunjukkan kategori harus ditandai sebagai Kategoris.
 - Atribut yang merupakan besaran numerik yang urutannya bermakna harus ditandai sebagai Numerik.

- Atribut yang merupakan string yang ingin Anda perlakukan sebagai kata yang dibatasi oleh spasi harus ditandai sebagai Teks.

<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

2. Dalam tutorial ini, Amazon ML telah mengidentifikasi tipe data untuk semua atribut dengan benar, jadi pilih Lanjutkan.

Selanjutnya, pilih atribut target.


Ingatlah bahwa targetnya adalah atribut yang harus dipelajari oleh model ML untuk diprediksi. Atribut y menunjukkan apakah seseorang telah berlangganan kampanye di masa lalu: 1 (ya) atau 0 (tidak).

Note

Pilih atribut target hanya jika Anda akan menggunakan sumber data untuk melatih dan mengevaluasi model ML.

Untuk memilih y sebagai atribut target

1. Di kanan bawah tabel, pilih panah tunggal untuk maju ke halaman terakhir tabel, di mana atribut bernama y muncul.



2. Di kolom Target, pilih y.



Amazon ML mengonfirmasi bahwa y dipilih sebagai target Anda.

3. Pilih Lanjutkan.
4. Pada halaman ID Baris, untuk Apakah data Anda berisi pengenalan? , pastikan bahwa Tidak, default, dipilih.
5. Pilih Review, lalu pilih Continue.

Sekarang setelah Anda memiliki sumber data pelatihan, Anda siap untuk [membuat](#) model Anda.

Langkah 3: Buat Model ML

Setelah Anda membuat sumber data pelatihan, Anda menggunakannya untuk membuat model ML, melatih model, dan kemudian mengevaluasi hasilnya. Model ML adalah kumpulan pola yang ditemukan Amazon dalam data Anda selama pelatihan. Anda menggunakan model untuk membuat prediksi.

Untuk membuat model ML

1. Karena wizard Memulai membuat sumber data pelatihan dan model, Amazon Machine Learning (Amazon ML) secara otomatis menggunakan sumber data pelatihan yang baru saja Anda buat, dan membawa Anda langsung ke halaman pengaturan model ML. Pada halaman pengaturan model ML, untuk nama model ML, pastikan bahwa default **ML model: Banking Data 1**, ditampilkan.

Menggunakan nama ramah, seperti default, membantu Anda mengidentifikasi dan mengelola model ML dengan mudah.

2. Untuk pengaturan Pelatihan dan evaluasi, pastikan bahwa Default dipilih.

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. [i](#)

Name this evaluation (Optional)

Evaluation: ML model: Banking Data 1

3. Untuk Nama evaluasi ini, terima defaultnya, **Evaluation: ML model: Banking Data 1**.
4. Pilih Tinjau, tinjau pengaturan Anda, lalu pilih Selesai.

Setelah Anda memilih Selesai, Amazon ML menambahkan model Anda ke antrian pemrosesan. Saat Amazon ML membuat model Anda, model tersebut menerapkan default dan melakukan tindakan berikut:

- Membagi sumber data pelatihan menjadi dua bagian, satu berisi 70% data dan satu berisi 30% sisanya
- Melatih model ML pada bagian yang berisi 70% dari data input
- Mengevaluasi model menggunakan 30% sisanya dari data input

Saat model Anda dalam antrian, Amazon ML melaporkan statusnya sebagai Tertunda.

Meskipun Amazon ML membuat model Anda, Amazon melaporkan statusnya sebagai Sedang

Berlangsung. Ketika telah menyelesaikan semua tindakan, ia melaporkan status sebagai Selesai. Tunggu evaluasi selesai sebelum melanjutkan.

Sekarang Anda siap untuk [meninjau kinerja model Anda dan menetapkan skor cut-off](#).

Untuk informasi lebih lanjut tentang pelatihan dan evaluasi model, lihat [Pelatihan Model ML](#) dan [evaluate an ML model](#).

Langkah 4: Tinjau Kinerja Prediktif Model ML dan Tetapkan Ambang Skor


Sekarang setelah Anda membuat model ML dan Amazon Machine Learning (Amazon ML) telah mengevaluasinya, mari kita lihat apakah itu cukup baik untuk digunakan. Selama evaluasi, Amazon ML menghitung metrik kualitas standar industri, yang disebut metrik Area Under a Curve (AUC), yang mengekspresikan kualitas kinerja model ML Anda. Amazon ML juga menafsirkan metrik AUC untuk memberi tahu Anda apakah kualitas model ML memadai untuk sebagian besar aplikasi pembelajaran mesin. (Pelajari lebih lanjut tentang AUC di [Mengukur Akurasi Model ML](#).) Mari kita tinjau metrik AUC, lalu sesuaikan ambang skor atau cut-off untuk mengoptimalkan kinerja prediktif model Anda.

Untuk meninjau metrik AUC untuk model ML Anda

1. Pada halaman ringkasan model ML, di panel navigasi laporan model ML, pilih Evaluasi, pilih Evaluasi: Model ML: Model perbankan 1, lalu pilih Ringkasan.
2. Pada halaman ringkasan Evaluasi, tinjau ringkasan evaluasi, termasuk metrik kinerja AUC model.

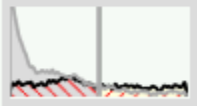
ML model performance metric

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](#)

Model ML menghasilkan skor prediksi numerik untuk setiap catatan dalam sumber data prediksi, dan kemudian menerapkan ambang batas untuk mengubah skor ini menjadi label biner 0 (untuk tidak) atau 1 (untuk ya). Dengan mengubah ambang skor, Anda dapat menyesuaikan cara model ML menetapkan label ini. Sekarang, atur ambang skor.

Untuk menetapkan ambang skor untuk model ML Anda

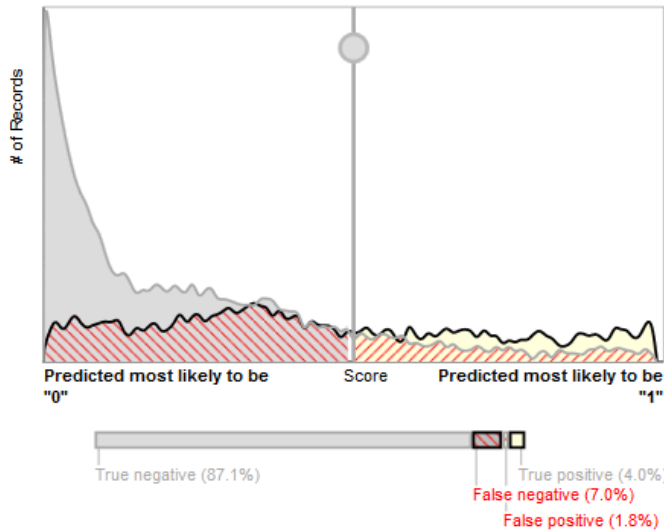
1. Pada halaman Ringkasan Evaluasi, pilih Sesuaikan Ambang Skor.

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

Anda dapat menyempurnakan metrik kinerja model ML Anda dengan menyesuaikan ambang skor. Menyesuaikan nilai ini mengubah tingkat kepercayaan yang harus dimiliki model dalam prediksi sebelum menganggap prediksi itu positif. Ini juga mengubah berapa banyak negatif palsu dan positif palsu yang bersedia Anda toleransi dalam prediksi Anda.

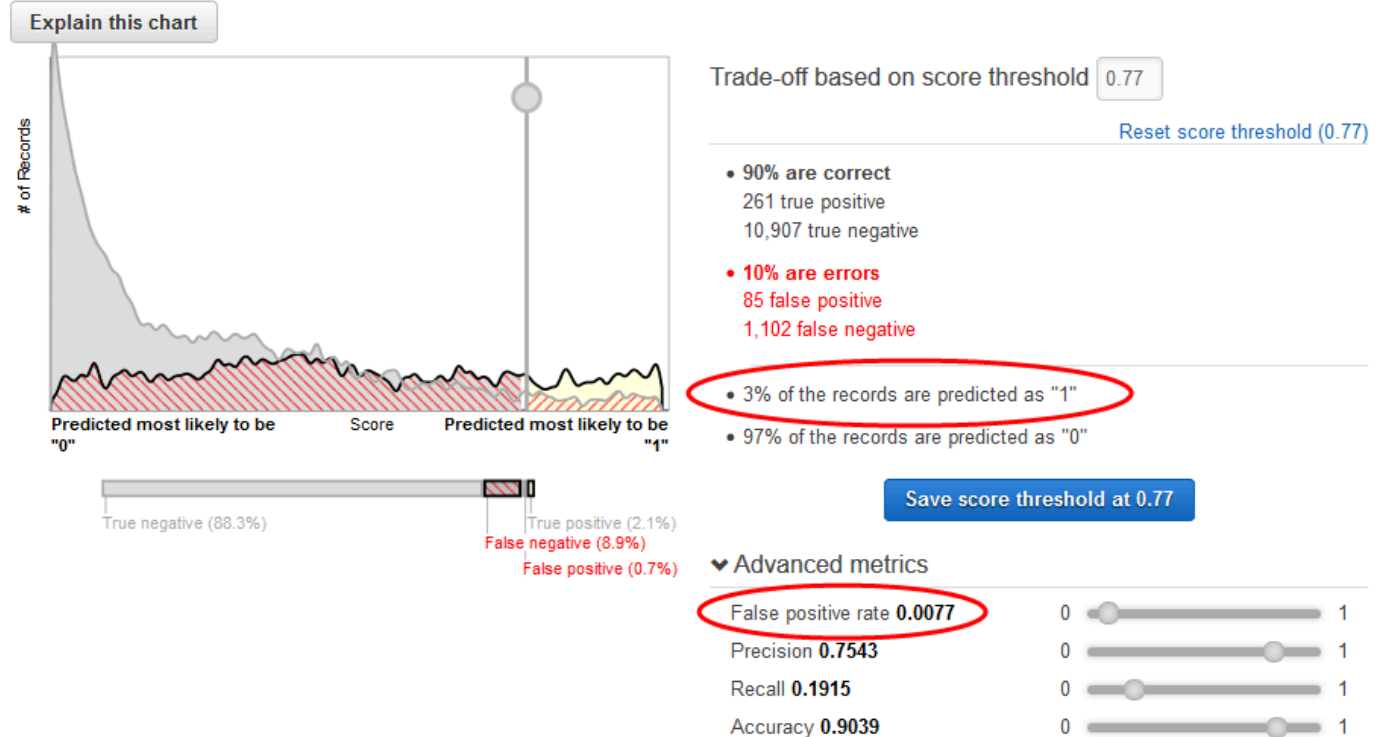
Anda dapat mengontrol batas untuk apa yang dianggap model sebagai prediksi positif dengan meningkatkan ambang skor hingga hanya menganggap prediksi dengan kemungkinan tertinggi menjadi positif sejati sebagai positif. Anda juga dapat mengurangi ambang skor sampai Anda tidak lagi memiliki negatif palsu. Pilih cutoff Anda untuk mencerminkan kebutuhan bisnis Anda. Untuk tutorial ini, setiap positif palsu membutuhkan uang kampanye, jadi kami menginginkan rasio positif sejati yang tinggi terhadap positif palsu.

2. Katakanlah Anda ingin menargetkan 3% pelanggan teratas yang akan berlangganan produk. Geser pemilih vertikal untuk mengatur ambang skor ke nilai yang sesuai dengan 3% dari catatan diprediksi sebagai "1".

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.



Perhatikan dampak ambang skor ini pada kinerja model ML: tingkat positif palsu adalah 0,007. Mari kita asumsikan bahwa tingkat positif palsu dapat diterima.

3. Pilih Simpan ambang skor pada 0,77.

Setiap kali Anda menggunakan model ML ini untuk membuat prediksi, itu akan memprediksi catatan dengan skor lebih dari 0,77 sebagai "1", dan sisa catatan sebagai "0".

Untuk mempelajari lebih lanjut tentang ambang skor, lihat [Klasifikasi Biner](#).

Sekarang Anda siap untuk [membuat prediksi menggunakan model Anda](#).

Langkah 5: Gunakan Model ML untuk Menghasilkan Prediksi

Amazon Machine Learning (Amazon Learning) dapat menghasilkan dua jenis prediksi — batch dan real-time.

Prediksi waktu nyata adalah prediksi untuk pengamatan tunggal yang dihasilkan Amazon ML. sesuai permintaan. Prediksi real-time sangat ideal untuk aplikasi seluler, situs web, dan aplikasi lain yang perlu menggunakan hasil secara interaktif.

Prediksi batch adalah seperangkat prediksi untuk sekelompok pengamatan. Amazon ML memproses catatan dalam prediksi batch bersama-sama, sehingga pemrosesan dapat memakan waktu. Gunakan prediksi batch untuk aplikasi yang memerlukan prediksi untuk serangkaian pengamatan atau prediksi yang tidak menggunakan hasil secara interaktif.

Untuk tutorial ini, Anda akan menghasilkan prediksi real-time yang memprediksi apakah satu pelanggan potensial akan berlangganan produk baru. Anda juga akan menghasilkan prediksi untuk sejumlah besar pelanggan potensial. Untuk prediksi batch, Anda akan menggunakan `banking-batch.csv` file yang Anda unggah. [Langkah 1: Siapkan Data Anda](#)


Mari kita mulai dengan prediksi real-time.

Note

Untuk aplikasi yang memerlukan prediksi real-time, Anda harus membuat titik akhir real-time untuk model ML. Anda akan dikenakan biaya saat titik akhir real-time tersedia. Sebelum Anda berkomitmen untuk menggunakan prediksi real-time dan mulai mengeluarkan biaya yang terkait dengannya, Anda dapat mencoba menggunakan fitur prediksi real-time di browser web Anda, tanpa membuat titik akhir real-time. Itulah yang akan kita lakukan untuk tutorial ini.

Untuk mencoba prediksi waktu nyata

1. Di panel navigasi laporan model ML, pilih Coba prediksi real-time.



ML model report

Summary

Settings

Monitoring

Tools

Try real-time predictions

- Pilih Tempel catatan.

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

- Dalam kotak dialog Tempel catatan, tempel pengamatan berikut:

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

- Dalam kotak dialog Tempel catatan, pilih Kirim untuk mengonfirmasi bahwa Anda ingin menghasilkan prediksi untuk pengamatan ini. Amazon ML mengisi nilai dalam bentuk prediksi real-time.

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

Note

Anda juga dapat mengisi bidang Nilai dengan mengetikkan nilai individual. Terlepas dari metode yang Anda pilih, Anda harus memberikan pengamatan yang tidak digunakan untuk melatih model.

5. Di bagian bawah halaman, pilih Buat prediksi.

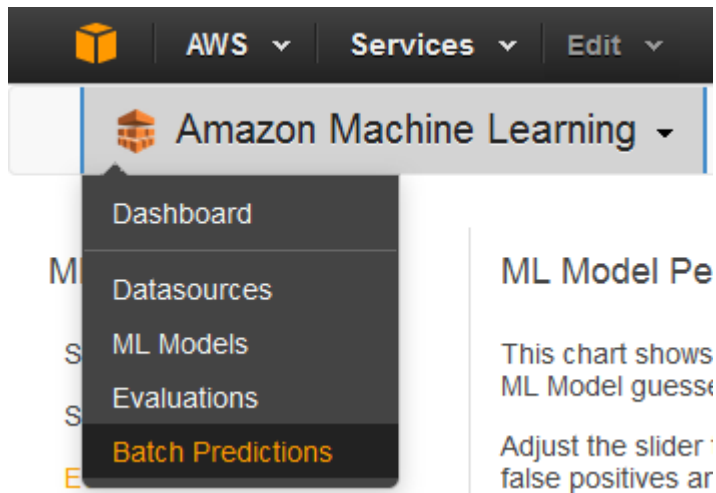
Prediksi muncul di panel Hasil prediksi di sebelah kanan. Prediksi ini memiliki label Prediksi0, yang berarti bahwa pelanggan potensial ini tidak mungkin menanggapi kampanye. Label yang diprediksi 1 akan berarti bahwa pelanggan cenderung merespons kampanye.



Sekarang, buat prediksi batch. Anda akan memberikan Amazon ML dengan nama model ML yang Anda gunakan; lokasi Amazon Simple Storage Service (Amazon S3) dari data input yang ingin Anda hasilkan prediksi (Amazon ML akan membuat sumber data prediksi batch dari data ini); dan lokasi Amazon S3 untuk menyimpan hasilnya.

Untuk membuat prediksi batch

1. Pilih Amazon Machine Learning, lalu pilih Batch Predictions.



2. Pilih Buat prediksi batch baru.
3. Pada halaman model ML untuk prediksi batch, pilih model ML: Data Perbankan 1.

Amazon ML menampilkan nama model, ID, waktu pembuatan, dan ID sumber data terkait.

4. Pilih Lanjutkan.
5. Untuk menghasilkan prediksi, Anda perlu memberikan Amazon ML data yang Anda perlukan prediksi. Ini disebut data input. Pertama, masukkan data input ke sumber data sehingga Amazon ML dapat mengaksesnya.

Untuk Cari data input, pilih Data saya ada di S3, dan saya perlu membuat sumber data.

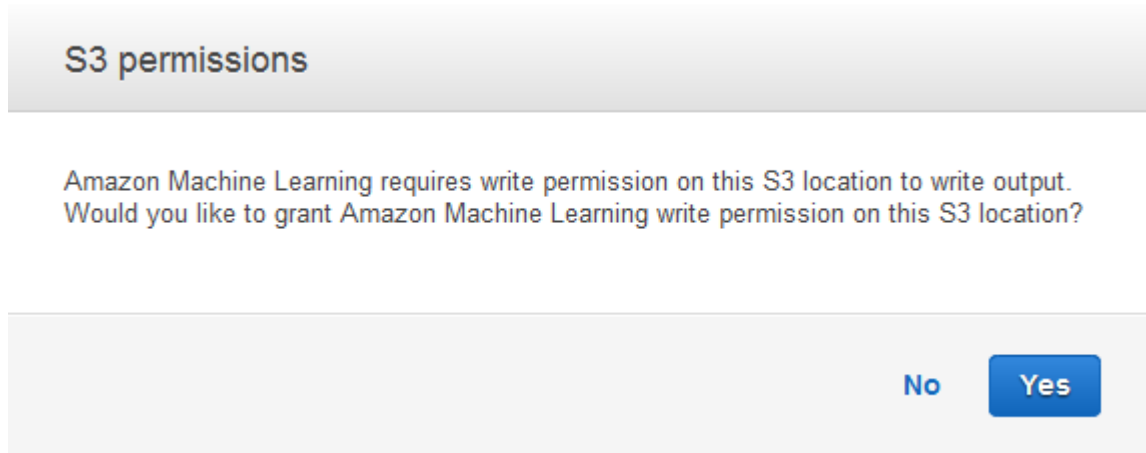
- Locate the input data**
- I already created a datasource pointing to my S3 data
 - My data is in S3, and I need to create a datasource

6. Untuk nama Datasource, ketik. **Banking Data 2**
7. Untuk Lokasi S3, ketik lokasi lengkap banking-batch.csv file: *your-bucket/banking-batch.csv*.
8. Untuk Apakah baris pertama di CSV Anda berisi nama kolom? , pilih Ya.
9. Pilih Verifikasi.

Amazon ML memvalidasi lokasi data Anda.

10. Pilih Lanjutkan.

11. Untuk tujuan S3, ketik nama lokasi Amazon S3 tempat Anda mengunggah file di Langkah 1: Siapkan Data Anda. Amazon ML mengunggah hasil prediksi di sana.
12. Untuk nama prediksi Batch, terima default, **Batch prediction: ML model: Banking Data 1**. Amazon ML memilih nama default berdasarkan model yang akan digunakan untuk membuat prediksi. Dalam tutorial ini, model dan prediksi dinamai menurut sumber data pelatihan, **Banking Data 1**.
13. Pilih Tinjau.
14. Di kotak dialog izin S3, pilih Ya.

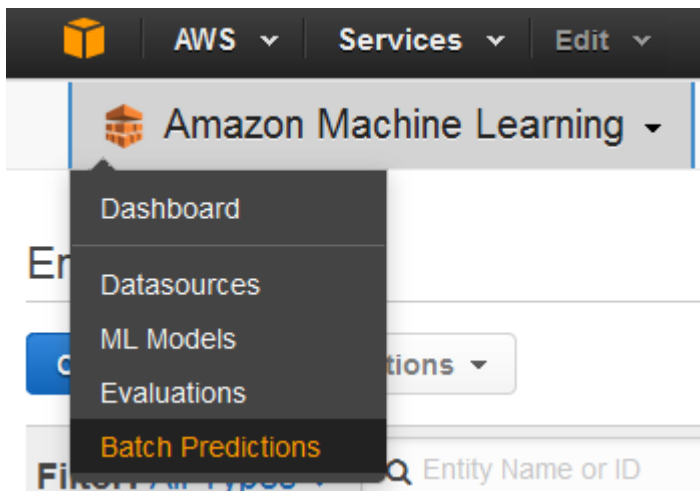


15. Pada halaman Ulasan, pilih Selesai.

Permintaan prediksi batch dikirim ke Amazon ML dan dimasukkan ke dalam antrian. Waktu yang dibutuhkan Amazon ML untuk memproses prediksi batch bergantung pada ukuran sumber data Anda dan kompleksitas model ML Anda. Sementara Amazon ML memproses permintaan, ia melaporkan status Sedang Berlangsung. Setelah prediksi batch selesai, status permintaan berubah menjadi Selesai. Sekarang, Anda dapat melihat hasilnya.

Untuk melihat prediksi


1. Pilih Amazon Machine Learning, lalu pilih Batch Predictions.



2. Dalam daftar prediksi, pilih Prediksi Batch: Model ML: Data Perbankan 1. Halaman info prediksi Batch muncul.

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. Untuk melihat hasil prediksi batch, buka konsol Amazon S3 dan arahkan ke lokasi Amazon S3 yang direferensikan <https://console.aws.amazon.com/s3/> di bidang URL Output S3. Dari sana, navigasikan ke folder hasil, yang akan memiliki nama yang mirip dengan `s3://aml-data/batch-prediction/result`.



Prediksi disimpan dalam file .gzip terkompresi dengan ekstensi.gz.

4. Unduh file prediksi ke desktop Anda, buka kompres, dan buka.

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

File ini memiliki dua kolom, BestAnswer dan skor, dan satu baris untuk setiap pengamatan di sumber data Anda. Hasil di kolom BestAnswer didasarkan pada ambang skor 0,77 yang Anda tetapkan. [Langkah 4: Tinjau Kinerja Prediktif Model ML dan Tetapkan Ambang Skor](#) Skor yang lebih besar dari 0,77 menghasilkan BestAnswer 1, yang merupakan respons atau prediksi positif, dan skor kurang dari 0,77 menghasilkan BestAnswer 0, yang merupakan respons atau prediksi negatif.

Contoh berikut menunjukkan prediksi positif dan negatif berdasarkan ambang skor 0.77.

Prediksi positif:

bestAnswer	score
1	0.8228876

Dalam contoh ini, nilai untuk BestAnswer adalah 1, dan nilai skor adalah 0.8228876. Nilai untuk BestAnswer adalah 1 karena skor lebih besar dari ambang skor 0,77. BestAnswer of 1 menunjukkan bahwa pelanggan cenderung membeli produk Anda, dan, oleh karena itu, dianggap sebagai prediksi positif.

Prediksi negatif:

bestAnswer	score
0	0.7695356

Dalam contoh ini, nilai BestAnswer adalah 0 karena nilai skornya adalah 0,7695356, yang kurang dari ambang skor 0,77. BestAnswer dari 0 menunjukkan bahwa pelanggan tidak mungkin membeli produk Anda, dan, oleh karena itu, dianggap sebagai prediksi negatif.

Setiap baris hasil batch sesuai dengan baris dalam input batch Anda (pengamatan di sumber data Anda).

Setelah menganalisis prediksi, Anda dapat menjalankan kampanye pemasaran yang ditargetkan; misalnya, dengan mengirim selebaran ke semua orang dengan skor prediksi. 1

Sekarang setelah Anda membuat, meninjau, dan menggunakan model Anda, [bersihkan data dan sumber daya AWS yang Anda buat](#) untuk menghindari biaya yang tidak perlu dan menjaga ruang kerja Anda tetap rapi.

Langkah 6: Bersihkan

Untuk menghindari biaya tambahan Amazon Simple Storage Service (Amazon S3), hapus data yang disimpan di Amazon S3. Anda tidak dikenakan biaya untuk sumber daya Amazon Amazon yang tidak digunakan lainnya, tetapi kami menyarankan Anda menghapusnya untuk menjaga ruang kerja Anda tetap bersih.

Untuk menghapus data input yang disimpan di Amazon S3

1. Buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Arahkan ke lokasi Amazon S3 tempat Anda menyimpan file `banking.csv` dan `banking-batch.csv` file.
3. Pilih `banking.csv`, `banking-batch.csv`, dan `.writePermissionCheck.tmp` file.
4. Pilih Tindakan, lalu pilih Hapus.
5. Saat diminta konfirmasi, pilih OK.

Meskipun Anda tidak dikenakan biaya untuk menyimpan catatan prediksi batch yang dijalankan Amazon ML atau sumber data, model, dan evaluasi yang Anda buat selama tutorial, sebaiknya Anda menghapusnya untuk mencegah kekacauan ruang kerja Anda.

Untuk menghapus prediksi batch

1. Arahkan ke lokasi Amazon S3 tempat Anda menyimpan output prediksi batch.
2. Pilih `batch-prediction` folder.
3. Pilih Tindakan, lalu pilih Hapus.
4. Saat diminta konfirmasi, pilih OK.

Untuk menghapus sumber daya Amazon Amazon

1. Di dasbor Amazon, pilih sumber daya berikut.
 - Sumber Banking Data 1 data
 - Sumber Banking Data 1_[percentBegin=0, percentEnd=70, strategy=sequential] data
 - Sumber Banking Data 1_[percentBegin=70, percentEnd=100, strategy=sequential] data
 - Sumber Banking Data 2 data
 - Model ML model: Banking Data 1 ML
 - Evaluation: ML model: Banking Data 1Evaluasi
2. Pilih Tindakan, lalu pilih Hapus.
3. Di kotak dialog, pilih Hapus untuk menghapus semua sumber daya yang dipilih.

Anda sekarang telah berhasil menyelesaikan tutorial. Untuk terus menggunakan konsol untuk membuat sumber data, model, dan prediksi, lihat Panduan Pengembang [Amazon Machine Learning](#). Untuk mempelajari cara menggunakan API, lihat [Referensi API Amazon Machine Learning](#).

Membuat dan Menggunakan Sumber Data

Anda dapat menggunakan sumber data Amazon ML untuk melatih model ML, mengevaluasi model ML, dan menghasilkan prediksi batch menggunakan model ML. Objek sumber data berisi metadata tentang data masukan Anda. Saat Anda membuat sumber data, Amazon ML akan membaca data input Anda, menghitung statistik deskriptif pada atributnya, dan menyimpan statistik, skema, dan informasi lainnya sebagai bagian dari objek sumber data. [Setelah membuat sumber data, Anda dapat menggunakan wawasan data Amazon Amazon untuk menjelajahi properti statistik data masukan Anda, dan Anda dapat menggunakan sumber data untuk melatih model ML.](#)

Note


Bagian ini mengasumsikan bahwa Anda sudah familiar dengan [konsep Amazon Machine Learning](#).

Topik

- [Memahami Format Data untuk Amazon](#)
- [Membuat Skema Data untuk Amazon ML](#)
- [Memisahkan Data Anda](#)
- [Wawasan Data](#)
- [Menggunakan Amazon S3 dengan Amazon ML](#)
- [Membuat Sumber Data Amazon ML dari Data di Amazon Redshift](#)
- [Menggunakan Data dari Database Amazon RDS untuk Membuat Sumber Data Amazon Amazon](#)

Memahami Format Data untuk Amazon

Input data adalah data yang Anda gunakan untuk membuat sumber data. Anda harus menyimpan data masukan Anda dalam format nilai yang dipisahkan koma (.csv). Setiap baris dalam file.csv adalah catatan data tunggal atau observasi. Setiap kolom dalam file.csv berisi atribut pengamatan. Misalnya, gambar berikut menunjukkan isi file.csv yang memiliki empat pengamatan, masing-masing dalam barisnya sendiri. Setiap pengamatan berisi delapan atribut, dipisahkan oleh koma. Atribut mewakili informasi berikut tentang setiap individu yang diwakili oleh pengamatan: CustomerID, jobBid, pendidikan, perumahan, pinjaman, kampanye, durasi, Kampanye. willRespondTo



Atribut

Amazon ML memerlukan nama untuk setiap atribut. Anda dapat menentukan nama atribut dengan:

- Menyertakan nama atribut di baris pertama (juga dikenal sebagai baris header) dari file.csv yang Anda gunakan sebagai data masukan
- Menyertakan nama atribut dalam file skema terpisah yang terletak di bucket S3 yang sama dengan data masukan Anda

Untuk informasi selengkapnya tentang menggunakan file skema, lihat [Membuat Skema Data](#).

Contoh berikut dari file.csv mencakup nama-nama atribut di baris header.

```
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
```

Persyaratan Format File Masukan

File.csv yang berisi data masukan Anda harus memenuhi persyaratan berikut:

- Harus dalam teks biasa menggunakan set karakter seperti ASCII, Unicode, atau EBCDIC.
- Terdiri dari pengamatan, satu observasi per baris.
- Untuk setiap pengamatan, nilai atribut harus dipisahkan dengan koma.

- Jika nilai atribut berisi koma (pembatas), seluruh nilai atribut harus diapit tanda kutip ganda.
- Setiap pengamatan harus diakhiri dengan end-of-line karakter, yang merupakan karakter khusus atau urutan karakter yang menunjukkan akhir garis.
- Nilai atribut tidak dapat menyertakan end-of-line karakter, bahkan jika nilai atribut diapit tanda kutip ganda.
- Setiap pengamatan harus memiliki jumlah atribut dan urutan atribut yang sama.
- Setiap observasi harus tidak lebih besar dari 100 KB. Amazon ML menolak pengamatan yang lebih besar dari 100 KB selama pemrosesan. Jika Amazon ML menolak lebih dari 10.000 pengamatan, ia menolak seluruh file.csv.

Menggunakan Beberapa File Sebagai Input Data ke Amazon

Anda dapat memberikan masukan ke Amazon ML sebagai satu file, atau sebagai kumpulan file.

Koleksi harus memenuhi persyaratan ini:

- Semua file harus memiliki skema data yang sama.
- Semua file harus berada di awalan Amazon Simple Storage Service (Amazon S3) yang sama, dan jalur yang Anda berikan untuk koleksi harus diakhiri dengan karakter garis miring ('/').

Misalnya, jika file data Anda diberi nama input1.csv, input2.csv, dan input3.csv, dan nama bucket S3 Anda adalah s3://examplebucket, jalur file Anda mungkin terlihat seperti ini:

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

```
s3://2.csv examplebucket/path/to/data/input
```

```
s3://3.csv examplebucket/path/to/data/input
```

Anda akan memberikan lokasi S3 berikut sebagai masukan ke Amazon ML:

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

End-of-Line Karakter dalam Format CSV


Saat Anda membuat file.csv Anda, setiap pengamatan akan dihentikan oleh karakter khusus. end-of-line Karakter ini tidak terlihat, tetapi secara otomatis disertakan di akhir setiap pengamatan ketika Anda menekan tombol Enter atau Return. Karakter khusus yang mewakili end-of-line bervariasi tergantung pada sistem operasi Anda. Sistem Unix, seperti Linux atau OS X, menggunakan karakter umpan baris yang ditunjukkan oleh "\n" (kode ASCII 10 dalam desimal atau 0x0a dalam

heksadesimal). Microsoft Windows menggunakan dua karakter yang disebut carriage return dan line feed yang ditunjukkan oleh "\r\n" (kode ASCII 13 dan 10 dalam desimal atau 0x0d dan 0x0a dalam heksadesimal).

Jika Anda ingin menggunakan OS X dan Microsoft Excel untuk membuat file.csv Anda, lakukan prosedur berikut. Pastikan untuk memilih format yang benar.

Untuk menyimpan file.csv jika Anda menggunakan OS X dan Excel

1. Saat menyimpan file.csv, pilih Format, lalu pilih Windows Comma Separated (.csv).
2. Pilih Simpan.



⚠ Important

Jangan simpan file.csv dengan menggunakan format Comma Separated Values (.csv) atau MS-DOS Comma Separated (.csv) karena Amazon ML tidak dapat membacanya.

Membuat Skema Data untuk Amazon ML

Skema terdiri dari semua atribut dalam data input dan tipe data yang sesuai. Hal ini memungkinkan Amazon ML untuk memahami data dalam sumber data. Amazon ML menggunakan informasi dalam skema untuk membaca dan menafsirkan data input, menghitung statistik, menerapkan transformasi atribut yang benar, dan menyempurnakan algoritme pembelajarannya. Jika Anda tidak memberikan skema, Amazon ML menyimpulkan satu dari data.

Contoh Skema

Agar Amazon ML dapat membaca data input dengan benar dan menghasilkan prediksi yang akurat, setiap atribut harus diberi tipe data yang benar. Mari kita telusuri contoh untuk melihat bagaimana tipe data ditetapkan ke atribut, dan bagaimana atribut dan tipe data disertakan dalam skema. Kami akan menyebut contoh kami "Kampanye Pelanggan" karena kami ingin memprediksi pelanggan mana yang akan menanggapi kampanye email kami. File input kami adalah file.csv dengan sembilan kolom:

```
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
```

Ini skema untuk data ini:

```
{
  "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"
}
]
```

Dalam file skema untuk contoh ini, nilai untuk `rowId` adalah `customerId`:

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

Atribut `willRespondToCampaign` didefinisikan sebagai atribut target:

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

`customerId` atribut dan tipe `CATEGORICAL` data dikaitkan dengan kolom pertama, `jobId` atribut dan tipe `CATEGORICAL` data dikaitkan dengan kolom kedua, `jobDescription` atribut dan tipe `TEXT` data dikaitkan dengan kolom ketiga, `education` atribut dan tipe `CATEGORICAL` data dikaitkan dengan kolom keempat, dan seterusnya. Kolom kesembilan dikaitkan dengan `willRespondToCampaign` atribut dengan tipe `BINARY` data, dan atribut ini juga didefinisikan sebagai atribut target.

Menggunakan targetAttributeName Field

`targetAttributeName` adalah nama atribut yang ingin Anda prediksi. Anda harus menetapkan `targetAttributeName` saat membuat atau mengevaluasi model.

Saat Anda melatih atau mengevaluasi model ML, `targetAttributeName` mengidentifikasi nama atribut dalam data input yang berisi jawaban “benar” untuk atribut target. Amazon ML menggunakan target, yang mencakup jawaban yang benar, untuk menemukan pola dan menghasilkan model ML.

Saat Anda mengevaluasi model Anda, Amazon ML menggunakan target untuk memeriksa keakuratan prediksi Anda. Setelah membuat dan mengevaluasi model ML, Anda dapat menggunakan data dengan unassigned `targetAttributeName` untuk menghasilkan prediksi dengan model ML Anda.

Anda menentukan atribut target di konsol Amazon ML saat membuat sumber data, atau dalam file skema. Jika Anda membuat file skema Anda sendiri, gunakan sintaks berikut untuk menentukan atribut target:

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

Dalam contoh ini, `exampleAttributeTarget` adalah nama atribut dalam file input Anda yang merupakan atribut target.

Menggunakan Bidang RowID

`row ID` ini adalah bendera opsional yang terkait dengan atribut dalam data input. Jika ditentukan, atribut ditandai sebagai disertakan dalam output prediksi. `row ID` Atribut ini memudahkan untuk mengaitkan prediksi mana yang sesuai dengan pengamatan mana. Contoh barang `row ID` adalah ID pelanggan atau atribut unik serupa.

Note

ID baris hanya untuk referensi Anda. Amazon ML tidak menggunakannya saat melatih model ML. Memilih atribut sebagai ID baris mengecualikannya dari yang digunakan untuk melatih model ML.

Anda menentukan `row ID` di konsol Amazon ML saat membuat sumber data, atau dalam file skema. Jika Anda membuat file skema Anda sendiri, gunakan sintaks berikut untuk menentukan: `row ID`

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

Dalam contoh sebelumnya, `exampleRow` adalah nama atribut dalam file input Anda yang didefinisikan sebagai ID baris.

Saat membuat prediksi batch, Anda mungkin mendapatkan output berikut:

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

Dalam contoh ini, `RowID` mewakili atribut `customerID`. Misalnya, `55 CustomerID` diprediksi akan menanggapi kampanye email kami dengan kepercayaan diri rendah (0.46317), `customerID 102` sementara diprediksi akan menanggapi kampanye email kami dengan keyakinan tinggi (0.89625).

Menggunakan AttributeType Field

Di Amazon ML, ada empat tipe data untuk atribut:

Biner

Pilih atribut `BINARY` yang hanya memiliki dua kemungkinan status, seperti `yes` atau `no`.

Misalnya, atribut `isNew`, untuk melacak apakah seseorang adalah pelanggan baru, akan memiliki `true` nilai untuk menunjukkan bahwa individu tersebut adalah pelanggan baru, dan `false` nilai untuk menunjukkan bahwa dia bukan pelanggan baru.

Nilai negatif yang valid adalah `0`, `n`, `no`, `f`, dan `false`.

Nilai positif yang valid adalah `1`, `y`, `yes`, `t`, dan `true`.

Amazon ML mengabaikan kasus input biner dan menghapus ruang putih di sekitarnya. Misalnya, " FaLSe " adalah nilai biner yang valid. Anda dapat mencampur nilai biner yang Anda gunakan dalam sumber data yang sama, seperti menggunakan `true`, `no` dan `1`. Amazon ML hanya mengeluarkan `0` dan `1` untuk atribut biner.

Kategoris

Pilih `CATEGORICAL` atribut yang mengambil sejumlah nilai string unik. Misalnya, ID pengguna, bulan, dan kode pos adalah nilai kategoris. Atribut kategoris diperlakukan sebagai string tunggal, dan tidak diberi token lebih lanjut.

Numerik

Pilih NUMERIC atribut yang mengambil kuantitas sebagai nilai.

Misalnya, suhu, berat, dan kecepatan klik adalah nilai numerik.

Tidak semua atribut yang menyimpan angka bersifat numerik. Atribut kategoris, seperti hari dalam sebulan dan IDs, sering direpresentasikan sebagai angka. Untuk dianggap numerik, angka harus sebanding dengan angka lain. Misalnya, ID pelanggan tidak 664727 memberi tahu Anda apa pun tentang ID pelanggan124552, tetapi bobot 10 memberi tahu Anda bahwa atribut itu lebih berat daripada atribut dengan bobot. 5 Hari dalam sebulan tidak numerik, karena yang pertama dari satu bulan dapat terjadi sebelum atau sesudah bulan kedua bulan berikutnya.

Note

Saat Anda menggunakan Amazon ML untuk membuat skema Anda, ia menetapkan tipe Numeric data ke semua atribut yang menggunakan angka. Jika Amazon ML membuat skema Anda, periksa penetapan yang salah dan setel atribut tersebut. CATEGORICAL

Teks

Pilih TEXT atribut yang merupakan string kata. Saat membaca dalam atribut teks, Amazon ML mengubahnya menjadi token, dibatasi oleh spasi putih.

Misalnya, `email subject` menjadi `email dansubject`, dan `email-subject here` menjadi `email-subject danhere`.

Jika tipe data untuk variabel dalam skema pelatihan tidak cocok dengan tipe data untuk variabel tersebut dalam skema evaluasi, Amazon ML mengubah tipe data evaluasi agar sesuai dengan tipe data pelatihan. Misalnya, jika skema data pelatihan menetapkan tipe data TEXT ke variabel `age`, tetapi skema evaluasi menetapkan tipe data ke NUMERIC, maka Amazon ML memperlakukan usia dalam data evaluasi sebagai TEXT variabel, bukan. NUMERIC

Untuk informasi tentang statistik yang terkait dengan setiap tipe data, lihat [Statistik Deskriptif](#).

Menyediakan Skema ke Amazon ML

Setiap sumber data membutuhkan skema. Anda dapat memilih dari dua cara untuk menyediakan Amazon ML dengan skema:

- Izinkan Amazon ML menyimpulkan tipe data dari setiap atribut dalam file data input dan secara otomatis membuat skema untuk Anda.
- Berikan file skema saat Anda mengunggah data Amazon Simple Storage Service (Amazon S3).

Mengizinkan Amazon ML Membuat Skema Anda

Saat Anda menggunakan konsol Amazon ML untuk membuat sumber data, Amazon ML menggunakan aturan sederhana, berdasarkan nilai variabel Anda, untuk membuat skema Anda. Kami sangat menyarankan agar Anda meninjau skema Amazon ML-dibuat, dan memperbaiki tipe data jika tidak akurat.

Menyediakan Skema

Setelah Anda membuat file skema Anda, Anda harus membuatnya tersedia untuk Amazon ML. Anda memiliki dua pilihan:

1. Berikan skema dengan menggunakan konsol Amazon ML.

Gunakan konsol untuk membuat sumber data Anda, dan sertakan file skema dengan menambahkan ekstensi.schema ke nama file data input Anda. Misalnya, jika URI Amazon Simple Storage Service (Amazon S3) ke data input Anda adalah `s3:///csv.schema.my-bucket-name/data/input.csv`, the URI to your schema will be `s3://my-bucket-name/data/input` Amazon ML secara otomatis menemukan file skema yang Anda berikan alih-alih mencoba menyimpulkan skema dari data Anda.

Untuk menggunakan direktori file sebagai input data Anda ke Amazon ML, tambahkan ekstensi.schema ke jalur direktori Anda. Misalnya, jika file data Anda berada di lokasi `s3:///schema.examplebucket/path/to/data/`, the URI to your schema will be `s3://examplebucket/path/to/data`

2. Menyediakan skema dengan menggunakan Amazon ML API.

Jika Anda berencana untuk memanggil Amazon ML API untuk membuat sumber data Anda, Anda dapat mengunggah file skema ke Amazon S3, dan kemudian memberikan URI ke file tersebut dalam atribut API. `DataSchemaLocationS3>CreateDataSourceFromS3` Untuk informasi lebih lanjut, lihat [CreateDataSourceFromS3](#).

Anda dapat memberikan skema langsung di `CreateDataSource` payload* APIs alih-alih menyimpannya terlebih dahulu ke Amazon S3. Anda melakukan ini dengan menempatkan string skema penuh dalam `DataSchema`

`atributCreateDataSourceFromS3,CreateDataSourceFromRDS`, atau `CreateDataSourceFromRedshift` APIs. Untuk informasi selengkapnya, lihat [Referensi API Amazon Machine Learning](#).

Memisahkan Data Anda

Tujuan mendasar dari model ML adalah untuk membuat prediksi yang akurat tentang instance data future di luar yang digunakan untuk melatih model. Sebelum menggunakan model ML untuk membuat prediksi, kita perlu mengevaluasi kinerja prediktif model. Untuk memperkirakan kualitas prediksi model ML dengan data yang belum dilihatnya, kami dapat memesan, atau membagi, sebagian data yang sudah kami ketahui jawabannya sebagai proxy untuk data future dan mengevaluasi seberapa baik model ML memprediksi jawaban yang benar untuk data tersebut. Anda membagi sumber data menjadi beberapa bagian untuk sumber data pelatihan dan sebagian untuk sumber data evaluasi.

Amazon ML menyediakan tiga opsi untuk membagi data Anda:

- Pra-membagi data - Anda dapat membagi data menjadi dua lokasi input data, sebelum mengunggahnya ke Amazon Simple Storage Service (Amazon S3) dan membuat dua sumber data terpisah dengannya.
- Amazon ML sequential split - Anda dapat memberi tahu Amazon ML untuk membagi data Anda secara berurutan saat membuat sumber data pelatihan dan evaluasi.
- Amazon ML random split - Anda dapat memberi tahu Amazon ML untuk membagi data Anda menggunakan metode acak unggulan saat membuat sumber data pelatihan dan evaluasi.

Pra-pemisahan Data Anda

Jika Anda ingin kontrol eksplisit atas data dalam sumber data pelatihan dan evaluasi, pisahkan data Anda menjadi lokasi data terpisah, dan buat sumber data terpisah untuk lokasi input dan evaluasi.

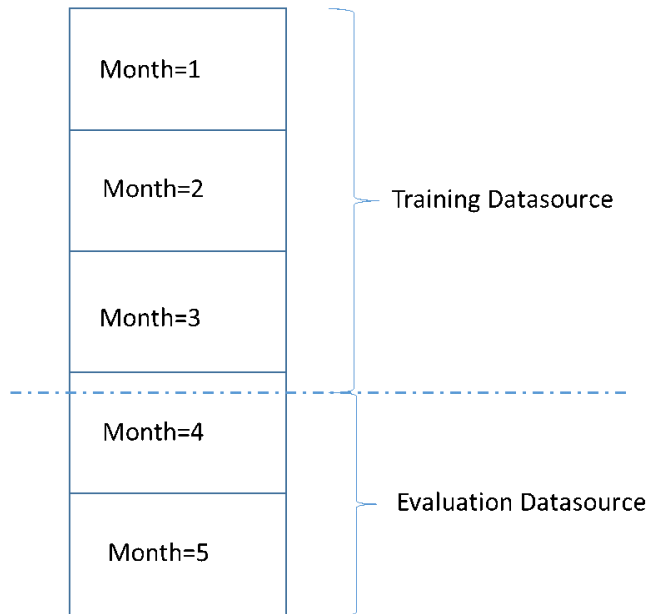
Memisahkan Data Anda Secara Berurutan

Cara sederhana untuk membagi data input Anda untuk pelatihan dan evaluasi adalah dengan memilih subset data yang tidak tumpang tindih sambil mempertahankan urutan catatan data. Pendekatan ini berguna jika Anda ingin mengevaluasi model ML Anda pada data untuk tanggal tertentu atau dalam rentang waktu tertentu. Misalnya, Anda memiliki data keterlibatan pelanggan selama lima bulan terakhir, dan Anda ingin menggunakan data historis ini untuk memprediksi

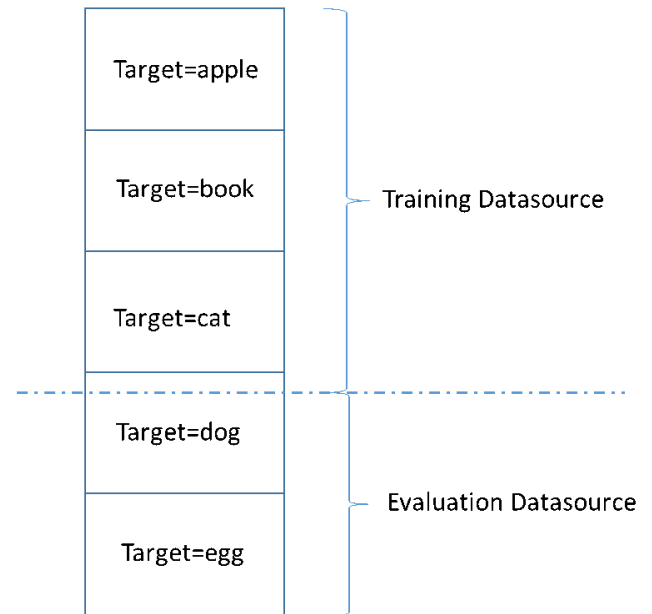
keterlibatan pelanggan di bulan berikutnya. Menggunakan awal rentang untuk pelatihan, dan data dari akhir rentang untuk evaluasi dapat menghasilkan perkiraan kualitas model yang lebih akurat daripada menggunakan data catatan yang diambil dari seluruh rentang data.

Gambar berikut menunjukkan contoh kapan Anda harus menggunakan strategi pemisahan berurutan versus kapan Anda harus menggunakan strategi acak.

Case 1: Sequential split is the **correct** strategy



Case 2: Sequential split is the **wrong** strategy



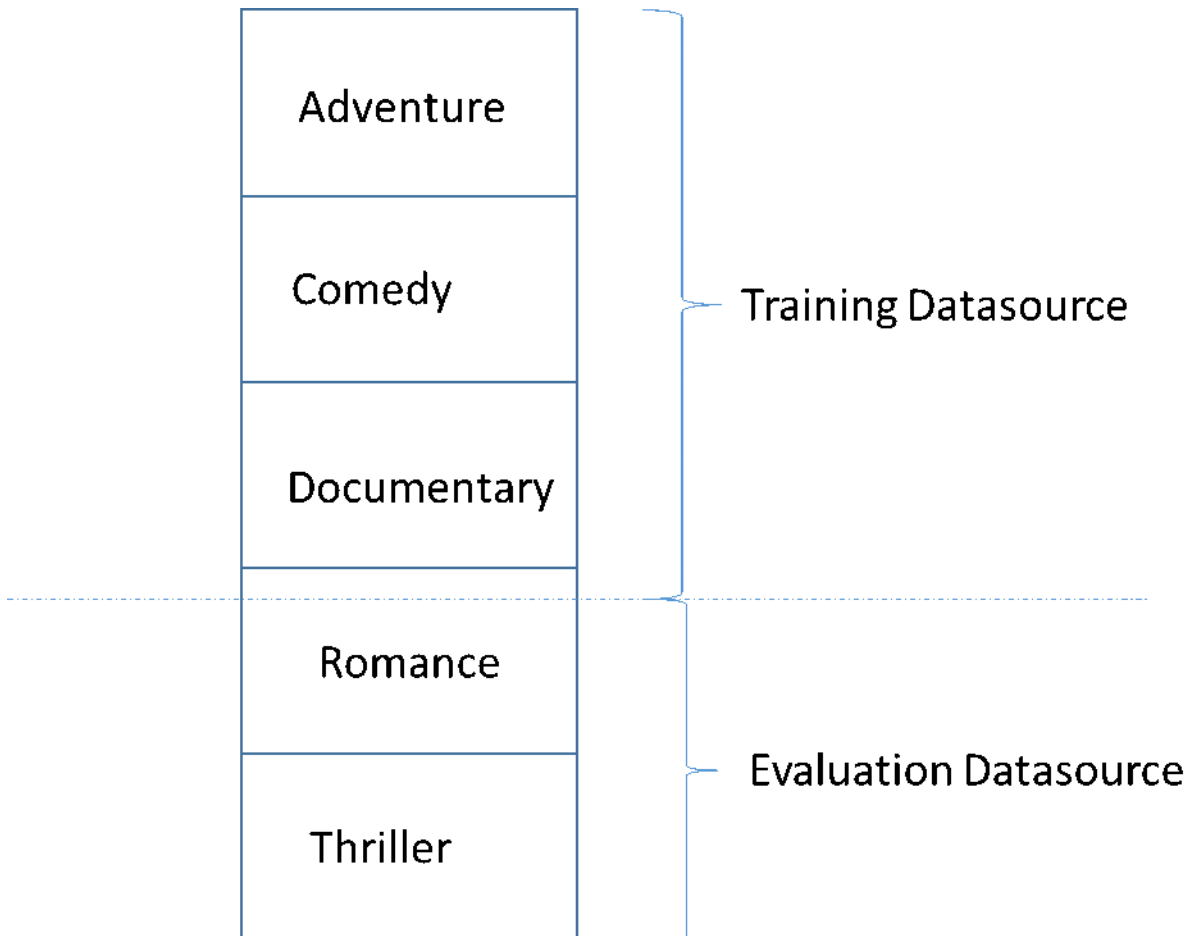
Saat membuat sumber data, Anda dapat memilih untuk membagi sumber data Anda secara berurutan, dan Amazon ML menggunakan 70 persen pertama data Anda untuk pelatihan dan 30 persen data lainnya untuk evaluasi. Ini adalah pendekatan default saat Anda menggunakan konsol Amazon Amazon untuk membagi data Anda.

Memisahkan Data Anda Secara Acak

Memisahkan data input secara acak ke dalam sumber data pelatihan dan evaluasi memastikan bahwa distribusi data serupa dalam sumber data pelatihan dan evaluasi. Pilih opsi ini ketika Anda tidak perlu mempertahankan urutan data input Anda.

Amazon ML menggunakan metode pembuatan nomor pseudo-acak unggulan untuk membagi data Anda. Benih sebagian didasarkan pada nilai string input dan sebagian pada konten data itu sendiri. Secara default, konsol Amazon Amazon menggunakan lokasi S3 dari data input sebagai string. Pengguna API dapat menyediakan string khusus. Ini berarti bahwa dengan bucket dan data S3 yang sama, Amazon ML membagi data dengan cara yang sama setiap saat. Untuk mengubah cara Amazon ML memisahkan data, Anda dapat

menggunakan `CreateDataSourceFromS3`, `CreateDataSourceFromRedshift`, atau `CreateDataSourceFromRDS` API dan memberikan nilai untuk string benih. Saat menggunakan ini APIs untuk membuat sumber data terpisah untuk pelatihan dan evaluasi, penting untuk menggunakan nilai string benih yang sama untuk sumber data dan tanda pelengkap untuk satu sumber data, untuk memastikan bahwa tidak ada tumpang tindih antara data pelatihan dan evaluasi.



Perangkap umum dalam mengembangkan model ML berkualitas tinggi adalah mengevaluasi model ML pada data yang tidak mirip dengan data yang digunakan untuk pelatihan. Misalnya, Anda menggunakan ML untuk memprediksi genre film, dan data pelatihan Anda berisi film dari genre Petualangan, Komedi, dan Dokumenter. Namun, data evaluasi Anda hanya berisi data dari genre Romance dan Thriller. Dalam hal ini, model ML tidak mempelajari informasi apa pun tentang genre Romance dan Thriller, dan evaluasi tidak mengevaluasi seberapa baik model tersebut mempelajari pola untuk genre Petualangan, Komedi, dan Dokumenter. Akibatnya, informasi genre tidak berguna, dan kualitas prediksi model ML untuk semua genre terganggu. Model dan evaluasi terlalu berbeda (memiliki statistik deskriptif yang sangat berbeda) untuk berguna. Ini dapat terjadi ketika data input diurutkan berdasarkan salah satu kolom dalam kumpulan data, dan kemudian dibagi secara berurutan.

Jika sumber data pelatihan dan evaluasi Anda memiliki distribusi data yang berbeda, Anda akan melihat peringatan evaluasi dalam evaluasi model Anda. Untuk informasi selengkapnya tentang peringatan evaluasi, lihat [Peringatan Evaluasi](#).

Anda tidak perlu menggunakan pemisahan acak di Amazon ML jika Anda telah mengacak data input Anda, misalnya, dengan mengacak data input Anda secara acak di Amazon S3, atau dengan menggunakan fungsi kueri Amazon Redshift SQL atau `random()` fungsi kueri MySQL SQL saat membuat sumber data. `rand()` Dalam kasus ini, Anda dapat mengandalkan opsi pemisahan sekuensial untuk membuat sumber data pelatihan dan evaluasi dengan distribusi serupa.

Wawasan Data

Amazon ML menghitung statistik deskriptif pada data masukan yang dapat Anda gunakan untuk memahami data Anda.

Statistik Deskriptif

Amazon ML menghitung statistik deskriptif berikut untuk jenis atribut yang berbeda:

Numerik:

- Histogram distribusi
- Jumlah nilai yang tidak valid
- Nilai minimum, median, rata-rata, dan maksimum

Biner dan kategoris:

- Hitung (dari nilai berbeda per kategori)
- Histogram distribusi nilai
- Nilai yang paling sering
- Nilai unik diperhitungkan
- Persentase nilai sebenarnya (hanya biner)
- Kata-kata yang paling menonjol
- Kata-kata yang paling sering

Teks:

- Nama atribut

- Korelasi dengan target (jika target ditetapkan)
- Total kata
- Kata-kata unik
- Rentang jumlah kata dalam satu baris
- Rentang panjang kata
- Kata-kata yang paling menonjol

Mengakses Data Insights di konsol Amazon

Di konsol Amazon Amazon, Anda dapat memilih nama atau ID sumber data apa pun untuk melihat halaman Data Insights. Halaman ini menyediakan metrik dan visualisasi yang memungkinkan Anda mempelajari data masukan yang terkait dengan sumber data, termasuk informasi berikut:

- Ringkasan data
- Distribusi target
- Nilai yang hilang
- Nilai tidak valid
- Ringkasan statistik variabel menurut tipe data
- Distribusi variabel menurut tipe data


Bagian berikut menjelaskan metrik dan visualisasi secara lebih rinci.

Ringkasan Data

Laporan ringkasan data dari sumber data menampilkan informasi ringkasan, termasuk ID sumber data, nama, tempat selesai, status saat ini, atribut target, informasi data masukan (lokasi bucket S3, format data, jumlah catatan yang diproses, dan jumlah catatan buruk yang ditemui selama pemrosesan) serta jumlah variabel menurut tipe data.

Distribusi Target

Laporan distribusi target menunjukkan distribusi atribut target dari sumber data. Dalam contoh berikut, ada 39.922 pengamatan di mana atribut target `willRespondTo` Kampanye sama dengan 0. Ini adalah jumlah pelanggan yang tidak menanggapi kampanye email. Ada 5.289 pengamatan di mana `willRespondTo` Kampanye sama dengan 1. Ini adalah jumlah pelanggan yang menanggapi kampanye email.



Nilai Hilang

Laporan nilai yang hilang mencantumkan atribut dalam data input yang nilainya hilang. Hanya atribut dengan tipe data numerik yang dapat memiliki nilai yang hilang. Karena nilai yang hilang dapat memengaruhi kualitas pelatihan model ML, kami merekomendasikan agar nilai yang hilang diberikan, jika memungkinkan.

Selama pelatihan model ML, jika atribut target hilang, Amazon ML akan menolak record yang sesuai. Jika atribut target ada dalam catatan, tetapi nilai untuk atribut numerik lain tidak ada, maka Amazon ML akan mengabaikan nilai yang hilang. Dalam kasus ini, Amazon ML membuat atribut pengganti dan menyetelnya ke 1 untuk menunjukkan bahwa atribut ini hilang. Hal ini memungkinkan Amazon ML untuk mempelajari pola dari terjadinya nilai yang hilang.

Nilai Tidak Valid

Nilai tidak valid hanya dapat terjadi dengan tipe data Numerik dan Biner. Anda dapat menemukan nilai yang tidak valid dengan melihat statistik ringkasan variabel dalam laporan tipe data. Dalam contoh berikut, ada satu nilai yang tidak valid dalam durasi atribut Numerik dan dua nilai tidak valid dalam tipe data biner (satu di atribut housing dan satu di atribut pinjaman).

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%)	

Korelasi Variabel-Target

Setelah Anda membuat sumber data, Amazon ML dapat mengevaluasi sumber data dan mengidentifikasi korelasi, atau dampak, antara variabel dan target. Misalnya, harga suatu produk mungkin memiliki dampak yang signifikan pada apakah itu adalah best seller atau tidak, sedangkan dimensi produk mungkin memiliki daya prediksi yang kecil.

Ini umumnya merupakan praktik terbaik untuk memasukkan sebanyak mungkin variabel dalam data pelatihan Anda. Namun, noise yang diperkenalkan dengan memasukkan banyak variabel dengan daya prediksi kecil dapat berdampak negatif pada kualitas dan akurasi model ML Anda.

Anda mungkin dapat meningkatkan kinerja prediktif model Anda dengan menghapus variabel yang memiliki dampak kecil saat Anda melatih model Anda. Anda dapat menentukan variabel mana yang tersedia untuk proses pembelajaran mesin dalam resep, yang merupakan mekanisme transformasi Amazon ML. Untuk mempelajari lebih lanjut tentang resep, lihat [Transformasi Data untuk Machine Learning](#).

Ringkasan Statistik Atribut menurut Tipe Data

Dalam laporan wawasan data, Anda dapat melihat statistik ringkasan atribut berdasarkan tipe data berikut:

- Biner
- Kategoris
- Numerik
- Teks

Statistik ringkasan untuk tipe data Biner menunjukkan semua atribut biner. Kolom Korelasi ke target menunjukkan informasi yang dibagikan antara kolom target dan kolom atribut. Kolom Persen benar menunjukkan persentase pengamatan yang memiliki nilai 1. Kolom Nilai tidak valid menunjukkan jumlah nilai yang tidak valid serta persentase nilai yang tidak valid untuk setiap atribut. Kolom Preview menyediakan link ke distribusi grafis untuk setiap atribut.

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%)	

Statistik ringkasan untuk tipe data Categorical menunjukkan semua atribut Kategoris dengan jumlah nilai unik, nilai paling sering, dan nilai yang paling sering. Kolom Preview menyediakan link ke distribusi grafis untuk setiap atribut.

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		

Statistik ringkasan untuk tipe data numerik menunjukkan semua atribut Numerik dengan jumlah nilai yang hilang, nilai tidak valid, rentang nilai, rata-rata, dan median. Kolom Preview menyediakan link ke distribusi grafis untuk setiap atribut.

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	

Statistik ringkasan untuk tipe data Teks menunjukkan semua atribut Teks, jumlah total kata dalam atribut itu, jumlah kata unik dalam atribut itu, rentang kata dalam atribut, rentang panjang kata, dan kata-kata yang paling menonjol. Kolom Preview menyediakan link ke distribusi grafis untuk setiap atribut.

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.

Contoh berikutnya menunjukkan statistik tipe data Teks untuk variabel teks yang disebut review, dengan empat catatan.

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

Kolom untuk contoh ini akan menampilkan informasi berikut.

- Kolom Atribut menunjukkan nama variabel. Dalam contoh ini, kolom ini akan mengatakan “review.”
- Kolom Korelasi ke target hanya ada jika target ditentukan. Korelasi mengukur jumlah informasi yang diberikan atribut ini tentang target. Semakin tinggi korelasinya, semakin banyak atribut ini memberi tahu Anda tentang target. Korelasi diukur dalam hal informasi timbal balik antara representasi sederhana dari atribut teks dan target.
- Kolom Total kata menunjukkan jumlah kata yang dihasilkan dari tokenisasi setiap catatan, membatasi kata-kata dengan spasi putih. Dalam contoh ini, kolom ini akan mengatakan “12”.
- Kolom Kata unik menunjukkan jumlah kata unik untuk atribut. Dalam contoh ini, kolom ini akan mengatakan “10.”
- Kolom Words in attribute (range) menunjukkan jumlah kata dalam satu baris dalam atribut. Dalam contoh ini, kolom ini akan mengatakan “0-6.”
- Kolom panjang kata (rentang) menunjukkan kisaran berapa banyak karakter dalam kata-kata. Dalam contoh ini, kolom ini akan mengatakan “2-11.”
- Kolom Kata yang paling menonjol menunjukkan daftar peringkat kata yang muncul di atribut. Jika ada atribut target, kata-kata diberi peringkat berdasarkan korelasinya dengan target, artinya kata-kata yang memiliki korelasi tertinggi dicantumkan terlebih dahulu. Jika tidak ada target yang ada dalam data, maka kata-kata tersebut diberi peringkat berdasarkan entropi mereka.

Memahami Distribusi Atribut Kategoris dan Biner


Dengan mengklik tautan Pratinjau yang terkait dengan atribut kategoris atau biner, Anda dapat melihat distribusi atribut tersebut serta data sampel dari file masukan untuk setiap nilai kategoris atribut.

Misalnya, tangkapan layar berikut menunjukkan distribusi untuk atribut kategoris JoBid. Distribusi menampilkan 10 nilai kategoris teratas, dengan semua nilai lainnya dikelompokkan sebagai “lainnya”.

Ini memberi peringkat masing-masing dari 10 nilai kategoris teratas dengan jumlah pengamatan dalam file input yang berisi nilai itu, serta tautan untuk melihat pengamatan sampel dari file data input.

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

Memahami Distribusi Atribut Numerik

Untuk melihat distribusi atribut numerik, klik tautan Pratinjau atribut. Saat melihat distribusi atribut numerik, Anda dapat memilih ukuran bin 500, 200, 100, 50, atau 20. Semakin besar ukuran bin, semakin kecil jumlah grafik batang yang akan ditampilkan. Selain itu, resolusi distribusi akan kasar untuk ukuran tempat sampah besar. Sebaliknya, pengaturan ukuran bucket ke 20 meningkatkan resolusi distribusi yang ditampilkan.

Nilai minimum, rata-rata, dan maksimum juga ditampilkan, seperti yang ditunjukkan pada gambar berikut.

Numeric Variables: duration



Memahami Distribusi Atribut Teks

Untuk melihat distribusi atribut teks, klik tautan Pratinjau atribut. Saat melihat distribusi atribut teks, Anda akan melihat informasi berikut.

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 > »

Peringkat

Token teks diberi peringkat berdasarkan jumlah informasi yang mereka sampaikan, paling informatif hingga paling tidak informatif.

Token

Token menunjukkan kata dari teks masukan yang berisi deretan statistik.

Keunggulan kata

Jika ada atribut target, kata-kata diberi peringkat berdasarkan korelasinya dengan target, sehingga kata-kata yang memiliki korelasi tertinggi dicantumkan terlebih dahulu. Jika tidak ada target yang ada dalam data, maka kata-kata tersebut diberi peringkat berdasarkan entropi mereka, yaitu jumlah informasi yang dapat mereka komunikasikan.

Hitung nomor

Nomor hitungan menunjukkan jumlah catatan masukan tempat token muncul.

Hitung persentase

Persentase hitungan menunjukkan persentase baris data input tempat token muncul.

Menggunakan Amazon S3 dengan Amazon ML

Amazon Simple Storage Service (Amazon S3) adalah penyimpanan untuk Internet. Anda dapat menggunakan Amazon S3 untuk menyimpan dan mengambil data sebanyak apa pun kapan pun, dari mana pun di web. Amazon ML menggunakan Amazon S3 sebagai repositori data utama untuk tugas-tugas berikut:

- Untuk mengakses file input Anda untuk membuat objek sumber data untuk pelatihan dan mengevaluasi model ML Anda.
- Untuk mengakses file input Anda untuk menghasilkan prediksi batch.
- Saat Anda membuat prediksi batch menggunakan model ML Anda, untuk menampilkan file prediksi ke bucket S3 yang Anda tentukan.
- Untuk menyalin data yang telah disimpan di Amazon Redshift atau Amazon Relational Database Service (Amazon RDS) ke dalam file.csv dan mengunggahnya ke Amazon S3.

Untuk mengaktifkan Amazon ML untuk melakukan tugas-tugas ini, Anda harus memberikan izin ke Amazon ML untuk mengakses data Amazon S3 Anda.

Note

Anda tidak dapat menampilkan file prediksi batch ke bucket S3 yang hanya menerima file terenkripsi sisi server. Pastikan kebijakan bucket Anda mengizinkan pengunggahan file yang tidak dienkripsi dengan mengonfirmasi bahwa kebijakan tersebut tidak menyertakan Deny efek untuk `s3:PutObject` tindakan jika tidak ada `s3:x-amz-server-side-encryption` header dalam permintaan. Untuk informasi selengkapnya tentang kebijakan bucket enkripsi sisi server S3, lihat [Melindungi Data Menggunakan Enkripsi Sisi Server di Panduan Pengguna Layanan Penyimpanan Sederhana Amazon](#).

Mengunggah Data Anda ke Amazon S3

Anda harus mengunggah data input ke Amazon Simple Storage Service (Amazon S3) Simple Storage Service (Amazon S3) karena Amazon ML membaca data dari lokasi Amazon S3. Anda dapat mengunggah data langsung ke Amazon S3 (misalnya, dari komputer Anda), atau Amazon ML dapat menyalin data yang telah Anda simpan di Amazon Redshift atau Amazon Relational Database Service (RDS) ke dalam file.csv dan mengunggahnya ke Amazon S3.

Untuk informasi selengkapnya tentang menyalin data Anda dari Amazon Redshift atau Amazon RDS, lihat [Menggunakan Amazon Redshift dengan Amazon ML atau Menggunakan Amazon RDS dengan Amazon ML](#), masing-masing.

Sisa bagian ini menjelaskan cara mengunggah data input Anda langsung dari komputer Anda ke Amazon S3. Sebelum Anda memulai prosedur di bagian ini, Anda harus memiliki data Anda dalam file.csv. Untuk informasi tentang cara memformat file.csv dengan benar sehingga Amazon ML dapat menggunakannya, lihat [Memahami Format Data untuk Amazon ML](#).

Untuk mengunggah data Anda dari komputer Anda ke Amazon S3

1. [Masuk ke AWS Management Console dan buka konsol Amazon S3 di https://console.aws.amazon.com/s3](https://console.aws.amazon.com/s3).
2. Buat bucket atau pilih bucket yang ada.
 - a. Untuk membuat bucket, pilih Create Bucket. Beri nama bucket Anda, pilih wilayah (Anda dapat memilih wilayah yang tersedia), lalu pilih Buat. Untuk informasi selengkapnya, lihat [Membuat Bucket](#) di Panduan Memulai Penyimpanan Sederhana Amazon.
 - b. Untuk menggunakan bucket yang sudah ada, cari bucket dengan memilih bucket di daftar Semua Bucket. Saat nama bucket muncul, pilih, lalu pilih Unggah.
3. Di kotak dialog Unggah, pilih Tambahkan File.
4. Arahkan ke folder yang berisi data masukan Anda. File csv, lalu pilih Buka.

Izin

Untuk memberikan izin bagi Amazon ML untuk mengakses salah satu bucket S3, Anda harus mengedit kebijakan bucket.

Untuk informasi tentang pemberian izin Amazon untuk membaca data dari bucket Anda di Amazon S3, lihat [Memberikan Izin Amazon ML untuk Membaca Data Anda dari Amazon S3](#).

Untuk informasi tentang pemberian izin Amazon untuk menampilkan hasil prediksi batch ke bucket Anda di Amazon S3, lihat [Memberikan Izin Amazon ML untuk Prediksi Output ke Amazon S3](#).

Untuk informasi tentang mengelola izin akses ke sumber daya Amazon S3, lihat Panduan Pengembang [Amazon S3](#).

Membuat Sumber Data Amazon ML dari Data di Amazon Redshift

Jika menyimpan data di Amazon Redshift, Anda dapat menggunakan wizard Create Datasource di konsol Amazon Machine Learning (Amazon ML) untuk membuat objek sumber data. Saat membuat sumber data dari data Amazon Redshift, Anda menentukan kluster yang berisi data dan kueri SQL untuk mengambil data Anda. Amazon ML mengeksekusi kueri dengan menjalankan perintah Amazon Unload Redshift di cluster. Amazon ML menyimpan hasilnya di lokasi Amazon Simple Storage Service (Amazon S3) pilihan Anda, lalu menggunakan data yang disimpan di Amazon S3 untuk membuat sumber data. Sumber data, cluster Amazon Redshift, dan bucket S3 semuanya harus berada di wilayah yang sama.

Note

Amazon ML tidak mendukung pembuatan sumber data dari kluster Amazon Redshift secara pribadi. VPCs Cluster harus memiliki alamat IP publik.

Topik

- [Parameter yang Diperlukan untuk Create Datasource Wizard](#)
- [Membuat Sumber Data dengan Amazon Redshift Data \(Konsol\)](#)
- [Memecahkan Masalah Amazon Redshift](#)

Parameter yang Diperlukan untuk Create Datasource Wizard

Agar Amazon ML dapat terhubung ke database Amazon Redshift dan membaca data atas nama Anda, Anda harus memberikan yang berikut:

- Pergeseran Merah Amazon `ClusterIdentifier`
- Nama basis data Amazon Redshift
- Kredensi basis data Amazon Redshift (nama pengguna dan kata sandi)

- Peran Amazon Amazon Redshift AWS Identity and Access Management (IAM) Amazon ML
- Kueri SQL Amazon Redshift
- (Opsional) Lokasi skema Amazon Amazon
- Lokasi pementasan Amazon S3 (tempat Amazon ML menempatkan data sebelum membuat sumber data)

Selain itu, Anda perlu memastikan bahwa pengguna IAM atau peran yang membuat sumber data Amazon Redshift (baik melalui konsol atau dengan menggunakan `CreateDataSourceFromRedshift` tindakan) memiliki izin. `iam:PassRole`

Pergeseran Merah Amazon **ClusterIdentifier**

Gunakan parameter peka huruf besar/kecil ini untuk mengaktifkan Amazon ML menemukan dan terhubung ke klaster Anda. Anda dapat memperoleh pengenalan cluster (nama) dari konsol Amazon Redshift. Untuk informasi selengkapnya tentang cluster, lihat [Amazon Redshift Clusters](#).

Nama Basis Data Amazon Redshift

Gunakan parameter ini untuk memberi tahu Amazon ML database mana di klaster Amazon Redshift yang berisi data yang ingin Anda gunakan sebagai sumber data Anda.

Kredensial Basis Data Amazon Redshift

Gunakan parameter ini untuk menentukan nama pengguna dan kata sandi pengguna database Amazon Redshift yang konteksnya kueri keamanan akan dijalankan.

Note

Amazon ML memerlukan nama pengguna dan kata sandi Amazon Redshift untuk terhubung ke database Amazon Redshift Anda. Setelah membongkar data ke Amazon S3, Amazon ML tidak pernah menggunakan kembali kata sandi Anda, juga tidak menyimpannya.

Peran Pergeseran Merah Amazon ML Amazon

Gunakan parameter ini untuk menentukan nama peran IAM yang harus digunakan Amazon ML untuk mengonfigurasi grup keamanan klaster Amazon Redshift dan kebijakan bucket untuk lokasi pementasan Amazon S3.

Jika Anda tidak memiliki peran IAM yang dapat mengakses Amazon Redshift, Amazon ML dapat membuat peran untuk Anda. Saat Amazon ML membuat peran, Amazon akan membuat dan melampirkan kebijakan yang dikelola pelanggan ke peran IAM. Kebijakan yang dibuat Amazon ML memberikan izin Amazon untuk mengakses hanya kluster yang Anda tentukan.

Jika Anda sudah memiliki peran IAM untuk mengakses Amazon Redshift, Anda dapat mengetik ARN peran tersebut, atau memilih peran dari daftar drop-down. Peran IAM dengan akses Amazon Redshift tercantum di bagian atas drop-down.

Peran IAM harus memiliki konten berikut:

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/*" }
      }
    }
  ]
}
```

Untuk informasi selengkapnya tentang Kebijakan yang Dikelola [Pelanggan](#), lihat [Kebijakan yang Dikelola Pelanggan](#) di Panduan Pengguna IAM.

Kueri SQL Amazon Redshift

Gunakan parameter ini untuk menentukan kueri SQL SELECT yang dijalankan Amazon ML di database Amazon Redshift Anda untuk memilih data Anda. Amazon ML menggunakan tindakan Amazon Redshift [UNLOAD](#) untuk menyalin hasil kueri Anda dengan aman ke lokasi Amazon S3.

Note

Amazon ML bekerja paling baik saat catatan input berada dalam urutan acak (diacak). Anda dapat dengan mudah mengacak hasil kueri Amazon Redshift SQL Anda dengan

menggunakan fungsi Amazon Redshift `random()`. Misalnya, katakanlah ini adalah kueri asli:

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

Anda dapat menyematkan pengocokan acak dengan memperbarui kueri seperti ini:

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

Lokasi Skema (Opsional)

Gunakan parameter ini untuk menentukan jalur Amazon S3 ke skema Anda untuk data Amazon Redshift yang akan diekspor Amazon ML.

Jika Anda tidak menyediakan skema untuk sumber data Anda, konsol Amazon ML akan secara otomatis membuat skema Amazon ML berdasarkan skema data kueri Amazon Redshift SQL. Skema Amazon ML memiliki tipe data yang lebih sedikit daripada skema Amazon Redshift, jadi ini bukan konversi one-to-one. Konsol Amazon ML mengonversi tipe data Amazon Redshift ke tipe data Amazon ML menggunakan skema konversi berikut.

Jenis Data Amazon Redshift	Alias Amazon Redshift	Tipe Data Amazon ML
SMALLINT	INT2	NUMERIC
INTEGER	INT, INT4	NUMERIC
BIGINT	INT8	NUMERIC
DECIMAL	NUMERIC	NUMERIC
REAL	FLOAT4	NUMERIC
DOUBLE PRECISION	FLOAT8, MENGAPUNG	NUMERIC
BOOLEAN	BOOL	BINARY
CHAR	KARAKTER, NCHAR, BPCHAR	KATEGORIS

Jenis Data Amazon Redshift	Alias Amazon Redshift	Tipe Data Amazon ML
VARCHAR	KARAKTER BERVARIASI, NVARCHAR, TEKS	TEXT
DATE		TEXT
TIMESTAMP	STEMPEL WAKTU TANPA ZONA WAKTU	TEXT

Untuk dikonversi ke tipe Binary data Amazon, nilai Amazon Redshift Booleans dalam data Anda harus didukung nilai Amazon ML Binary. Jika tipe data Boolean Anda memiliki nilai yang tidak didukung, Amazon ML mengonversinya ke tipe data yang paling spesifik. Misalnya, jika Amazon Redshift Boolean memiliki nilai 0, dan 1, 2 Amazon ML mengonversi Boolean menjadi tipe data. Numeric Untuk informasi selengkapnya tentang nilai biner yang didukung, lihat [Menggunakan Attribute Type Field](#).

Jika Amazon ML tidak dapat mengetahui tipe data, maka defaultnya. Text

Setelah Amazon ML mengonversi skema, Anda dapat meninjau dan mengoreksi tipe data Amazon ML yang ditetapkan di wizard Create Datasource, dan merevisi skema sebelum Amazon ML membuat sumber data.

Lokasi Pementasan Amazon S3

Gunakan parameter ini untuk menentukan nama lokasi pementasan Amazon S3 tempat Amazon ML menyimpan hasil kueri Amazon Redshift SQL. Setelah membuat sumber data, Amazon ML menggunakan data di lokasi pementasan alih-alih kembali ke Amazon Redshift.

Note

Karena Amazon ML mengasumsikan peran IAM yang ditentukan oleh peran Amazon Amazon Redshift Amazon, Amazon ML memiliki izin untuk mengakses objek apa pun di lokasi pementasan Amazon S3 yang ditentukan. Karena itu, kami menyarankan Anda hanya menyimpan file yang tidak berisi informasi sensitif di lokasi pementasan Amazon S3. Misalnya, jika bucket root Anda `s3://mybucket/`, kami sarankan Anda membuat lokasi untuk menyimpan hanya file yang ingin diakses Amazon ML, seperti `s3://mybucket/AmazonMLInput/`.

Membuat Sumber Data dengan Amazon Redshift Data (Konsol)

Konsol Amazon ML menyediakan dua cara untuk membuat sumber data menggunakan data Amazon Redshift. Anda dapat membuat sumber data dengan menyelesaikan wizard Create Datasource, atau, jika Anda sudah memiliki sumber data yang dibuat dari data Amazon Redshift, Anda dapat menyalin sumber data asli dan mengubah pengaturannya. Menyalin sumber data memungkinkan Anda membuat beberapa sumber data serupa dengan mudah.

Untuk informasi tentang membuat sumber data menggunakan API, lihat

[CreateDataSourceFromRedshift](#)

Untuk informasi lebih lanjut tentang parameter dalam prosedur berikut, lihat [Parameter yang Diperlukan untuk Create Datasource Wizard](#).

Topik

- [Membuat Sumber Data \(Konsol\)](#)
- [Menyalin Sumber Data \(Konsol\)](#)

Membuat Sumber Data (Konsol)

Untuk membongkar data dari Amazon Redshift ke sumber data Amazon, gunakan wizard Create Datasource.

Untuk membuat sumber data dari data di Amazon Redshift

1. Buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di dasbor Amazon, di bawah Entities, pilih Create new... , dan kemudian pilih Datasource.
3. Pada halaman Input data, pilih Amazon Redshift.
4. Di wizard Create Datasource, untuk pengidentifikasi Cluster, ketikkan nama cluster Anda.
5. Untuk nama Database, ketik nama database Amazon Redshift.
6. Untuk nama pengguna Database, ketikkan nama pengguna database Anda.
7. Untuk kata sandi Database, ketikkan kata sandi basis data Anda.
8. Untuk peran IAM, pilih peran IAM Anda. Jika Anda belum memilikinya, pilih Buat peran baru. Amazon ML membuat peran IAM Amazon Redshift untuk Anda.
9. Untuk menguji setelan Amazon Redshift, pilih Akses Uji (di samping peran IAM). Jika Amazon ML tidak dapat terhubung ke Amazon Redshift dengan setelan yang disediakan, Anda tidak

dapat terus membuat sumber data. Untuk bantuan penyelesaian masalah, lihat [Menyelesaikan Masalah Kesalahan](#).

10. Untuk kueri SQL, ketik kueri SQL Anda.
11. Untuk lokasi Skema, pilih apakah Anda ingin Amazon ML membuat skema untuk Anda. Jika Anda telah membuat skema sendiri, ketik jalur Amazon S3 ke file skema Anda.
12. Untuk lokasi pementasan Amazon S3, ketik jalur Amazon S3 ke bucket tempat Anda ingin Amazon ML meletakkan data yang dibongkar dari Amazon Redshift.
13. (Opsional) Untuk nama Datasource, ketikkan nama untuk sumber data Anda.
14. Pilih Verifikasi. Amazon ML memverifikasi bahwa ia dapat terhubung ke database Amazon Redshift Anda.
15. Pada halaman Skema, tinjau tipe data untuk semua atribut dan perbaiki, seperlunya.
16. Pilih Lanjutkan.
17. Jika Anda ingin menggunakan sumber data ini untuk membuat atau mengevaluasi model ML, untuk Apakah Anda berencana menggunakan kumpulan data ini untuk membuat atau mengevaluasi model ML? , pilih Ya. Jika Anda memilih Ya, pilih baris target Anda. Untuk informasi tentang target, lihat [Menggunakan targetAttributeName Field](#).

Jika Anda ingin menggunakan sumber data ini bersama dengan model yang telah Anda buat untuk membuat prediksi, pilih No.

18. Pilih Lanjutkan.
19. Untuk Apakah data Anda berisi pengenalan? , jika data Anda tidak berisi pengenalan baris, pilih Tidak.

Jika data Anda berisi pengenalan baris, pilih Ya. Untuk informasi tentang pengidentifikasi baris, lihat [Menggunakan Bidang RowID](#).

20. Pilih Tinjau.
21. Pada halaman Tinjauan, tinjau pengaturan Anda, lalu pilih Selesai.

Setelah Anda membuat sumber data, Anda dapat menggunakannya untuk [create an ML model](#) Jika Anda telah membuat model, Anda dapat menggunakan sumber data untuk atau [evaluate an ML model generate predictions](#)

Menyalin Sumber Data (Konsol)

Saat Anda ingin membuat sumber data yang mirip dengan sumber data yang ada, Anda dapat menggunakan konsol Amazon Amazon untuk menyalin sumber data asli dan memodifikasi pengaturannya. Misalnya, Anda dapat memilih untuk memulai dengan sumber data yang ada, lalu memodifikasi skema data agar sesuai dengan data Anda; mengubah kueri SQL yang digunakan untuk membongkar data dari Amazon Redshift; atau tentukan pengguna (IAM) AWS Identity and Access Management lain untuk mengakses klaster Amazon Redshift.

Untuk menyalin dan memodifikasi sumber data Amazon Redshift

1. Buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di dasbor Amazon, di bawah Entities, pilih Create new... , dan kemudian pilih Datasource.
3. Pada halaman Input data, untuk Dimana data Anda? , pilih Amazon Redshift. Jika Anda sudah memiliki sumber data yang dibuat dari data Amazon Redshift, Anda memiliki opsi untuk menyalin pengaturan dari sumber data lain.

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](#).

Jika Anda belum memiliki sumber data yang dibuat dari data Amazon Redshift, opsi ini tidak muncul.

4. Pilih Temukan sumber data.
5. Pilih sumber data yang ingin Anda salin, dan pilih Salin pengaturan. Amazon ML secara otomatis mengisi sebagian besar pengaturan sumber data dengan pengaturan dari sumber data asli. Itu tidak menyalin kata sandi database, lokasi skema, atau nama sumber data dari sumber data asli.
6. Ubah salah satu pengaturan yang diisi otomatis yang ingin Anda ubah. Misalnya, jika Anda ingin mengubah data yang dibongkar Amazon ML dari Amazon Redshift, ubah kueri SQL.
7. Untuk kata sandi Database, ketikkan kata sandi basis data Anda. Amazon ML tidak menyimpan atau menggunakan kembali kata sandi Anda, jadi Anda harus selalu menyediakannya.
8. (Opsional) Untuk lokasi Skema, Amazon ML telah memilih sebelumnya Saya ingin Amazon ML menghasilkan skema yang direkomendasikan untuk Anda. Jika Anda telah membuat skema, pilih

Saya ingin menggunakan skema yang saya buat dan simpan di Amazon S3 dan ketik jalur ke file skema Anda di Amazon S3.

9. (Opsional) Untuk nama Datasource, ketikkan nama untuk sumber data Anda. Jika tidak, Amazon ML akan menghasilkan nama sumber data baru untuk Anda.
10. Pilih Verifikasi. Amazon ML memverifikasi bahwa ia dapat terhubung ke database Amazon Redshift Anda.
11. (Opsional) Jika Amazon ML menyimpulkan skema untuk Anda, pada halaman Skema, tinjau tipe data untuk semua atribut dan perbaiki, jika diperlukan.
12. Pilih Lanjutkan.
13. Jika Anda ingin menggunakan sumber data ini untuk membuat atau mengevaluasi model ML, untuk Apakah Anda berencana menggunakan kumpulan data ini untuk membuat atau mengevaluasi model ML? , pilih Ya. Jika Anda memilih Ya, pilih baris target Anda. Untuk informasi tentang target, lihat [Menggunakan targetAttributeName Field](#).

Jika Anda ingin menggunakan sumber data ini bersama dengan model yang telah Anda buat untuk membuat prediksi, pilih No.

14. Pilih Lanjutkan.
15. Untuk Apakah data Anda berisi pengenalan? , jika data Anda tidak berisi pengenalan baris, pilih Tidak.

Jika data Anda berisi pengenalan baris, pilih Ya, dan pilih baris yang ingin Anda gunakan sebagai pengenalan. Untuk informasi tentang pengidentifikasi baris, lihat [Menggunakan Bidang RowID](#).

16. Pilih Tinjau.
17. Tinjau pengaturan Anda, lalu pilih Selesai.

Setelah Anda membuat sumber data, Anda dapat menggunakannya untuk [create an ML model](#) Jika Anda telah membuat model, Anda dapat menggunakan sumber data untuk atau [evaluate an ML model generate predictions](#)

Memecahkan Masalah Amazon Redshift

Saat Anda membuat sumber data Amazon Redshift, model ML, dan evaluasi, Amazon Machine Learning (Amazon Learning) melaporkan status objek Amazon ML Anda di konsol Amazon ML. Jika Amazon ML mengembalikan pesan kesalahan, gunakan informasi dan sumber daya berikut untuk memecahkan masalah.

Untuk jawaban atas pertanyaan umum tentang Amazon ML, lihat [Amazon Machine Learning FAQs](#). Anda juga dapat mencari jawaban dan memposting pertanyaan di [forum Amazon Machine Learning](#).

Topik

- [Menyelesaikan Masalah Kesalahan](#)
- [Menghubungi AWS Support](#)

Menyelesaikan Masalah Kesalahan

Format peran tidak valid. Berikan peran IAM yang valid. Misalnya, arn:aws:iam:: id:role/. YourAccount
YourRedshiftRole

Menyebabkan

Format Nama Sumber Daya Amazon (ARN) peran IAM Anda tidak benar.

Solusi

Di wizard Create Datasource, perbaiki ARN untuk peran Anda. Untuk informasi tentang peran pemformatan ARNs, lihat [IAM ARNs](#) di Panduan Pengguna IAM. Wilayah ini opsional untuk peran ARNs IAM.

Peran tidak valid. Amazon ML tidak dapat mengambil <role ARN>peran IAM. Berikan peran IAM yang valid dan membuatnya dapat diakses oleh Amazon ML.

Menyebabkan

Peran Anda tidak diatur untuk memungkinkan Amazon ML untuk mengasumsikan itu.

Solusi

Di [konsol IAM](#), edit peran Anda sehingga memiliki kebijakan kepercayaan yang memungkinkan Amazon ML untuk mengambil peran yang melekat padanya.

<user ARN>Pengguna ini tidak berwenang untuk lulus <role ARN>peran IAM.

Menyebabkan

Pengguna IAM Anda tidak memiliki kebijakan izin yang memungkinkannya meneruskan peran ke Amazon ML.

Solusi

Lampirkan kebijakan izin ke pengguna IAM yang memungkinkan Anda meneruskan peran ke Amazon ML. Anda dapat melampirkan kebijakan izin ke pengguna IAM Anda di konsol [IAM](#).

Melewati peran IAM di seluruh akun tidak diperbolehkan. Peran IAM harus menjadi milik akun ini.

Menyebabkan

Anda tidak dapat melewati peran yang dimiliki oleh akun IAM lain.

Solusi

Masuk ke akun AWS yang Anda gunakan untuk membuat peran. Anda dapat melihat peran IAM Anda di konsol [IAM](#) Anda.

Peran yang ditentukan tidak memiliki izin untuk melakukan operasi. Berikan peran yang memiliki kebijakan yang memberikan izin yang diperlukan Amazon ML.

Menyebabkan

Peran IAM Anda tidak memiliki izin untuk melakukan operasi yang diminta.

Solusi

Edit kebijakan izin yang dilampirkan pada peran Anda di [konsol IAM](#) untuk memberikan izin yang diperlukan.

Amazon ML tidak dapat mengonfigurasi grup keamanan di kluster Amazon Redshift tersebut dengan peran IAM yang ditentukan.

Menyebabkan

Peran IAM Anda tidak memiliki izin yang diperlukan untuk mengonfigurasi kluster keamanan Amazon Redshift.

Solusi

Edit kebijakan izin yang dilampirkan pada peran Anda di [konsol IAM](#) untuk memberikan izin yang diperlukan.

Terjadi kesalahan saat Amazon ML mencoba mengonfigurasi grup keamanan di kluster Anda. Coba lagi nanti.

Menyebabkan

Saat Amazon ML mencoba terhubung ke kluster Amazon Redshift Anda, Amazon mengalami masalah.

Solusi

Verifikasi bahwa peran IAM yang Anda berikan di wizard Create Datasource memiliki semua izin yang diperlukan.

Format ID cluster tidak valid. Cluster IDs harus dimulai dengan huruf dan harus berisi hanya karakter alfanumerik dan tanda hubung. Mereka tidak dapat berisi dua tanda hubung berturut-turut atau diakhiri dengan tanda hubung.

Menyebabkan

Format ID kluster Amazon Redshift Anda salah.

Solusi

Di wizard Create Datasource, perbaiki ID cluster Anda sehingga hanya berisi karakter alfanumerik dan tanda hubung dan tidak berisi dua tanda hubung berturut-turut atau diakhiri dengan tanda hubung.

Tidak ada <Amazon Redshift cluster name>cluster, atau cluster tidak berada di wilayah yang sama dengan layanan Amazon MLmu. Tentukan cluster di wilayah yang sama dengan Amazon Amazon ini.

Menyebabkan

Amazon ML tidak dapat menemukan kluster Amazon Redshift Anda karena tidak terletak di wilayah tempat Anda membuat sumber data Amazon ML.

Solusi

Pastikan kluster Anda ada di halaman [Cluster](#) konsol Amazon Redshift, bahwa Anda membuat sumber data di wilayah yang sama di mana kluster Amazon Redshift berada, dan ID cluster yang ditentukan dalam wizard Create Datasource sudah benar.

Amazon ML tidak dapat membaca data di kluster Amazon Redshift Anda. Berikan ID cluster Amazon Redshift yang benar.

Menyebabkan

Amazon ML tidak dapat membaca data di kluster Amazon Redshift yang Anda tentukan.

Solusi

Di wizard Create Datasource, tentukan ID kluster Amazon Redshift yang benar, verifikasi bahwa Anda membuat sumber data di wilayah yang sama dengan kluster Amazon Redshift, dan kluster Anda terdaftar di halaman Amazon Redshift Clusters.

<Amazon Redshift cluster name>Cluster tidak dapat diakses publik.

Menyebabkan

Amazon ML tidak dapat mengakses kluster Anda karena kluster tidak dapat diakses publik dan tidak memiliki alamat IP publik.

Solusi

Buat cluster dapat diakses publik dan berikan alamat IP publik. Untuk informasi tentang membuat kluster dapat diakses publik, lihat [Memodifikasi Cluster di Panduan Manajemen Pergeseran Merah Amazon](#).

<Redshift>Status kluster tidak tersedia untuk Amazon ML. Gunakan konsol Amazon Redshift untuk melihat dan menyelesaikan masalah status kluster ini. Status cluster harus “tersedia.”

Menyebabkan

Amazon ML tidak dapat melihat status kluster.

Solusi

Pastikan kluster Anda tersedia. Untuk informasi tentang memeriksa status kluster, lihat [Mendapatkan Gambaran Umum Status Cluster](#) di Panduan Manajemen Pergeseran Merah Amazon. Untuk informasi tentang me-reboot kluster agar tersedia, lihat [Mem-boot ulang Cluster di Panduan Manajemen Pergeseran Merah Amazon](#).

Tidak ada <database name>database di cluster ini. Verifikasi bahwa nama database sudah benar atau tentukan cluster dan database lain.

Menyebabkan

Amazon ML tidak dapat menemukan database yang ditentukan di kluster yang ditentukan.

Solusi

Verifikasi bahwa nama database yang dimasukkan dalam wizard Create Datasource sudah benar, atau tentukan nama cluster dan database yang benar.

Amazon ML tidak dapat mengakses database Anda. Berikan kata sandi yang valid untuk pengguna database<user name>.

Menyebabkan

Kata sandi yang Anda berikan di wizard Create Datasource untuk memungkinkan Amazon ML mengakses database Amazon Redshift Anda tidak benar.

Solusi

Berikan kata sandi yang benar untuk pengguna database Amazon Redshift Anda.

Terjadi kesalahan saat Amazon ML mencoba memvalidasi kueri.

Menyebabkan

Ada masalah dengan kueri SQL Anda.

Solusi

Verifikasi bahwa kueri Anda adalah SQL yang valid.

Terjadi kesalahan saat menjalankan kueri SQL Anda. Verifikasi nama database dan kueri yang disediakan. Akar penyebab: {ServerMessage}.

Menyebabkan

Amazon Redshift tidak dapat menjalankan kueri Anda.

Solusi

Verifikasi bahwa Anda menentukan nama database yang benar di wizard Create Datasource, dan kueri Anda adalah SQL yang valid.

Terjadi kesalahan saat menjalankan kueri SQL Anda. Akar penyebab: {ServerMessage}.

Menyebabkan

Amazon Redshift tidak dapat menemukan tabel yang ditentukan.

Solusi

Verifikasi bahwa tabel yang Anda tentukan dalam wizard Create Datasource ada di database cluster Amazon Redshift, dan Anda memasukkan ID cluster, nama database, dan kueri SQL yang benar.

Menghubungi AWS Support

Jika Anda memiliki AWS Premium Support, Anda dapat membuat kasus dukungan teknis di [AWS Support Center](#).

Menggunakan Data dari Database Amazon RDS untuk Membuat Sumber Data Amazon Amazon

Amazon ML memungkinkan Anda membuat objek sumber data dari data yang disimpan dalam database MySQL di Amazon Relational Database Service (Amazon RDS). Saat Anda melakukan tindakan ini, Amazon ML membuat objek AWS Data Pipeline yang mengeksekusi kueri SQL yang Anda tentukan, dan menempatkan output ke dalam bucket S3 pilihan Anda. Amazon ML menggunakan data tersebut untuk membuat sumber data.

Note

Amazon ML hanya mendukung database MySQL di VPCs

Sebelum Amazon ML dapat membaca data input Anda, Anda harus mengekspor data tersebut ke Amazon Simple Storage Service (Amazon S3). Anda dapat mengatur Amazon ML untuk melakukan ekspor untuk Anda dengan menggunakan API. (RDS terbatas pada API, dan tidak tersedia dari konsol.)

Agar Amazon ML dapat terhubung ke database MySQL Anda di Amazon RDS dan membaca data atas nama Anda, Anda harus memberikan yang berikut:

- Pengidentifikasi instans RDS DB
- Nama database MySQL
- Peran AWS Identity and Access Management (IAM) yang digunakan untuk membuat, mengaktifkan, dan menjalankan pipa data
- Kredensi pengguna database:
 - Nama pengguna

- Kata Sandi
- Informasi keamanan AWS Data Pipeline:
 - Peran sumber daya IAM
 - Peran layanan IAM
- Informasi keamanan Amazon RDS:
 - ID subnet.
 - Kelompok keamanan IDs
- Kueri SQL yang menentukan data yang ingin Anda gunakan untuk membuat sumber data
- Lokasi keluaran S3 (bucket) digunakan untuk menyimpan hasil kueri
- (Opsional) Lokasi file skema data

Selain itu, Anda perlu memastikan bahwa pengguna IAM atau peran yang membuat sumber data Amazon RDS dengan menggunakan operasi [CreateDataSourceFromRDS](#) memiliki izin. `iam:PassRole` Untuk informasi selengkapnya, lihat [Mengontrol Akses ke Sumber Daya Amazon ML-dengan IAM](#).

Topik

- [Pengidentifikasi Instans Database RDS](#)
- [Nama Database MySQL](#)
- [Kredensial Pengguna Database](#)
- [Informasi Keamanan AWS Data Pipeline](#)
- [Informasi Keamanan Amazon RDS](#)
- [Kueri MySQL SQL](#)
- [Lokasi Output S3](#)

Pengidentifikasi Instans Database RDS

Pengidentifikasi instans RDS DB adalah nama unik yang Anda berikan yang mengidentifikasi instance database yang harus digunakan Amazon ML saat berinteraksi dengan Amazon RDS. Anda dapat menemukan pengenalan instans RDS DB di konsol Amazon RDS.

Nama Database MySQL

MySQL Database Name menentukan nama database MySQL dalam contoh RDS DB.

Kredensial Pengguna Database

Untuk terhubung ke instans RDS DB, Anda harus menyediakan nama pengguna dan kata sandi pengguna database yang memiliki izin yang cukup untuk menjalankan kueri SQL yang Anda berikan.

Informasi Keamanan AWS Data Pipeline

Untuk mengaktifkan akses AWS Data Pipeline yang aman, Anda harus memberikan nama peran sumber daya IAM dan peran layanan IAM.

Instans EC2 mengasumsikan peran sumber daya untuk menyalin data dari Amazon RDS ke Amazon S3. Cara termudah untuk membuat peran sumber daya ini adalah dengan menggunakan `DataPipelineDefaultResourceRole` templat, dan daftar machinelearning.amazonaws.com sebagai layanan tepercaya. Untuk informasi selengkapnya tentang template, lihat [Menyiapkan peran IAM](#) di Panduan Pengembang AWS Data Pipeline.

Jika Anda membuat peran Anda sendiri, itu harus memiliki konten berikut:

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 mengasumsikan peran layanan untuk memantau kemajuan penyalinan data dari Amazon RDS ke Amazon S3. Cara termudah untuk membuat peran sumber daya ini adalah dengan

menggunakan `DataPipelineDefaultRole` templat, dan daftar `machinelearning.aws.com` sebagai layanan tepercaya. Untuk informasi selengkapnya tentang template, lihat [Menyiapkan peran IAM](#) di Panduan Pengembang AWS Data Pipeline.

Informasi Keamanan Amazon RDS

Untuk mengaktifkan akses Amazon RDS yang aman, Anda perlu menyediakan VPC Subnet ID dan RDS Security Group IDs. Anda juga perlu mengatur aturan masuk yang sesuai untuk subnet VPC yang ditunjukkan oleh Subnet ID parameter, dan memberikan ID grup keamanan yang memiliki izin ini.

Kueri MySQL SQL

`MySQL SQL QueryParameter` menentukan query SQL `SELECT` yang ingin Anda jalankan pada database MySQL Anda. Hasil kueri disalin ke lokasi keluaran S3 (bucket) yang Anda tentukan.

Note

Teknologi pembelajaran mesin bekerja paling baik ketika catatan masukan disajikan dalam urutan acak (diacak). Anda dapat dengan mudah mengacak hasil kueri MySQL SQL Anda dengan menggunakan fungsi `rand()`. Misalnya, katakanlah ini adalah kueri asli:

“PILIH col1, col2,... DARI training_table”

Anda dapat menambahkan pengocokan acak dengan memperbarui kueri seperti ini:

“PILIH col1, col2,... DARI training_table PESANAN OLEH rand ()”

Lokasi Output S3

`S3 Output LocationParameter` menentukan nama lokasi “pementasan” Amazon S3 di mana hasil kueri MySQL SQL adalah output.

Note

Anda perlu memastikan bahwa Amazon ML memiliki izin untuk membaca data dari lokasi ini setelah data diekspor dari Amazon RDS. Untuk informasi tentang menyetel izin ini, lihat [Memberikan Izin Amazon MLL untuk Membaca Data Anda dari Amazon S3](#).

Pelatihan Model ML

Proses pelatihan model ML melibatkan penyediaan algoritma ML (yaitu, algoritma pembelajaran) dengan data pelatihan untuk dipelajari. Istilah model ML mengacu pada artefak model yang dibuat oleh proses pelatihan.

Data pelatihan harus berisi jawaban yang benar, yang dikenal sebagai target atau atribut target. Algoritma pembelajaran menemukan pola dalam data pelatihan yang memetakan atribut data input ke target (jawaban yang ingin Anda prediksi), dan menghasilkan model ML yang menangkap pola-pola ini.

Anda dapat menggunakan model ML untuk mendapatkan prediksi pada data baru yang Anda tidak tahu targetnya. Misalnya, katakanlah Anda ingin melatih model ML untuk memprediksi apakah email adalah spam atau bukan spam. Anda akan memberikan Amazon ML data pelatihan yang berisi email yang Anda tahu targetnya (yaitu, label yang memberi tahu apakah email itu spam atau bukan spam). Amazon ML akan melatih model ML dengan menggunakan data ini, menghasilkan model yang mencoba memprediksi apakah email baru akan spam atau bukan spam.

Untuk informasi umum tentang model ML dan algoritma ML, lihat [Konsep Machine Learning](#).

Topik

- [Jenis Model ML](#)
- [Proses Pelatihan](#)
- [Parameter Pelatihan](#)
- [Membuat Model ML](#)

Jenis Model ML

Amazon ML mendukung tiga jenis model ML: klasifikasi biner, klasifikasi multiclass, dan regresi. Jenis model yang harus Anda pilih tergantung pada jenis target yang ingin Anda prediksi.

Model Klasifikasi Biner

Model ML untuk masalah klasifikasi biner memprediksi hasil biner (salah satu dari dua kelas yang mungkin). Untuk melatih model klasifikasi biner, Amazon ML menggunakan algoritma pembelajaran standar industri yang dikenal sebagai regresi logistik.

Contoh Masalah Klasifikasi Biner

- “Apakah email ini spam atau bukan spam?”
- “Apakah pelanggan akan membeli produk ini?”
- “Apakah produk ini buku atau hewan ternak?”
- “Apakah ulasan ini ditulis oleh pelanggan atau robot?”

Model Klasifikasi Multiclass

Model ML untuk masalah klasifikasi multiclass memungkinkan Anda menghasilkan prediksi untuk beberapa kelas (memprediksi satu dari lebih dari dua hasil). Untuk melatih model multiclass, Amazon ML menggunakan algoritma pembelajaran standar industri yang dikenal sebagai regresi logistik multinomial.

Contoh Masalah Multiclass

- “Apakah produk ini buku, film, atau pakaian?”
- “Apakah film ini komedi romantis, dokumenter, atau thriller?”
- “Kategori produk mana yang paling menarik bagi pelanggan ini?”

Model Regresi

Model ML untuk masalah regresi memprediksi nilai numerik. Untuk model regresi pelatihan, Amazon ML menggunakan algoritma pembelajaran standar industri yang dikenal sebagai regresi linier.

Contoh Masalah Regresi

- “Berapa suhu di Seattle besok?”
- “Untuk produk ini, berapa unit yang akan dijual?”
- “Berapa harga yang akan dijual rumah ini?”

Proses Pelatihan

Untuk melatih model ML, Anda perlu menentukan yang berikut:

- Sumber data pelatihan masukan
- Nama atribut data yang berisi target yang akan diprediksi

- Instruksi transformasi data yang diperlukan
- Parameter pelatihan untuk mengontrol algoritma pembelajaran

Selama proses pelatihan, Amazon ML secara otomatis memilih algoritme pembelajaran yang benar untuk Anda, berdasarkan jenis target yang Anda tentukan dalam sumber data pelatihan.

Parameter Pelatihan

Biasanya, algoritma pembelajaran mesin menerima parameter yang dapat digunakan untuk mengontrol properti tertentu dari proses pelatihan dan model ML yang dihasilkan. Di Amazon Machine Learning, ini disebut parameter pelatihan. Anda dapat mengatur parameter ini menggunakan konsol Amazon, API, atau antarmuka baris perintah (CLI). Jika Anda tidak menyetel parameter apa pun, Amazon ML akan menggunakan nilai default yang diketahui berfungsi dengan baik untuk berbagai tugas pembelajaran mesin.

Anda dapat menentukan nilai untuk parameter pelatihan berikut:

- Ukuran model maksimum
- Jumlah maksimum lintasan atas data pelatihan
- Jenis kocokan
- Jenis regularisasi
- Jumlah regularisasi

Di konsol Amazon Amazon, parameter pelatihan ditetapkan secara default. Pengaturan default cukup untuk sebagian besar masalah ML. tetapi Anda dapat memilih nilai lain untuk menyempurnakan kinerja. Parameter pelatihan tertentu lainnya, seperti tingkat pembelajaran, dikonfigurasi untuk Anda berdasarkan data Anda.

Bagian berikut memberikan informasi lebih lanjut tentang parameter pelatihan.

Ukuran Model Maksimum

Ukuran model maksimum adalah ukuran total, dalam satuan byte, pola yang dibuat Amazon MLL selama pelatihan model ML.

Secara default, Amazon ML membuat model 100 MB. Anda dapat menginstruksikan Amazon ML untuk membuat model yang lebih kecil atau lebih besar dengan menentukan ukuran yang berbeda. Untuk berbagai ukuran yang tersedia, lihat [Jenis Model ML](#)

Jika Amazon ML tidak dapat menemukan pola yang cukup untuk mengisi ukuran model, itu akan menciptakan model yang lebih kecil. Misalnya, jika Anda menentukan ukuran model maksimum 100 MB, tetapi Amazon ML menemukan pola yang totalnya hanya 50 MB, model yang dihasilkan akan menjadi 50 MB. Jika Amazon ML menemukan lebih banyak pola daripada yang sesuai dengan ukuran yang ditentukan, ini memberlakukan batas maksimum dengan memangkas pola yang paling tidak memengaruhi kualitas model yang dipelajari.

Memilih ukuran model memungkinkan Anda untuk mengontrol trade-off antara kualitas prediksi model dan biaya penggunaan. Model yang lebih kecil dapat menyebabkan Amazon ML menghapus banyak pola agar sesuai dengan batas ukuran maksimum, yang memengaruhi kualitas prediksi. Model yang lebih besar, di sisi lain, lebih mahal untuk meminta prediksi waktu nyata.

Note

Jika Anda menggunakan model ML untuk menghasilkan prediksi real-time, Anda akan dikenakan biaya reservasi kapasitas kecil yang ditentukan oleh ukuran model. Untuk informasi selengkapnya, lihat [Harga untuk Amazon ML](#).

Kumpulan data input yang lebih besar tidak selalu menghasilkan model yang lebih besar karena model menyimpan pola, bukan data input; jika polanya sedikit dan sederhana, model yang dihasilkan akan kecil. Input data yang memiliki sejumlah besar atribut mentah (kolom input) atau fitur turunan (output dari transformasi data Amazon ML) kemungkinan akan memiliki lebih banyak pola yang ditemukan dan disimpan selama proses pelatihan. Memilih ukuran model yang tepat untuk data dan masalah Anda sebaiknya didekati dengan beberapa eksperimen. Log pelatihan model Amazon (yang dapat Anda unduh dari konsol atau melalui API) berisi pesan tentang berapa banyak pemangkasan model (jika ada) yang terjadi selama proses pelatihan, memungkinkan Anda memperkirakan hit-to-prediction kualitas potensial.

Jumlah Maksimum Pass atas Data

Untuk hasil terbaik, Amazon ML mungkin perlu melakukan beberapa kali melewati data Anda untuk menemukan pola. Secara default, Amazon ML membuat 10 lintasan, tetapi Anda dapat mengubah default dengan menyetel angka hingga 100. Amazon ML melacak kualitas pola (konvergensi model) seiring berjalannya waktu, dan secara otomatis menghentikan pelatihan ketika tidak ada lagi titik data atau pola untuk ditemukan. Misalnya, jika Anda mengatur jumlah lintasan ke 20, tetapi Amazon ML menemukan bahwa tidak ada pola baru yang dapat ditemukan pada akhir 15 lintasan, maka itu akan menghentikan pelatihan pada 15 lintasan.

Secara umum, kumpulan data dengan hanya beberapa pengamatan biasanya memerlukan lebih banyak operasi atas data untuk mendapatkan kualitas model yang lebih tinggi. Kumpulan data yang lebih besar sering mengandung banyak titik data serupa, yang menghilangkan kebutuhan akan sejumlah besar lintasan. Dampak memilih lebih banyak data melewati data Anda adalah dua kali lipat: pelatihan model membutuhkan waktu lebih lama, dan biayanya lebih mahal.

Jenis Kocokan untuk Data Pelatihan

Di Amazon ML, Anda harus mengocokkan data pelatihan Anda. Pengocokan mencampur urutan data Anda sehingga algoritma SGD tidak menemukan satu jenis data untuk terlalu banyak pengamatan berturut-turut. Misalnya, jika Anda melatih model ML untuk memprediksi jenis produk, dan data pelatihan Anda mencakup jenis produk film, mainan, dan video game, jika Anda mengurutkan data berdasarkan kolom jenis produk sebelum mengunggahnya, algoritma akan melihat data menurut abjad berdasarkan jenis produk. Algoritma melihat semua data Anda untuk film terlebih dahulu, dan model ML Anda mulai mempelajari pola untuk film. Kemudian, ketika model Anda menemukan data tentang mainan, setiap pembaruan yang dibuat algoritma akan sesuai dengan model dengan jenis produk mainan, bahkan jika pembaruan tersebut menurunkan pola yang sesuai dengan film. Peralihan tiba-tiba dari jenis film ke mainan ini dapat menghasilkan model yang tidak belajar bagaimana memprediksi jenis produk secara akurat.

Anda harus mengacak data pelatihan Anda bahkan jika Anda memilih opsi pemisahan acak saat Anda membagi sumber data input menjadi bagian pelatihan dan evaluasi. Strategi pemisahan acak memilih subset acak dari data untuk setiap sumber data, tetapi tidak mengubah urutan baris dalam sumber data. Untuk informasi selengkapnya tentang membagi data Anda, lihat [Memisahkan Data Anda](#).

Saat Anda membuat model ML menggunakan konsol, Amazon ML secara default akan mengacak data dengan teknik pseudo-random shuffling. Terlepas dari jumlah lintasan yang diminta, Amazon ML mengacak data hanya sekali sebelum melatih model ML. Jika Anda mengacak data Anda sebelum memberikannya ke Amazon ML, dan tidak ingin Amazon ML mengacak data Anda lagi, Anda dapat menyetel tipe Shuffle ke `none`. Misalnya, jika Anda mengacak catatan di file.csv secara acak sebelum mengunggahnya ke Amazon S3, gunakan fungsi tersebut dalam kueri SQL MySQL Anda saat membuat sumber data dari Amazon RDS, atau menggunakan `rand()` `random()` fungsi tersebut dalam kueri Amazon Redshift SQL saat membuat sumber data dari Amazon Redshift, menyetel tipe Shuffle ke `tidak` akan memengaruhi akurasi prediktif model ML Anda. `none` Mengacak data Anda hanya sekali mengurangi waktu proses dan biaya untuk membuat model ML.

⚠ Important

Saat Anda membuat model ML menggunakan Amazon ML API, Amazon ML tidak akan mengacak data Anda secara default. Jika Anda menggunakan API alih-alih konsol untuk membuat model ML, kami sangat menyarankan agar Anda mengacak data dengan menyetel `sgd.shuffleType` parameternya. `auto`

Jenis dan Jumlah Regularisasi

Kinerja prediktif model ML kompleks (yang memiliki banyak atribut input) menderita ketika data berisi terlalu banyak pola. Ketika jumlah pola meningkat, begitu juga kemungkinan bahwa model mempelajari artefak data yang tidak disengaja, daripada pola data yang sebenarnya. Dalam kasus seperti itu, model bekerja dengan sangat baik pada data pelatihan, tetapi tidak dapat menggeneralisasi dengan baik pada data baru. Fenomena ini dikenal sebagai overfitting data pelatihan.

Regularisasi membantu mencegah model linier menyesuaikan contoh data pelatihan dengan menghukum nilai bobot ekstrim. Regularisasi L1 mengurangi jumlah fitur yang digunakan dalam model dengan mendorong bobot fitur yang seharusnya memiliki bobot yang sangat kecil menjadi nol. Regularisasi L1 menghasilkan model yang jarang dan mengurangi jumlah kebisingan dalam model. Regularisasi L2 menghasilkan nilai bobot keseluruhan yang lebih kecil, yang menstabilkan bobot ketika ada korelasi tinggi antara fitur. Anda dapat mengontrol jumlah regularisasi L1 atau L2 dengan menggunakan parameter. `Regularization amount` Menentukan `Regularization amount` nilai yang sangat besar dapat menyebabkan semua fitur memiliki bobot nol.

Memilih dan menyetel nilai regularisasi optimal adalah subjek aktif dalam penelitian pembelajaran mesin. Anda mungkin akan mendapat manfaat dari memilih regularisasi L2 dalam jumlah moderat, yang merupakan default di konsol Amazon Amazon. Pengguna tingkat lanjut dapat memilih antara tiga jenis regularisasi (tidak ada, L1, atau L2) dan jumlah. Untuk informasi lebih lanjut tentang regularisasi, buka [Regularisasi](#) (matematika).

Parameter Pelatihan: Jenis dan Nilai Default

Tabel berikut mencantumkan parameter pelatihan Amazon Amazon, bersama dengan nilai default dan rentang yang diijinkan untuk masing-masing parameter.

Parameter Pelatihan	Jenis	Nilai Default	Deskripsi
maks MLModel SizeInBytes	Bilangan Bulat	100.000.000 byte (100 MiB)	Kisaran yang diijinkan: 100.000 (100 KiB) hingga 2.147.483.648 (2 GiB) Tergantung pada data input, ukuran model dapat mempengaruhi kinerja.
SGD.MaxPasses	Bilangan Bulat	10	Rentang yang diijinkan: 1-100
SGD.shuffleType	String	auto	Nilai yang diijinkan: auto atau none
sgd.l1 RegularizationAmount	Ganda	0 (Secara default, L1 tidak digunakan)	Rentang yang diijinkan: 0 hingga MAX_DOUBLE Nilai L1 antara 1E-4 dan 1E-8 telah ditemukan untuk menghasilkan hasil yang baik. Nilai yang lebih besar cenderung menghasilkan model yang tidak terlalu berguna. Anda tidak dapat mengatur L1 dan L2. Anda harus memilih satu atau yang lain.
sgd.l2 RegularizationAmount	Ganda	1E-6 (Secara default, L2 digunakan dengan jumlah regularisasi ini)	Rentang yang diijinkan: 0 hingga MAX_DOUBLE Nilai L2 antara 1E-2 dan 1E-6 telah ditemukan untuk menghasilkan hasil yang baik. Nilai yang lebih besar cenderung menghasilkan model yang tidak terlalu berguna. Anda tidak dapat mengatur L1 dan L2. Anda harus memilih satu atau yang lain.

Membuat Model ML

Setelah Anda membuat sumber data, Anda siap untuk membuat model ML. Jika Anda menggunakan konsol Amazon Machine Learning untuk membuat model, Anda dapat memilih untuk menggunakan pengaturan default atau menyesuaikan model dengan menerapkan opsi kustom.

Opsi kustom meliputi:

- Pengaturan evaluasi: Anda dapat memilih agar Amazon ML menyimpan sebagian data input untuk mengevaluasi kualitas prediktif model ML. Untuk informasi tentang evaluasi, lihat [Mengevaluasi Model ML](#).
- Resep: Sebuah resep memberi tahu Amazon ML atribut dan transformasi atribut mana yang tersedia untuk pelatihan model. Untuk informasi tentang resep Amazon Amazon, lihat [Transformasi Fitur dengan Resep Data](#).
- Parameter pelatihan: Parameter mengontrol sifat-sifat tertentu dari proses pelatihan dan model ML yang dihasilkan. Untuk informasi selengkapnya tentang parameter pelatihan, lihat [Parameter Pelatihan](#).

Untuk memilih atau menentukan nilai untuk pengaturan ini, pilih opsi Kustom saat Anda menggunakan wizard Buat Model ML. Jika Anda ingin Amazon ML menerapkan pengaturan default, pilih Default.

Saat Anda membuat model ML, Amazon ML memilih jenis algoritme pembelajaran yang akan digunakan berdasarkan jenis atribut atribut dari atribut target Anda. (Atribut target adalah atribut yang berisi jawaban “benar”.) Jika atribut target Anda adalah Binary, Amazon ML membuat model klasifikasi biner, yang menggunakan algoritma regresi logistik. Jika atribut target Anda Categorical, Amazon ML akan membuat model multiclass, yang menggunakan algoritma regresi logistik multinomial. Jika atribut target Anda adalah Numerik, Amazon ML akan membuat model regresi, yang menggunakan algoritma regresi linier.

Topik

- [Prasyarat](#)
- [Membuat Model ML dengan Opsi Default](#)
- [Membuat Model ML dengan Opsi Kustom](#)

Prasyarat

Sebelum menggunakan konsol Amazon Amazon untuk membuat model ML, Anda perlu membuat dua sumber data, satu untuk melatih model dan satu untuk mengevaluasi model. Jika Anda belum membuat dua sumber data, lihat [Langkah 2: Buat Datasource Pelatihan](#) di tutorial.

Membuat Model ML dengan Opsi Default

Pilih opsi Default, jika Anda ingin Amazon ML:

- Pisahkan data input untuk menggunakan 70 persen pertama untuk pelatihan dan gunakan 30 persen sisanya untuk evaluasi
- Sarankan resep berdasarkan statistik yang dikumpulkan pada sumber data pelatihan, yang merupakan 70 persen dari sumber data input
- Pilih parameter pelatihan default

Untuk memilih opsi default

1. Di konsol Amazon ML, pilih Amazon Machine Learning, lalu pilih model ML.
2. Pada halaman ringkasan model ML, pilih Buat model ML baru.
3. Pada halaman Input data, pastikan bahwa saya sudah membuat sumber data yang menunjuk ke data S3 saya dipilih.
4. Dalam tabel, pilih sumber data Anda, lalu pilih Lanjutkan.
5. Pada halaman pengaturan model ML, untuk nama model ML, ketikkan nama untuk model ML Anda.
6. Untuk pengaturan Pelatihan dan evaluasi, pastikan Default dipilih.
7. Untuk Nama evaluasi ini, ketikkan nama untuk evaluasi, lalu pilih Tinjau. Amazon ML melewati sisa wizard dan membawa Anda ke halaman Ulasan.
8. Tinjau data Anda, hapus tag yang disalin dari sumber data yang tidak ingin diterapkan pada model dan evaluasi, lalu pilih Selesai.

Membuat Model ML dengan Opsi Kustom

Menyesuaikan model ML Anda memungkinkan Anda untuk:

- Berikan resep Anda sendiri. Untuk informasi tentang cara menyediakan resep Anda sendiri, lihat [Referensi Format Resep](#).
- Pilih parameter pelatihan. Untuk informasi selengkapnya tentang parameter pelatihan, lihat [Parameter Pelatihan](#).
- Pilih rasio training/evaluation pemisahan selain rasio 70/30 default atau berikan sumber data lain yang telah Anda siapkan untuk evaluasi. Untuk informasi tentang strategi pemisahan, lihat [Memisahkan Data Anda](#).

Anda juga dapat memilih nilai default untuk salah satu pengaturan ini.

Jika Anda telah membuat model menggunakan opsi default dan ingin meningkatkan kinerja prediktif model Anda, gunakan opsi Kustom untuk membuat model baru dengan beberapa pengaturan yang disesuaikan. Misalnya, Anda dapat menambahkan lebih banyak transformasi fitur ke resep atau menambah jumlah pass dalam parameter pelatihan.

Untuk membuat model dengan opsi khusus

1. Di konsol Amazon ML, pilih Amazon Machine Learning, lalu pilih model ML.
2. Pada halaman ringkasan model ML, pilih Buat model ML baru.
3. Jika Anda telah membuat sumber data, pada halaman Input data, pilih Saya sudah membuat sumber data yang menunjuk ke data S3 saya. Dalam tabel, pilih sumber data Anda, lalu pilih Lanjutkan.

Jika Anda perlu membuat sumber data, pilih Data saya ada di S3, dan saya perlu membuat sumber data, pilih Lanjutkan. Anda dialihkan ke wizard Create a Datasource. Tentukan apakah data Anda dalam S3 atau Redshift, lalu pilih Verifikasi. Selesaikan prosedur untuk membuat sumber data.

Setelah Anda membuat sumber data, Anda akan diarahkan ke langkah berikutnya dalam wizard Buat Model ML.

4. Pada halaman pengaturan model ML, untuk nama model ML, ketikkan nama untuk model ML Anda.
5. Di Pilih pengaturan pelatihan dan evaluasi, pilih Kustom, lalu pilih Lanjutkan.
6. Di halaman Resep, Anda bisa [customize a recipe](#). Jika Anda tidak ingin menyesuaikan resep, Amazon ML menyarankan satu untuk Anda. Pilih Lanjutkan.

7. Pada halaman Pengaturan lanjutan, tentukan Ukuran model ML Maksimum, Jumlah maksimum data yang lewat, Jenis acak untuk data pelatihan, jenis Regularisasi, dan jumlah Regularisasi. Jika Anda tidak menentukan ini, Amazon ML menggunakan parameter pelatihan default.

Untuk informasi lebih lanjut tentang parameter ini dan defaultnya, lihat [Parameter Pelatihan](#)

Pilih Lanjutkan.

8. Pada halaman Evaluasi, tentukan apakah Anda ingin segera mengevaluasi model ML. Jika Anda tidak ingin mengevaluasi model ML sekarang, pilih Review.

Jika Anda ingin mengevaluasi model ML sekarang:

- a. Untuk Nama evaluasi ini, ketikkan nama untuk evaluasi.
 - b. Untuk Pilih data evaluasi, pilih apakah Anda ingin Amazon ML memesan sebagian data masukan untuk evaluasi dan, jika Anda melakukannya, bagaimana Anda ingin membagi sumber data, atau memilih untuk menyediakan sumber data yang berbeda untuk evaluasi.
 - c. Pilih Tinjau.
9. Pada halaman Tinjauan, edit pilihan Anda, hapus tag yang disalin dari sumber data yang tidak ingin diterapkan pada model dan evaluasi, lalu pilih Selesai.

Setelah Anda membuat model, lihat [Langkah 4: Tinjau Kinerja Prediktif Model ML dan Tetapkan Ambang Skor](#).

Transformasi Data untuk Machine Learning

Model pembelajaran mesin hanya sebegus data yang digunakan untuk melatihnya. Karakteristik utama dari data pelatihan yang baik adalah bahwa ia disediakan dengan cara yang dioptimalkan untuk pembelajaran dan generalisasi. Proses menyusun data dalam format optimal ini dikenal di industri sebagai transformasi fitur.

Topik

- [Pentingnya Transformasi Fitur](#)
- [Transformasi Fitur dengan Resep Data](#)
- [Referensi Format Resep](#)
- [Resep yang Disarankan](#)
- [Referensi Transformasi Data](#)
- [Penataan Ulang Data](#)

Pentingnya Transformasi Fitur

Pertimbangkan model pembelajaran mesin yang tugasnya memutuskan apakah transaksi kartu kredit itu curang atau tidak. Berdasarkan pengetahuan latar belakang aplikasi dan analisis data, Anda dapat memutuskan bidang data (atau fitur) mana yang penting untuk disertakan dalam data input. Misalnya, jumlah transaksi, nama pedagang, alamat, dan alamat pemilik kartu kredit penting untuk diberikan pada proses pembelajaran. Di sisi lain, ID transaksi yang dihasilkan secara acak tidak membawa informasi (jika kita tahu bahwa itu benar-benar acak), dan tidak berguna.

Setelah Anda memutuskan bidang mana yang akan disertakan, Anda mengubah fitur-fitur ini untuk membantu proses pembelajaran. Transformasi menambah pengalaman latar belakang ke data input, memungkinkan model pembelajaran mesin untuk mendapatkan manfaat dari pengalaman ini. Misalnya, alamat pedagang berikut direpresentasikan sebagai string:

“Jalan Utama 123, Seattle, WA 98101”

Dengan sendirinya, alamat tersebut memiliki kekuatan ekspresif yang terbatas — hanya berguna untuk pola pembelajaran yang terkait dengan alamat yang tepat itu. Memecahnya menjadi bagian-bagian konstituen, bagaimanapun, dapat membuat fitur tambahan seperti “Alamat” (123 Main Street), “Kota” (Seattle), “Negara Bagian” (WA) dan “Zip” (98101). Sekarang, algoritma pembelajaran dapat

mengelompokkan transaksi yang lebih berbeda bersama-sama, dan menemukan pola yang lebih luas — mungkin beberapa kode pos pedagang mengalami aktivitas yang lebih curang daripada yang lain.

Untuk informasi selengkapnya tentang pendekatan dan proses transformasi fitur, lihat [Konsep Machine Learning](#).

Transformasi Fitur dengan Resep Data

Ada dua cara untuk mengubah fitur sebelum membuat model ML dengan Amazon ML: Anda dapat mengubah data input Anda secara langsung sebelum menunjukkannya ke Amazon ML, atau Anda dapat menggunakan transformasi data bawaan Amazon ML. Anda dapat menggunakan resep Amazon ML, yang merupakan instruksi yang telah diformat sebelumnya untuk transformasi umum. Dengan resep, Anda dapat melakukan hal berikut:

- Pilih dari daftar transformasi pembelajaran mesin umum bawaan, dan terapkan ini ke variabel individu atau kelompok variabel
- Pilih variabel input dan transformasi mana yang tersedia untuk proses pembelajaran mesin

Menggunakan resep Amazon ML menawarkan beberapa keuntungan. Amazon ML melakukan transformasi data untuk Anda, jadi Anda tidak perlu menerapkannya sendiri. Selain itu, mereka cepat karena Amazon ML menerapkan transformasi saat membaca data input, dan memberikan hasil untuk proses pembelajaran tanpa langkah menengah menyimpan hasil ke disk.

Referensi Format Resep

Resep Amazon ML berisi instruksi untuk mengubah data Anda sebagai bagian dari proses pembelajaran mesin. Resep didefinisikan menggunakan sintaks seperti JSON, tetapi mereka memiliki batasan tambahan di luar batasan JSON normal. Resep memiliki bagian berikut, yang harus muncul dalam urutan yang ditunjukkan di sini:

- Grup memungkinkan pengelompokan beberapa variabel, untuk kemudahan menerapkan transformasi. Misalnya, Anda dapat membuat grup dari semua variabel yang berkaitan dengan bagian teks bebas dari halaman web (judul, isi), dan kemudian melakukan transformasi pada semua bagian ini sekaligus.
- Penugasan memungkinkan pembuatan variabel bernama menengah yang dapat digunakan kembali dalam pemrosesan.

- Output menentukan variabel mana yang akan digunakan dalam proses pembelajaran, dan transformasi apa (jika ada) yang berlaku untuk variabel-variabel ini.

Grup

Anda dapat menentukan kelompok variabel untuk secara kolektif mengubah semua variabel dalam kelompok, atau menggunakan variabel ini untuk pembelajaran mesin tanpa mengubahnya. Secara default, Amazon ML membuat grup berikut untuk Anda:

ALL_TEXT, ALL_NUMERIC, ALL_CATEGORICAL, ALL_BINARY — Grup khusus tipe berdasarkan variabel yang ditentukan dalam skema sumber data.

Note

Anda tidak dapat membuat grup dengan ALL_INPUTS.

Variabel-variabel ini dapat digunakan di bagian output resep Anda tanpa didefinisikan. Anda juga dapat membuat grup kustom dengan menambahkan atau mengurangi variabel dari grup yang ada, atau langsung dari kumpulan variabel. Dalam contoh berikut, kami mendemonstrasikan ketiga pendekatan, dan sintaks untuk tugas pengelompokan:

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

Nama grup harus dimulai dengan karakter alfabet dan panjangnya bisa antara 1 dan 64 karakter. Jika nama grup tidak dimulai dengan karakter abjad atau jika mengandung karakter khusus (, " \ t \ r \ n ()), maka nama tersebut perlu dikutip untuk dimasukkan dalam resep.

Tugas

Anda dapat menetapkan satu atau lebih transformasi ke variabel perantara, untuk kenyamanan dan keterbacaan. Misalnya, jika Anda memiliki variabel teks bernama email_subject, dan Anda

menerapkan transformasi huruf kecil padanya, Anda dapat memberi nama variabel yang dihasilkan `email_subject_lowercase`, sehingga mudah untuk melacaknya di tempat lain dalam resep. Tugas juga dapat dirantai, memungkinkan Anda untuk menerapkan beberapa transformasi dalam urutan tertentu. Contoh berikut menunjukkan tugas tunggal dan berantai dalam sintaks resep:

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

Nama variabel menengah harus dimulai dengan karakter alfabet dan panjangnya bisa antara 1 dan 64 karakter. Jika nama tidak dimulai dengan alfabet atau jika mengandung karakter khusus (, " \ t \ r \n()), maka nama perlu dikutip untuk dimasukkan dalam resep.

Output

Bagian output mengontrol variabel input mana yang akan digunakan untuk proses pembelajaran, dan transformasi mana yang berlaku untuk mereka. Bagian keluaran kosong atau tidak ada adalah kesalahan, karena tidak ada data yang akan diteruskan ke proses pembelajaran.

Bagian output paling sederhana hanya menyertakan grup `ALL_INPUTS` yang telah ditentukan sebelumnya, menginstruksikan Amazon ML. untuk menggunakan semua variabel yang ditentukan dalam sumber data untuk pembelajaran:

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

Bagian output juga dapat merujuk ke grup lain yang telah ditentukan sebelumnya dengan menginstruksikan Amazon ML untuk menggunakan semua variabel dalam grup ini:

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

```
"ALL_NUMERIC",  
  
"ALL_CATEGORICAL"  
  
]
```

Bagian output juga dapat merujuk ke grup khusus. Dalam contoh berikut, hanya satu grup kustom yang ditentukan di bagian tugas pengelompokan pada contoh sebelumnya yang akan digunakan untuk pembelajaran mesin. Semua variabel lain akan dijatuhkan:

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

Bagian output juga dapat merujuk ke tugas variabel yang ditentukan di bagian penugasan:

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

Dan variabel input atau transformasi dapat didefinisikan secara langsung di bagian output:

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

Output perlu secara eksplisit menentukan semua variabel dan variabel transformasi yang diharapkan tersedia untuk proses pembelajaran. Katakanlah, misalnya, bahwa Anda memasukkan dalam output produk Cartesian dari `var1` dan `var2`. Jika Anda ingin memasukkan variabel mentah `var1` dan `var2` juga, maka Anda perlu menambahkan variabel mentah di bagian output:

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

Output dapat mencakup komentar untuk keterbacaan dengan menambahkan teks komentar bersama dengan variabel:

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

Anda dapat mencampur dan mencocokkan semua pendekatan ini dalam bagian output.

Note

Komentar tidak diperbolehkan di konsol Amazon ML saat menambahkan resep.

Contoh Resep Lengkap

Contoh berikut mengacu pada beberapa pemroses data bawaan yang diperkenalkan dalam contoh sebelumnya:

```
{  
  "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"
]
}
```

Resep yang Disarankan

Saat Anda membuat sumber data baru di Amazon, dan statistik dihitung untuk sumber data tersebut, Amazon ML juga akan membuat resep yang disarankan yang dapat digunakan untuk

membuat model ML baru dari sumber data. Sumber data yang disarankan didasarkan pada data dan atribut target yang ada dalam data, dan menyediakan titik awal yang berguna untuk membuat dan menyempurnakan model ML Anda.

Untuk menggunakan resep yang disarankan di konsol Amazon Amazon, pilih Datasource atau Datasource dan model ML dari daftar drop-down Buat baru. Untuk pengaturan model ML, Anda akan memiliki pilihan pengaturan Pelatihan dan Evaluasi Default atau Kustom dalam langkah Pengaturan Model ML dari wizard Buat Model ML. Jika Anda memilih opsi Default, Amazon ML akan secara otomatis menggunakan resep yang disarankan. Jika Anda memilih opsi Kustom, editor resep di langkah berikutnya akan menampilkan resep yang disarankan, dan Anda akan dapat memverifikasi atau memodifikasinya sesuai kebutuhan.

Note

Amazon ML memungkinkan Anda untuk membuat sumber data dan kemudian segera menggunakannya untuk membuat model ML, sebelum perhitungan statistik selesai. Dalam hal ini, Anda tidak akan dapat melihat resep yang disarankan di opsi Kustom, tetapi Anda masih dapat melanjutkan melewati langkah itu dan meminta Amazon ML. menggunakan resep default untuk pelatihan model.

Untuk menggunakan resep yang disarankan dengan Amazon ML API, Anda dapat meneruskan string kosong di parameter Resep dan RecipeUri API. Tidak mungkin untuk mengambil resep yang disarankan menggunakan Amazon ML API.

Referensi Transformasi Data

Topik

- [Transformasi N-gram](#)
- [Transformasi Bigram Jarang Ortogonal \(OSB\)](#)
- [Transformasi Huruf Kecil](#)
- [Hapus Transformasi Tanda Baca](#)
- [Transformasi Binning Kuantil](#)
- [Transformasi Normalisasi](#)
- [Transformasi Produk Cartesian](#)

Transformasi N-gram

Transformasi n-gram mengambil variabel teks sebagai input dan menghasilkan string yang sesuai dengan menggeser jendela (dapat dikonfigurasi pengguna) n kata, menghasilkan output dalam proses. Misalnya, perhatikan string teks “Saya sangat menikmati membaca buku ini”.

Menentukan transformasi n-gram dengan ukuran jendela = 1 hanya memberi Anda semua kata individual dalam string itu:

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

Menentukan transformasi n-gram dengan ukuran jendela = 2 memberi Anda semua kombinasi dua kata serta kombinasi satu kata:

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

Menentukan transformasi n-gram dengan ukuran jendela = 3 akan menambahkan kombinasi tiga kata ke daftar ini, menghasilkan yang berikut:

```
{"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"}
```

Anda dapat meminta n-gram dengan ukuran mulai dari 2-10 kata. N-gram dengan ukuran 1 dihasilkan secara implisit untuk semua input yang tipenya ditandai sebagai teks dalam skema data, jadi Anda tidak perlu memintanya. Terakhir, perlu diingat bahwa n-gram dihasilkan dengan memecah data input pada karakter spasi putih. Itu berarti, misalnya, karakter tanda baca akan dianggap sebagai bagian dari token kata: menghasilkan n-gram dengan jendela 2 untuk string “merah, hijau, biru” akan menghasilkan {"merah,", "hijau,", "biru,", "merah, hijau", "hijau, biru"}. Anda dapat menggunakan prosesor penghapus tanda baca (dijelaskan nanti dalam dokumen ini) untuk menghapus simbol tanda baca jika ini bukan yang Anda inginkan.

Untuk menghitung n-gram ukuran jendela 3 untuk variabel var1:

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

Transformasi Bigram Jarang Ortogonal (OSB)

Transformasi OSB dimaksudkan untuk membantu dalam analisis string teks dan merupakan alternatif untuk transformasi bi-gram (n-gram dengan ukuran jendela 2). OSBs dihasilkan dengan menggeser jendela ukuran n di atas teks, dan mengeluarkan setiap pasangan kata yang menyertakan kata pertama di jendela.

Untuk membangun setiap OSB, kata-kata penyusunnya digabungkan dengan karakter “_” (garis bawah), dan setiap token yang dilewati ditunjukkan dengan menambahkan garis bawah lain ke dalam OSB. Dengan demikian, OSB mengkodekan tidak hanya token yang terlihat di dalam jendela, tetapi juga indikasi jumlah token yang dilewati dalam jendela yang sama.

Sebagai ilustrasi, pertimbangkan string “Rubah coklat cepat melompat di atas anjingnya yang malas”, dan berukuran OSBs 4. Enam jendela empat kata, dan dua jendela terakhir yang lebih pendek dari akhir string ditunjukkan dalam contoh berikut, juga OSBs dihasilkan dari masing-masing:

Jendela, {OSBs dihasilkan}

```
"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}
```

Bigram jarang ortogonal adalah alternatif untuk n-gram yang mungkin bekerja lebih baik dalam beberapa situasi. Jika data Anda memiliki bidang teks besar (10 kata atau lebih), bereksperimenlah untuk melihat mana yang berfungsi lebih baik. Perhatikan bahwa apa yang merupakan bidang teks besar dapat bervariasi tergantung pada situasinya. Namun, dengan bidang teks yang lebih besar,

OSBs telah ditunjukkan secara empiris untuk mewakili teks secara unik karena simbol lompat khusus (garis bawah).

Anda dapat meminta ukuran jendela 2 hingga 10 untuk transformasi OSB pada variabel teks input.

Untuk menghitung OSBs dengan ukuran jendela 5 untuk variabel `var1`:

```
“osb (var1, 5)”
```

Transformasi Huruf Kecil

Prosesor transformasi huruf kecil mengubah input teks menjadi huruf kecil. Misalnya, dengan masukan “The Quick Brown Fox Jumps Over the Lazy Dog”, prosesor akan menampilkan “rubah coklat cepat melompat di atas lazy dog”.

Untuk menerapkan transformasi huruf kecil ke variabel `var1`:

```
“huruf kecil (var1)”
```

Hapus Transformasi Tanda Baca

Amazon ML secara implisit membagi input yang ditandai sebagai teks dalam skema data pada spasi putih. Tanda baca dalam string berakhir dengan token kata yang berdampingan, atau sebagai token terpisah seluruhnya, tergantung pada spasi di sekitarnya. Jika ini tidak diinginkan, transformasi penghapusan tanda baca dapat digunakan untuk menghapus simbol tanda baca dari fitur yang dihasilkan. Misalnya, mengingat string “Selamat datang di AML - tolong kencangkan sabuk pengaman Anda!”, kumpulan token berikut dihasilkan secara implisit:

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

Menerapkan prosesor penghapusan tanda baca ke string ini menghasilkan set ini:

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

Perhatikan bahwa hanya tanda baca awalan dan sufiks yang dihapus. Tanda baca yang muncul di tengah token, misalnya tanda hubung di “sabuk pengaman”, tidak dihapus.

Untuk menerapkan penghapusan tanda baca ke variabel `var1`:

```
“no_punct (var1)”
```

Transformasi Binning Kuantil

Prosesor binning kuantil mengambil dua input, variabel numerik dan parameter yang disebut nomor bin, dan mengeluarkan variabel kategoris. Tujuannya adalah untuk menemukan non-linearitas dalam distribusi variabel dengan mengelompokkan nilai yang diamati bersama-sama.

Dalam banyak kasus, hubungan antara variabel numerik dan target tidak linier (nilai variabel numerik tidak meningkat atau menurun secara monoton dengan target). Dalam kasus seperti itu, mungkin berguna untuk memasukkan fitur numerik ke dalam fitur kategoris yang mewakili rentang fitur numerik yang berbeda. Setiap nilai fitur kategoris (bin) kemudian dapat dimodelkan sebagai memiliki hubungan liniernya sendiri dengan target. Misalnya, katakanlah Anda tahu bahwa fitur numerik kontinu `account_age` tidak berkorelasi linier dengan kemungkinan untuk membeli buku. Anda dapat memasukkan usia ke dalam fitur kategoris yang mungkin dapat menangkap hubungan dengan target dengan lebih akurat.

Prosesor binning kuantil dapat digunakan untuk menginstruksikan Amazon ML untuk menetapkan `n` bin dengan ukuran yang sama berdasarkan distribusi semua nilai input dari variabel usia, dan kemudian mengganti setiap angka dengan token teks yang berisi bin. Jumlah optimal naman untuk variabel numerik tergantung pada karakteristik variabel dan hubungannya dengan target, dan ini paling baik ditentukan melalui eksperimen. Amazon ML menyarankan nomor bin optimal untuk fitur numerik berdasarkan statistik data dalam [Resep yang Disarankan](#).

Anda dapat meminta antara 5 dan 1000 naman kuantil untuk dihitung untuk variabel input numerik apa pun.

Untuk contoh berikut menunjukkan bagaimana untuk menghitung dan menggunakan 50 bin di tempat variabel numerik `var1`:

```
"kuantile_bin (var1, 50)"
```

Transformasi Normalisasi

Transformator normalisasi menormalkan variabel numerik untuk memiliki rata-rata nol dan varians satu. Normalisasi variabel numerik dapat membantu proses pembelajaran jika terdapat perbedaan rentang yang sangat besar antara variabel numerik karena variabel dengan besaran tertinggi dapat mendominasi model ML, tidak peduli apakah fitur tersebut informatif sehubungan dengan target atau tidak.

Untuk menerapkan transformasi ini ke variabel numerik `var1`, tambahkan ini ke resep:

menormalkan (var1)

Transformator ini juga dapat mengambil kelompok variabel numerik yang ditentukan pengguna atau grup yang telah ditentukan sebelumnya untuk semua variabel numerik (ALL_NUMERIC) sebagai masukan:

menormalkan (ALL_NUMERIC)

Catatan

Tidak wajib menggunakan prosesor normalisasi untuk variabel numerik.

Transformasi Produk Cartesien

Transformasi Cartesien menghasilkan permutasi dari dua atau lebih teks atau variabel input kategoris. Transformasi ini digunakan ketika interaksi antar variabel dicurigai. Misalnya, pertimbangkan kumpulan data pemasaran bank yang digunakan dalam Tutorial: Menggunakan Amazon ML untuk Memprediksi Respons terhadap Penawaran Pemasaran. Dengan menggunakan kumpulan data ini, kami ingin memprediksi apakah seseorang akan merespons positif promosi bank, berdasarkan informasi ekonomi dan demografis. Kami mungkin menduga bahwa jenis pekerjaan orang tersebut agak penting (mungkin ada korelasi antara dipekerjakan di bidang tertentu dan memiliki uang yang tersedia), dan tingkat pendidikan tertinggi yang dicapai juga penting. Kita mungkin juga memiliki intuisi yang lebih dalam bahwa ada sinyal kuat dalam interaksi kedua variabel ini — misalnya, bahwa promosi ini sangat cocok untuk pelanggan yang merupakan pengusaha yang memperoleh gelar sarjana.

Transformasi produk Cartesien mengambil variabel kategoris atau teks sebagai input, dan menghasilkan fitur baru yang menangkap interaksi antara variabel input ini. Secara khusus, untuk setiap contoh pelatihan, itu akan membuat kombinasi fitur, dan menambahkannya sebagai fitur mandiri. Sebagai contoh, katakanlah baris input kita yang disederhanakan terlihat seperti ini:

target, pendidikan, pekerjaan

0, university.degree, teknisi

0, high.school, layanan

1, university.degree, admin

Jika kita menentukan bahwa transformasi Cartesien akan diterapkan pada bidang pendidikan dan pekerjaan variabel kategoris, fitur yang dihasilkan `education_job_interaction` akan terlihat seperti ini:

target, education_job_interaction

0, university.degree_technician

0, high.school_services

1, university.degree_admin

Transformasi Cartesian bahkan lebih kuat dalam hal mengerjakan urutan token, seperti halnya ketika salah satu argumennya adalah variabel teks yang secara implisit atau eksplisit dibagi menjadi token. Misalnya, pertimbangkan tugas mengklasifikasikan buku sebagai buku teks atau tidak. Secara intuitif, kita mungkin berpikir bahwa ada sesuatu tentang judul buku yang dapat memberi tahu kita bahwa itu adalah buku teks (kata-kata tertentu mungkin lebih sering muncul dalam judul buku teks), dan kita mungkin juga berpikir bahwa ada sesuatu tentang pengikatan buku yang bersifat prediktif (buku teks lebih cenderung menjadi hardcover), tetapi sebenarnya kombinasi dari beberapa kata dalam judul dan pengikatan yang paling prediktif. Untuk contoh dunia nyata, tabel berikut menunjukkan hasil penerapan prosesor Cartesian ke variabel input yang mengikat dan judul:

Buku Teks	Judul	Mengikat	Produk Cartesian dari no_punct (Judul) dan Binding
1	Ekonomi: Prinsip, Masalah, Kebijakan	Hardcover	{"Economics_Hardcover", "Prinsip_Hardcover", "Problems_Hardcover", "Policies_Hardcover"}
0	Hati yang Tak Terlihat: Romantis Ekonomi	Softcover	{"The_Softcover", "Invisible_Softcover", "Heart_Softcover", "An_Softcover", "Economics_Softcover", "Romance_Softcover"}
0	Menyenangkan Dengan Masalah	Softcover	{"Fun_Softcover", "Dengan_Softcover", "Problems_Softcover"}

Contoh berikut menunjukkan bagaimana menerapkan transformator Cartesian untuk var1 dan var2:

kartesius (var1, var2)

Penataan Ulang Data

Fungsionalitas penataan ulang data memungkinkan Anda membuat sumber data yang hanya didasarkan pada sebagian data input yang ditunjukkannya. Misalnya, saat Anda membuat Model ML

menggunakan wizard Buat Model ML di konsol Amazon, dan memilih opsi evaluasi default, Amazon ML secara otomatis menyimpan 30% data Anda untuk evaluasi model ML, dan menggunakan 70% lainnya untuk pelatihan. Fungsionalitas ini diaktifkan oleh fitur Penataan Ulang Data Amazon ML.

Jika Anda menggunakan Amazon MLAPI untuk membuat sumber data, Anda dapat menentukan bagian mana dari data input sumber data baru yang akan didasarkan. Anda melakukan ini dengan meneruskan instruksi dalam `DataRearrangement` parameter ke `CreateDataSourceFromS3`, `CreateDataSourceFromRedshift` atau `CreateDataSourceFromRDS` APIs. Isi `DataRearrangement` string adalah string JSON yang berisi lokasi awal dan akhir data Anda, dinyatakan sebagai persentase, tanda pelengkap, dan strategi pemisahan. Misalnya, `DataRearrangement` string berikut menentukan bahwa 70% pertama dari data akan digunakan untuk membuat sumber data:

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

DataRearrangement Parameter

Untuk mengubah cara Amazon ML membuat sumber data, gunakan parameter ikuti.

PercentBegin (Opsional)

Gunakan `percentBegin` untuk menunjukkan di mana data untuk sumber data dimulai. Jika Anda tidak menyertakan `percentBegin` dan `percentEnd`, Amazon ML menyertakan semua data saat membuat sumber data.

Nilai yang valid adalah 0 untuk 100, inklusif.

PercentEnd (Opsional)

Gunakan `percentEnd` untuk menunjukkan di mana data untuk sumber data berakhir. Jika Anda tidak menyertakan `percentBegin` dan `percentEnd`, Amazon ML menyertakan semua data saat membuat sumber data.

Nilai yang valid adalah 0 untuk 100, inklusif.

Pelengkap (Opsional)

`complementParameter` memberitahu Amazon ML untuk menggunakan data yang tidak termasuk dalam rentang `percentBegin` `percentEnd` untuk membuat sumber data. `complementParameter` ini berguna jika Anda perlu membuat sumber data pelengkap untuk pelatihan dan evaluasi. Untuk membuat sumber data komplementer, gunakan nilai yang sama untuk `percentBegin` dan `percentEnd`, bersama dengan parameternya. `complement`

Misalnya, dua sumber data berikut tidak berbagi data apa pun, dan dapat digunakan untuk melatih dan mengevaluasi model. Sumber data pertama memiliki 25 persen data, dan yang kedua memiliki 75 persen data.

Sumber data untuk evaluasi:

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

Sumber data untuk pelatihan:

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

Nilai yang valid adalah `true` dan `false`.

Strategi (Opsional)

Untuk mengubah cara Amazon ML membagi data untuk sumber data, gunakan parameternya. `strategy`

Nilai default untuk `strategy` parameter adalah `sequential`, artinya Amazon ML mengambil semua catatan data antara `percentBegin` dan `percentEnd` parameter untuk sumber data, dalam urutan bahwa catatan muncul dalam data input

Dua `DataRearrangement` baris berikut adalah contoh sumber data pelatihan dan evaluasi yang diurutkan secara berurutan:

```
Sumber data untuk evaluasi: {"splitting":{"percentBegin":70, "percentEnd":100, "strategy":"sequential"}}
```

```
Sumber data untuk pelatihan: {"splitting":{"percentBegin":70, "percentEnd":100, "strategy":"sequential", "complement":"true"}}
```

Untuk membuat sumber data dari pemilihan data secara acak, atur `strategy` parameter ke `random` dan berikan string yang digunakan sebagai nilai benih untuk pemisahan data acak (misalnya, Anda dapat menggunakan jalur S3 ke data Anda sebagai string benih acak). Jika Anda memilih strategi pemisahan acak, Amazon ML menetapkan setiap baris data nomor pseudo-acak, dan kemudian memilih baris yang memiliki nomor yang ditetapkan antara `percentBegin` `percentEnd`. Nomor pseudo-acak ditetapkan menggunakan byte offset sebagai benih, sehingga mengubah data menghasilkan pemisahan yang berbeda. Setiap pemesanan yang ada dipertahankan. Strategi pemisahan acak memastikan bahwa variabel dalam data pelatihan dan evaluasi didistribusikan dengan cara yang sama. Ini berguna dalam kasus di mana data input mungkin memiliki urutan pengurutan implisit, yang jika tidak akan menghasilkan sumber data pelatihan dan evaluasi yang berisi catatan data yang tidak serupa.

Dua `DataRearrangement` baris berikut adalah contoh sumber data pelatihan dan evaluasi yang tidak diurutkan secara berurutan:

Sumber data untuk evaluasi:

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

Sumber data untuk pelatihan:

```
{
```

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

Nilai yang valid adalah `sequential` dan `random`.

(Opsional) Strategi: `RandomSeed`

Amazon ML menggunakan `RandomSeed` untuk membagi data. Benih default untuk API adalah string kosong. Untuk menentukan benih untuk strategi pemisahan acak, berikan string. Untuk informasi selengkapnya tentang benih acak, lihat [Memisahkan Data Anda Secara Acak](#) di Panduan Pengembang Amazon Machine Learning.

Untuk contoh kode yang menunjukkan cara menggunakan validasi silang dengan Amazon, buka Sampel [Machine Learning Github](#).

Mengevaluasi Model ML

Anda harus selalu mengevaluasi model untuk menentukan apakah itu akan melakukan pekerjaan yang baik dalam memprediksi target pada data baru dan masa depan. Karena instance future memiliki nilai target yang tidak diketahui, Anda perlu memeriksa metrik akurasi model ML pada data yang sudah Anda ketahui jawabannya, dan gunakan penilaian ini sebagai proxy untuk akurasi prediktif pada data future.

Untuk mengevaluasi model dengan benar, Anda menyimpan sampel data yang telah diberi label dengan target (kebenaran dasar) dari sumber data pelatihan. Mengevaluasi akurasi prediktif model ML dengan data yang sama yang digunakan untuk pelatihan tidak berguna, karena memberikan penghargaan kepada model yang dapat “mengingat” data pelatihan, sebagai lawan dari generalisasi darinya. Setelah Anda selesai melatih model ML, Anda mengirimkan model pengamatan yang ditahan yang Anda ketahui nilai targetnya. Anda kemudian membandingkan prediksi yang dikembalikan oleh model ML dengan nilai target yang diketahui. Terakhir, Anda menghitung metrik ringkasan yang memberi tahu Anda seberapa baik nilai prediksi dan nilai sebenarnya cocok.

Di Amazon ML, Anda mengevaluasi model ML dengan membuat evaluasi. Untuk membuat evaluasi untuk model ML, Anda memerlukan model ML yang ingin Anda evaluasi, dan Anda memerlukan data berlabel yang tidak digunakan untuk pelatihan. Pertama, buat sumber data untuk evaluasi dengan membuat sumber data Amazon MS dengan data yang ditahan. Data yang digunakan dalam evaluasi harus memiliki skema yang sama dengan data yang digunakan dalam pelatihan dan menyertakan nilai aktual untuk variabel target.

Jika semua data Anda berada dalam satu file atau direktori, Anda dapat menggunakan konsol Amazon ML untuk membagi data. Jalur default dalam wizard model Create ML memisahkan sumber data input dan menggunakan 70% pertama untuk sumber data pelatihan dan 30% sisanya untuk sumber data evaluasi. Anda juga dapat menyesuaikan rasio split dengan menggunakan opsi Kustom di wizard model Create ML, di mana Anda dapat memilih untuk memilih sampel 70% acak untuk pelatihan dan menggunakan 30% sisanya untuk evaluasi. Untuk menentukan rasio pemisahan kustom lebih lanjut, gunakan string penataan ulang data di [Create Datasource](#) API. Setelah Anda memiliki sumber data evaluasi dan model ML, Anda dapat membuat evaluasi dan meninjau hasil evaluasi.

Topik

- [Wawasan Model ML](#)
- [Wawasan Model Biner](#)

- [Wawasan Model Multiclass](#)
- [Wawasan Model Regresi](#)
- [Mencegah Overfitting](#)
- [Validasi Lintas](#)
- [Peringatan Evaluasi](#)

Wawasan Model ML

Saat Anda mengevaluasi model ML, Amazon ML menyediakan metrik standar industri dan sejumlah wawasan untuk meninjau akurasi prediktif model Anda. Di Amazon ML, hasil evaluasi berisi yang berikut:

- Metrik akurasi prediksi untuk melaporkan keberhasilan keseluruhan model
- Visualisasi untuk membantu mengeksplorasi keakuratan model Anda di luar metrik akurasi prediksi
- Kemampuan untuk meninjau dampak pengaturan ambang skor (hanya untuk klasifikasi biner)
- Peringatan tentang kriteria untuk memeriksa validitas evaluasi

Pilihan metrik dan visualisasi tergantung pada jenis model ML yang Anda evaluasi. Penting untuk meninjau visualisasi ini untuk memutuskan apakah model Anda berkinerja cukup baik untuk memenuhi kebutuhan bisnis Anda.

Wawasan Model Biner

Menafsirkan Prediksi

Output aktual dari banyak algoritma klasifikasi biner adalah skor prediksi. Skor menunjukkan kepastian sistem bahwa pengamatan yang diberikan termasuk dalam kelas positif (nilai target sebenarnya adalah 1). Model klasifikasi biner di Amazon ML menghasilkan skor yang berkisar dari 0 hingga 1. Sebagai konsumen skor ini, untuk membuat keputusan tentang apakah pengamatan harus diklasifikasikan sebagai 1 atau 0, Anda menafsirkan skor dengan memilih ambang klasifikasi, atau cut-off, dan membandingkan skor terhadapnya. Setiap pengamatan dengan skor lebih tinggi dari cut-off diprediksi sebagai target= 1, dan skor yang lebih rendah dari cut-off diprediksi sebagai target= 0.

Di Amazon ML, batas skor default adalah 0,5. Anda dapat memilih untuk memperbarui cut-off ini agar sesuai dengan kebutuhan bisnis Anda. Anda dapat menggunakan visualisasi di konsol untuk memahami bagaimana pilihan cut-off akan memengaruhi aplikasi Anda.

Mengukur Akurasi Model ML

Amazon ML menyediakan metrik akurasi standar industri untuk model klasifikasi biner yang disebut Area Under the (Receiver Operating Characteristic) Curve (AUC). AUC mengukur kemampuan model untuk memprediksi skor yang lebih tinggi untuk contoh positif dibandingkan dengan contoh negatif. Karena tidak tergantung pada batas skor, Anda bisa merasakan akurasi prediksi model Anda dari metrik AUC tanpa memilih ambang batas.


Metrik AUC mengembalikan nilai desimal dari 0 menjadi 1. Nilai AUC mendekati 1 menunjukkan model ML yang sangat akurat. Nilai mendekati 0,5 menunjukkan model ML yang tidak lebih baik daripada menebak secara acak. Nilai mendekati 0 tidak biasa dilihat, dan biasanya menunjukkan masalah dengan data. Pada dasarnya, AUC mendekati 0 mengatakan bahwa model ML telah mempelajari pola yang benar, tetapi menggunakannya untuk membuat prediksi yang dibalik dari kenyataan ('0 diprediksi sebagai '1 dan sebaliknya). Untuk informasi lebih lanjut tentang AUC, buka halaman [karakteristik operasi Receiver](#) di Wikipedia.

Metrik AUC dasar untuk model biner adalah 0,5. Ini adalah nilai untuk model ML hipotetis yang secara acak memprediksi jawaban 1 atau 0. Model ML biner Anda harus berkinerja lebih baik daripada nilai ini agar mulai berharga.

Menggunakan Visualisasi Kinerja

Untuk menjelajahi keakuratan model ML, Anda dapat meninjau grafik di halaman Evaluasi di konsol Amazon Amazon. Halaman ini menunjukkan kepada Anda dua histogram: a) histogram skor untuk positif aktual (targetnya adalah 1) dan b) histogram skor untuk negatif aktual (targetnya adalah 0) dalam data evaluasi.

Model ML yang memiliki akurasi prediktif yang baik akan memprediksi skor yang lebih tinggi ke 1s aktual dan skor yang lebih rendah ke 0 aktual. Model yang sempurna akan memiliki dua histogram di dua ujung sumbu x yang berbeda yang menunjukkan bahwa positif aktual semuanya mendapat skor tinggi dan negatif aktual semuanya mendapat skor rendah. Namun, model ML membuat kesalahan, dan grafik tipikal akan menunjukkan bahwa kedua histogram tumpang tindih pada skor tertentu. Model berkinerja sangat buruk tidak akan dapat membedakan antara kelas positif dan negatif, dan kedua kelas akan memiliki histogram yang sebagian besar tumpang tindih.



Dengan menggunakan visualisasi, Anda dapat mengidentifikasi jumlah prediksi yang termasuk dalam dua jenis prediksi yang benar dan dua jenis prediksi yang salah.

Prediksi yang Benar

- True positive (TP): Amazon ML memprediksi nilainya sebagai 1, dan nilai sebenarnya adalah 1.
- True negative (TN): Amazon ML memprediksi nilainya sebagai 0, dan nilai sebenarnya adalah 0.

Prediksi yang Salah

- Positif palsu (FP): Amazon ML memprediksi nilainya sebagai 1, tetapi nilai sebenarnya adalah 0.
- False negative (FN): Amazon ML memprediksi nilainya sebagai 0, tetapi nilai sebenarnya adalah 1.

i Note

Jumlah TP, TN, FP, dan FN tergantung pada ambang skor yang dipilih, dan mengoptimalkan salah satu dari angka-angka ini berarti membuat tradeoff pada yang lain. Jumlah yang tinggi TPs biasanya menghasilkan jumlah yang tinggi FPs dan jumlah yang rendah TNs.

Menyesuaikan Cut-off Skor

Model ML bekerja dengan menghasilkan skor prediksi numerik, dan kemudian menerapkan cut-off untuk mengubah skor ini menjadi label biner 0/1. Dengan mengubah batas skor, Anda dapat menyesuaikan perilaku model saat membuat kesalahan. Pada halaman Evaluasi di konsol Amazon

Amazon, Anda dapat meninjau dampak dari berbagai batas skor, dan Anda dapat menyimpan batas skor yang ingin Anda gunakan untuk model Anda.

Saat Anda menyesuaikan ambang batas skor, amati trade-off antara dua jenis kesalahan. Memindahkan cut-off ke kiri menangkap lebih banyak positif sejati, tetapi trade-off adalah peningkatan jumlah kesalahan positif palsu. Memindahkannya ke kanan menangkap lebih sedikit kesalahan positif palsu, tetapi trade-off adalah bahwa ia akan kehilangan beberapa positif sejati. Untuk aplikasi prediktif Anda, Anda membuat keputusan jenis kesalahan mana yang lebih dapat ditoleransi dengan memilih skor cut-off yang sesuai.

Meninjau Metrik Lanjutan

Amazon ML menyediakan metrik tambahan berikut untuk mengukur akurasi prediktif model ML: akurasi, presisi, ingatan, dan tingkat positif palsu.

Akurasi

Akurasi (ACC) mengukur fraksi prediksi yang benar. Kisarannya adalah 0 hingga 1. Nilai yang lebih besar menunjukkan akurasi prediksi yang lebih baik:

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

presisi

Presisi mengukur fraksi positif aktual di antara contoh-contoh yang diprediksi positif. Kisarannya adalah 0 hingga 1. Nilai yang lebih besar menunjukkan akurasi prediksi yang lebih baik:

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

Ingat

Ingat mengukur fraksi positif aktual yang diprediksi positif. Kisarannya adalah 0 hingga 1. Nilai yang lebih besar menunjukkan akurasi prediksi yang lebih baik:

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

Tingkat Positif Palsu

Tingkat positif palsu (FPR) mengukur tingkat alarm palsu atau fraksi negatif aktual yang diprediksi positif. Kisarannya adalah 0 hingga 1. Nilai yang lebih kecil menunjukkan akurasi prediksi yang lebih baik:

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

Bergantung pada masalah bisnis Anda, Anda mungkin lebih tertarik pada model yang berkinerja baik untuk subset tertentu dari metrik ini. Misalnya, dua aplikasi bisnis mungkin memiliki persyaratan yang sangat berbeda untuk model ML-nya:

- Satu aplikasi mungkin perlu sangat yakin tentang prediksi positif yang sebenarnya positif (presisi tinggi), dan mampu salah mengklasifikasikan beberapa contoh positif sebagai negatif (ingatan sedang).
- Aplikasi lain mungkin perlu memprediksi dengan benar sebanyak mungkin contoh positif (ingatan tinggi), dan akan menerima beberapa contoh negatif yang salah diklasifikasikan sebagai positif (presisi sedang).

Amazon ML memungkinkan Anda memilih batas skor yang sesuai dengan nilai tertentu dari salah satu metrik lanjutan sebelumnya. Ini juga menunjukkan pengorbanan yang terjadi dengan mengoptimalkan satu metrik. Misalnya, jika Anda memilih cut-off yang sesuai dengan presisi tinggi, Anda biasanya harus menukarnya dengan penarikan yang lebih rendah.

Note

Anda harus menyimpan batas skor agar dapat diterapkan dalam mengklasifikasikan prediksi masa depan berdasarkan model ML Anda.

Wawasan Model Multiclass

Menafsirkan Prediksi

Output aktual dari algoritma klasifikasi multiclass adalah serangkaian skor prediksi. Skor menunjukkan kepastian model bahwa pengamatan yang diberikan milik masing-masing kelas. Tidak seperti masalah klasifikasi biner, Anda tidak perlu memilih batas skor untuk membuat prediksi. Jawaban yang diprediksi adalah kelas (misalnya, label) dengan skor prediksi tertinggi.

Mengukur Akurasi Model ML

Metrik tipikal yang digunakan dalam multiclass sama dengan metrik yang digunakan dalam kasus klasifikasi biner setelah meratakannya di semua kelas. Di Amazon ML, skor F1 rata-rata makro digunakan untuk mengevaluasi akurasi prediktif metrik multiclass.

Skor F1 Rata-rata Makro

Skor F1 adalah metrik klasifikasi biner yang mempertimbangkan presisi dan ingatan metrik biner. Ini adalah mean harmonik antara presisi dan ingatan. Kisarannya adalah 0 hingga 1. Nilai yang lebih besar menunjukkan akurasi prediksi yang lebih baik:

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

Skor F1 rata-rata makro adalah rata-rata tidak tertimbang dari skor F1 atas semua kelas dalam kasus multiclass. Itu tidak memperhitungkan frekuensi terjadinya kelas dalam dataset evaluasi. Nilai yang lebih besar menunjukkan akurasi prediksi yang lebih baik. Contoh berikut menunjukkan kelas K dalam sumber data evaluasi:

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

Skor F1 Rata-rata Makro Dasar


Amazon ML menyediakan metrik dasar untuk model multiclass. Ini adalah skor F1 rata-rata makro untuk model multiclass hipotetis yang akan selalu memprediksi kelas yang paling sering sebagai jawabannya. Misalnya, jika Anda memprediksi genre film dan genre yang paling umum dalam data pelatihan Anda adalah Romance, maka model dasar akan selalu memprediksi genre sebagai Romance. Anda akan membandingkan model MLmu dengan baseline ini untuk memvalidasi jika model MLmu lebih baik daripada model ML yang memprediksi jawaban konstan ini.

Menggunakan Visualisasi Kinerja

Amazon ML menyediakan matriks kebingungan sebagai cara untuk memvisualisasikan keakuratan model prediktif klasifikasi multikelas. Matriks kebingungan menggambarkan dalam tabel jumlah atau persentase prediksi yang benar dan salah untuk setiap kelas dengan membandingkan kelas prediksi pengamatan dan kelas sebenarnya.

Misalnya, jika Anda mencoba mengklasifikasikan film ke dalam genre, model prediktif mungkin memprediksi bahwa genre (kelas) adalah Romance. Namun, genre sebenarnya mungkin Thriller.

Saat Anda mengevaluasi keakuratan model ML klasifikasi multiclass, Amazon ML mengidentifikasi kesalahan klasifikasi ini dan menampilkan hasilnya dalam matriks kebingungan, seperti yang ditunjukkan pada ilustrasi berikut.



Informasi berikut ditampilkan dalam matriks kebingungan:

- Jumlah prediksi yang benar dan salah untuk setiap kelas: Setiap baris dalam matriks kebingungan sesuai dengan metrik untuk salah satu kelas yang sebenarnya. Sebagai contoh, baris pertama menunjukkan bahwa untuk film yang sebenarnya dalam genre Romance, model Multiclass MLM mendapatkan prediksi yang tepat untuk lebih dari 80% kasus. Ini salah memprediksi genre sebagai Thriller untuk kurang dari 20% kasus, dan Petualangan untuk kurang dari 20% kasus.
- Skor F1 berdasarkan kelas: Kolom terakhir menunjukkan skor F1 untuk masing-masing kelas.
- Frekuensi kelas sejati dalam data evaluasi: Kolom kedua hingga terakhir menunjukkan bahwa dalam kumpulan data evaluasi, 57,92% pengamatan dalam data evaluasi adalah Romance, 21,23% adalah Thriller, dan 20,85% adalah Petualangan.
- Frekuensi kelas yang diprediksi untuk data evaluasi: Baris terakhir menunjukkan frekuensi setiap kelas dalam prediksi. 77,56% pengamatan diprediksi sebagai Romantis, 9,33% diprediksi sebagai Thriller, dan 13,12% diprediksi sebagai Petualangan.

Konsol Amazon ML menyediakan tampilan visual yang mengakomodasi hingga 10 kelas dalam matriks kebingungan, terdaftar dalam urutan kelas yang paling sering hingga yang paling tidak sering dalam data evaluasi. Jika data evaluasi Anda memiliki lebih dari 10 kelas, Anda akan melihat 9 kelas teratas yang paling sering terjadi dalam matriks kebingungan, dan semua kelas lainnya akan diciutkan menjadi kelas yang disebut “orang lain.” Amazon ML juga menyediakan kemampuan untuk mengunduh matriks kebingungan penuh melalui tautan di halaman visualisasi multiclass.

Wawasan Model Regresi

Menafsirkan Prediksi

Output dari model regresi ML adalah nilai numerik untuk prediksi model target. Misalnya, jika Anda memprediksi harga rumah, prediksi model bisa menjadi nilai seperti 254.013.

Note

Rentang prediksi dapat berbeda dari kisaran target dalam data pelatihan. Misalnya, katakanlah Anda memprediksi harga rumah, dan target dalam data pelatihan memiliki nilai dalam kisaran 0 hingga 450.000. Target yang diprediksi tidak perlu berada dalam kisaran yang sama, dan mungkin mengambil nilai positif (lebih besar dari 450.000) atau nilai negatif (kurang dari nol). Penting untuk merencanakan cara mengatasi nilai prediksi yang berada di luar rentang yang dapat diterima untuk aplikasi Anda.

Mengukur Akurasi Model ML

Untuk tugas regresi, Amazon ML menggunakan metrik root mean square error (RMSE) standar industri. Ini adalah ukuran jarak antara target numerik yang diprediksi dan jawaban numerik aktual (kebenaran dasar). Semakin kecil nilai RMSE, semakin baik akurasi prediktif model. Model dengan prediksi yang benar sempurna akan memiliki RMSE 0. Contoh berikut menunjukkan data evaluasi yang berisi catatan N:

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

Baseline RMSE

Amazon ML menyediakan metrik dasar untuk model regresi. Ini adalah RMSE untuk model regresi hipotetis yang akan selalu memprediksi rata-rata target sebagai jawabannya. Misalnya, jika Anda memprediksi usia pembeli rumah dan usia rata-rata untuk pengamatan dalam data pelatihan Anda adalah 35, model dasar akan selalu memprediksi jawabannya sebagai 35. Anda akan membandingkan model MLmu dengan baseline ini untuk memvalidasi jika model MLmu lebih baik daripada model ML yang memprediksi jawaban konstan ini.

Menggunakan Visualisasi Kinerja

Merupakan praktik umum untuk meninjau residu untuk masalah regresi. Sisa untuk pengamatan dalam data evaluasi adalah perbedaan antara target sebenarnya dan target yang diprediksi. Residu mewakili bagian target yang tidak dapat diprediksi oleh model. Sisa positif menunjukkan bahwa model meremehkan target (target sebenarnya lebih besar dari target yang diprediksi). Sisa negatif menunjukkan perkiraan yang terlalu tinggi (target sebenarnya lebih kecil dari target yang diprediksi). Histogram residu pada data evaluasi ketika didistribusikan dalam bentuk lonceng dan berpusat pada nol menunjukkan bahwa model membuat kesalahan secara acak dan tidak secara sistematis di atas atau di bawah memprediksi rentang nilai target tertentu. Jika residu tidak membentuk bentuk lonceng berpusat nol, ada beberapa struktur dalam kesalahan prediksi model. Menambahkan lebih banyak variabel ke model dapat membantu model menangkap pola yang tidak ditangkap oleh model saat ini. Ilustrasi berikut menunjukkan residu yang tidak berpusat di sekitar nol.

Select Bin Width:


50

20

10

5

2



Mencegah Overfitting

Saat membuat dan melatih model ML, tujuannya adalah untuk memilih model yang membuat prediksi terbaik, yang berarti memilih model dengan pengaturan terbaik (pengaturan model ML atau hiperparameter). Di Amazon Machine Learning, ada empat hiperparameter yang dapat Anda atur: jumlah pass, regularisasi, ukuran model, dan jenis shuffle. Namun, jika Anda memilih pengaturan parameter model yang menghasilkan kinerja prediktif “terbaik” pada data evaluasi, Anda mungkin terlalu cocok dengan model Anda. Overfitting terjadi ketika model telah menghafal pola yang terjadi dalam sumber data pelatihan dan evaluasi, tetapi gagal untuk menggeneralisasi pola dalam data. Ini sering terjadi ketika data pelatihan mencakup semua data yang digunakan dalam evaluasi. Model overfitted bekerja dengan baik selama evaluasi, tetapi gagal membuat prediksi yang akurat pada data yang tidak terlihat.

Untuk menghindari pemilihan model overfitted sebagai model terbaik, Anda dapat memesan data tambahan untuk memvalidasi kinerja model ML. Misalnya, Anda dapat membagi data Anda menjadi 60 persen untuk pelatihan, 20 persen untuk evaluasi, dan tambahan 20 persen untuk validasi. Setelah memilih parameter model yang berfungsi dengan baik untuk data evaluasi, Anda

menjalankan evaluasi kedua dengan data validasi untuk melihat seberapa baik kinerja model ML pada data validasi. Jika model memenuhi harapan Anda pada data validasi, maka model tersebut tidak sesuai dengan data.


Menggunakan kumpulan data ketiga untuk validasi membantu Anda memilih parameter model ML yang sesuai untuk mencegah overfitting. Namun, menyimpan data dari proses pelatihan untuk evaluasi dan validasi membuat lebih sedikit data yang tersedia untuk pelatihan. Ini terutama masalah dengan kumpulan data kecil karena selalu terbaik untuk menggunakan data sebanyak mungkin untuk pelatihan. Untuk mengatasi masalah ini, Anda dapat melakukan validasi silang. Untuk informasi tentang validasi silang, lihat [Validasi Lintas](#)

Validasi Lintas

Validasi silang adalah teknik untuk mengevaluasi model ML dengan melatih beberapa model ML pada himpunan bagian dari data input yang tersedia dan mengevaluasinya pada subset data yang saling melengkapi. Gunakan validasi silang untuk mendeteksi overfitting, yaitu gagal menggeneralisasi pola.

Di Amazon, Anda dapat menggunakan metode validasi silang k-fold untuk melakukan validasi silang. Dalam validasi silang k-fold, Anda membagi data input menjadi k subset data (juga dikenal sebagai lipatan). Anda melatih model ML pada semua kecuali satu ($k-1$) dari himpunan bagian, dan kemudian mengevaluasi model pada subset yang tidak digunakan untuk pelatihan. Proses ini diulang k kali, dengan subset berbeda disediakan untuk evaluasi (dan dikecualikan dari pelatihan) setiap kali.

Diagram berikut menunjukkan contoh himpunan bagian pelatihan dan himpunan bagian evaluasi komplementer yang dihasilkan untuk masing-masing dari empat model yang dibuat dan dilatih selama validasi silang 4 kali lipat. Model pertama menggunakan 25 persen data pertama untuk evaluasi, dan 75 persen sisanya untuk pelatihan. Model dua menggunakan subset kedua 25 persen (25 persen hingga 50 persen) untuk evaluasi, dan tiga himpunan bagian data sisanya untuk pelatihan, dan seterusnya.



Setiap model dilatih dan dievaluasi menggunakan sumber data pelengkap - data dalam sumber data evaluasi mencakup dan terbatas pada semua data yang tidak ada dalam sumber data pelatihan. Anda membuat sumber data untuk masing-masing himpunan bagian ini dengan `DataRearrangement` parameter `di`, dan `createDataSourceFromS3`, `createDataSourceFromRedShift` dan `createDataSourceFromRDS` APIs. Dalam `DataRearrangement` parameter, tentukan subset data mana yang akan disertakan dalam sumber data dengan menentukan di mana harus memulai dan mengakhiri setiap segmen. Untuk membuat sumber data pelengkap yang diperlukan untuk validasi silang 4 kali lipat, tentukan `DataRearrangement` parameter seperti yang ditunjukkan pada contoh berikut:

Model satu:

Sumber data untuk evaluasi:

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

Sumber data untuk pelatihan:

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

Model dua:

Sumber data untuk evaluasi:

```
{"splitting":{"percentBegin":25, "percentEnd":50}}
```

Sumber data untuk pelatihan:

```
{"splitting":{"percentBegin":25, "percentEnd":50, "complement":"true"}}
```

Model tiga:

Sumber data untuk evaluasi:

```
{"splitting":{"percentBegin":50, "percentEnd":75}}
```

Sumber data untuk pelatihan:

```
{"splitting":{"percentBegin":50, "percentEnd":75, "complement":"true"}}
```

Model empat:

Sumber data untuk evaluasi:

```
{"splitting":{"percentBegin":75, "percentEnd":100}}
```

Sumber data untuk pelatihan:

```
{"splitting":{"percentBegin":75, "percentEnd":100, "complement":"true"}}
```

Melakukan validasi silang 4 kali lipat menghasilkan empat model, empat sumber data untuk melatih model, empat sumber data untuk mengevaluasi model, dan empat evaluasi, satu untuk setiap model. Amazon ML menghasilkan metrik kinerja model untuk setiap evaluasi. Misalnya, dalam validasi silang 4 kali lipat untuk masalah klasifikasi biner, masing-masing evaluasi melaporkan metrik area di bawah kurva (AUC). Anda bisa mendapatkan ukuran kinerja keseluruhan dengan menghitung rata-rata dari empat metrik AUC. Untuk informasi tentang metrik AUC, lihat [Mengukur Akurasi Model ML](#).

Untuk kode contoh yang menunjukkan cara membuat validasi silang dan rata-rata skor model, lihat kode [sampel Amazon Amazon](#).

Menyesuaikan Model Anda

Setelah Anda memvalidasi silang model, Anda dapat menyesuaikan pengaturan untuk model berikutnya jika model Anda tidak sesuai dengan standar Anda. Untuk informasi lebih lanjut tentang overfitting, lihat [Model Fit: Underfitting vs. Overfitting](#). Untuk informasi lebih lanjut tentang regularisasi, lihat [Regularisasi](#) Untuk informasi selengkapnya tentang mengubah pengaturan regularisasi, lihat [Membuat Model ML dengan Opsi Kustom](#)

Peringatan Evaluasi

Amazon ML memberikan wawasan untuk membantu Anda memvalidasi apakah Anda mengevaluasi model dengan benar. Jika salah satu kriteria validasi tidak dipenuhi oleh evaluasi, konsol Amazon Amazon memberi tahu Anda dengan menampilkan kriteria validasi yang telah dilanggar, sebagai berikut.

- Evaluasi model ML dilakukan pada data yang ditahan

Amazon ML memberi tahu Anda jika Anda menggunakan sumber data yang sama untuk pelatihan dan evaluasi. Jika Anda menggunakan Amazon ML untuk membagi data Anda, Anda akan

memenuhi kriteria validitas ini. Jika Anda tidak menggunakan Amazon ML untuk membagi data Anda, pastikan untuk mengevaluasi model ML Anda dengan sumber data selain sumber data pelatihan.

- Data yang cukup digunakan untuk evaluasi model prediktif

Amazon ML memberi tahu Anda jika jumlah pengamatan/catatan dalam data evaluasi Anda kurang dari 10% jumlah pengamatan yang Anda miliki dalam sumber data pelatihan Anda. Untuk mengevaluasi model Anda dengan benar, penting untuk menyediakan sampel data yang cukup besar. Kriteria ini memberikan pemeriksaan untuk memberi tahu Anda jika Anda menggunakan terlalu sedikit data. Jumlah data yang diperlukan untuk mengevaluasi model ML Anda bersifat subjektif. 10% dipilih di sini sebagai stop gap tanpa adanya ukuran yang lebih baik.

- Skema cocok

Amazon ML memberi tahu Anda jika skema untuk sumber data pelatihan dan evaluasi tidak sama. Jika Anda memiliki atribut tertentu yang tidak ada dalam sumber data evaluasi atau jika Anda memiliki atribut tambahan, Amazon ML akan menampilkan peringatan ini.

- Semua catatan dari file evaluasi digunakan untuk evaluasi kinerja model prediktif

Penting untuk mengetahui apakah semua catatan yang disediakan untuk evaluasi benar-benar digunakan untuk mengevaluasi model. Amazon ML memberi tahu Anda jika beberapa catatan dalam sumber data evaluasi tidak valid dan tidak disertakan dalam perhitungan metrik akurasi. Misalnya, jika variabel target hilang untuk beberapa pengamatan dalam sumber data evaluasi, Amazon ML tidak dapat memeriksa apakah prediksi model ML untuk pengamatan ini benar. Dalam hal ini, catatan dengan nilai target yang hilang dianggap tidak valid.

- Distribusi variabel target

Amazon ML menunjukkan distribusi atribut target dari sumber data pelatihan dan evaluasi sehingga Anda dapat meninjau apakah target didistribusikan dengan cara yang sama di kedua sumber data. Jika model dilatih pada data pelatihan dengan distribusi target yang berbeda dari distribusi target pada data evaluasi, maka kualitas evaluasi dapat menurun karena sedang dihitung pada data dengan statistik yang sangat berbeda. Yang terbaik adalah memiliki data yang didistribusikan dengan cara yang sama di atas data pelatihan dan evaluasi, dan mintalah kumpulan data ini meniru sebanyak mungkin data yang akan ditemui model saat membuat prediksi.

Jika peringatan ini terpicu, coba gunakan strategi pemisahan acak untuk membagi data menjadi sumber data pelatihan dan evaluasi. Dalam kasus yang jarang terjadi, peringatan ini mungkin secara keliru memperingatkan Anda tentang perbedaan distribusi target meskipun Anda membagi

data secara acak. Amazon ML menggunakan perkiraan statistik data untuk mengevaluasi distribusi data, kadang-kadang memicu peringatan ini karena kesalahan.

Menghasilkan dan Menafsirkan Prediksi

Amazon ML menyediakan dua mekanisme untuk menghasilkan prediksi: asinkron (berbasis batch) dan sinkron (). one-at-a-time

Gunakan prediksi asinkron, atau prediksi batch, ketika Anda memiliki sejumlah pengamatan dan ingin mendapatkan prediksi untuk pengamatan sekaligus. Proses ini menggunakan sumber data sebagai input, dan menghasilkan prediksi ke dalam file.csv yang disimpan dalam bucket S3 pilihan Anda. Anda harus menunggu hingga proses prediksi batch selesai sebelum Anda dapat mengakses hasil prediksi. Ukuran maksimum sumber data yang dapat diproses Amazon dalam file batch adalah 1 TB (sekitar 100 juta catatan). Jika sumber data Anda lebih besar dari 1 TB, pekerjaan Anda akan gagal dan Amazon ML akan mengembalikan kode kesalahan. Untuk mencegah hal ini, bagi data Anda menjadi beberapa batch. Jika catatan Anda biasanya lebih panjang, Anda akan mencapai batas 1 TB sebelum 100 juta catatan diproses. Dalam hal ini, kami menyarankan Anda menghubungi [dukungan AWS](#) untuk meningkatkan ukuran pekerjaan untuk prediksi batch Anda.

Gunakan prediksi sinkron, atau real-time, saat Anda ingin mendapatkan prediksi pada latensi rendah. API prediksi real-time menerima observasi input tunggal yang diserialkan sebagai string JSON, dan secara serempak mengembalikan prediksi dan metadata terkait sebagai bagian dari respons API. Anda dapat menjalankan API secara bersamaan lebih dari satu kali untuk mendapatkan prediksi sinkron secara paralel. Untuk informasi selengkapnya tentang batas throughput API prediksi real-time, lihat batas prediksi waktu nyata dalam referensi [Amazon ML.API](#).

Topik

- [Membuat Prediksi Batch](#)
- [Meninjau Metrik Prediksi Batch](#)
- [Membaca File Output Prediksi Batch](#)
- [Meminta Prediksi Waktu Nyata](#)

Membuat Prediksi Batch

Untuk membuat prediksi batch, Anda membuat BatchPrediction objek menggunakan konsol Amazon Machine Learning (Amazon ML) atau API. BatchPredictionObjek menjelaskan serangkaian prediksi yang dihasilkan Amazon ML dengan menggunakan model ML Anda dan serangkaian pengamatan masukan. Saat Anda membuat BatchPrediction objek, Amazon ML memulai alur kerja asinkron yang menghitung prediksi.

Anda harus menggunakan skema yang sama untuk sumber data yang Anda gunakan untuk mendapatkan prediksi batch dan sumber data yang Anda gunakan untuk melatih model ML yang Anda kueri untuk prediksi. Satu-satunya pengecualian adalah bahwa sumber data untuk prediksi batch tidak perlu menyertakan atribut target karena Amazon ML memprediksi target. Jika Anda memberikan atribut target, Amazon ML mengabaikan nilainya.

Membuat Prediksi Batch (Konsol)

Untuk membuat prediksi batch menggunakan konsol Amazon Amazon, gunakan wizard Buat Prediksi Batch.

Untuk membuat prediksi batch (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di dasbor Amazon, di bawah Objects, pilih Create new... , dan kemudian pilih prediksi Batch.
3. Pilih model Amazon ML yang ingin Anda gunakan untuk membuat prediksi batch.
4. Untuk mengonfirmasi bahwa Anda ingin menggunakan model ini, pilih Lanjutkan.
5. Pilih sumber data yang ingin Anda buat prediksi. Sumber data harus memiliki skema yang sama dengan model Anda, meskipun tidak perlu menyertakan atribut target.
6. Pilih Lanjutkan.
7. Untuk tujuan S3, ketik nama bucket S3 Anda.
8. Pilih Tinjau.
9. Tinjau pengaturan Anda dan pilih Buat prediksi batch.

Membuat Prediksi Batch (API)

Untuk membuat BatchPrediction objek menggunakan Amazon ML API, Anda harus memberikan parameter berikut:

ID Sumber Data

ID sumber data yang menunjuk ke pengamatan yang Anda inginkan prediksi. Misalnya, jika Anda ingin prediksi untuk data dalam file yang dipanggil `s3://examplebucket/input.csv`, Anda akan membuat objek sumber data yang menunjuk ke file data, dan kemudian meneruskan ID sumber data tersebut dengan parameter ini.

BatchPrediction ID

ID yang akan ditetapkan ke prediksi batch.

ID Model ML

ID model ML yang harus dikueri Amazon ML untuk prediksi.

Jenis Keluaran

URI bucket S3 untuk menyimpan output prediksi. Amazon ML harus memiliki izin untuk menulis data ke bucket ini.

`OutputUriParameter` harus merujuk ke jalur S3 yang diakhiri dengan karakter garis miring ('/'), seperti yang ditunjukkan pada contoh berikut:

```
s3://examplebucket/examplepath/
```

Untuk informasi tentang mengonfigurasi izin S3, lihat. [Memberikan Izin Amazon ML untuk Prediksi Output ke Amazon S3](#)

(Opsional) BatchPrediction Nama

(Opsional) Nama yang dapat dibaca manusia untuk prediksi batch Anda.

Meninjau Metrik Prediksi Batch

Setelah Amazon Machine Learning (Amazon Learning) membuat prediksi batch, Amazon Machine Learning menyediakan dua metrik `Records seen:` dan `Records failed to process` `Records seen` memberi tahu Anda berapa banyak catatan Amazon ML. melihat ketika menjalankan prediksi batch Anda. `Records failed to process` memberitahu Anda berapa banyak catatan Amazon ML tidak dapat memproses.

Untuk mengizinkan Amazon ML memproses catatan yang gagal, periksa pemformatan catatan dalam data yang digunakan untuk membuat sumber data Anda, dan pastikan semua atribut yang diperlukan ada dan semua data sudah benar. Setelah memperbaiki data, Anda dapat membuat ulang prediksi batch, atau membuat sumber data baru dengan catatan yang gagal, lalu membuat prediksi batch baru menggunakan sumber data baru.

Meninjau Metrik Prediksi Batch (Konsol)

Untuk melihat metrik di konsol Amazon Amazon, buka halaman ringkasan prediksi Batch dan lihat di bagian Info yang Diproses.

Meninjau Metrik dan Detail Prediksi Batch (API)

Anda dapat menggunakan Amazon ML APIs untuk mengambil detail tentang BatchPrediction objek, termasuk metrik rekaman. Amazon ML menyediakan panggilan API prediksi batch berikut:

- CreateBatchPrediction
- UpdateBatchPrediction
- DeleteBatchPrediction
- GetBatchPrediction
- DescribeBatchPredictions

Untuk informasi selengkapnya, lihat [Referensi API Amazon ML](#).

Membaca File Output Prediksi Batch

Lakukan langkah-langkah berikut untuk mengambil file keluaran prediksi batch:

1. Temukan file manifes prediksi batch.
2. Baca file manifes untuk menentukan lokasi file output.
3. Ambil file output yang berisi prediksi.
4. Menafsirkan isi dari file output. Isi akan bervariasi berdasarkan jenis model ML yang digunakan untuk menghasilkan prediksi.

Bagian berikut menjelaskan langkah-langkah secara lebih rinci.

Menemukan File Manifes Prediksi Batch

File manifes dari prediksi batch berisi informasi yang memetakan file input Anda ke file output prediksi.

Untuk menemukan file manifes, mulailah dengan lokasi keluaran yang Anda tentukan saat membuat objek prediksi batch. Anda dapat melakukan kueri objek prediksi batch yang telah selesai untuk mengambil lokasi S3 file ini dengan menggunakan [Amazon ML API](#) atau file. <https://console.aws.amazon.com/machinelearning/>

File manifes terletak di lokasi keluaran di jalur yang terdiri dari string statis `/batch-prediction/` yang ditambahkan ke lokasi keluaran dan nama file manifes, yang merupakan ID prediksi batch, dengan ekstensi `.manifest` ditambahkan ke sana.

Misalnya, jika Anda membuat objek prediksi batch dengan `IDbp-example`, dan Anda menentukan lokasi S3 `s3://examplebucket/output/` sebagai lokasi keluaran, Anda akan menemukan file manifes Anda di sini:

```
s3://examplebucket/output/batch-prediction/bp-example.manifest
```

Membaca File Manifest

Isi file.manifest dikodekan sebagai peta JSON, di mana kuncinya adalah string dari nama file data input S3, dan nilainya adalah string dari file hasil prediksi batch terkait. Ada satu baris pemetaan untuk setiap pasangan input/output file. Melanjutkan contoh kita, jika input untuk pembuatan `BatchPrediction` objek terdiri dari satu file bernama `data.csv` yang terletak di `s3://examplebucket/input/`, Anda mungkin melihat string pemetaan yang terlihat seperti ini:

```
{"s3://examplebucket/input/data.csv":  
s3://examplebucket/output/batch-prediction/result/bp-example-data.csv.gz"}
```

Jika input untuk pembuatan `BatchPrediction` objek terdiri dari tiga file yang disebut `data1.csv`, `data2.csv`, dan `data3.csv`, dan semuanya disimpan di lokasi S3 `s3://examplebucket/input/`, Anda mungkin melihat string pemetaan yang terlihat seperti ini:

```
{"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"}
```

Mengambil File Output Prediksi Batch

Anda dapat mengunduh setiap file prediksi batch yang diperoleh dari pemetaan manifes dan memprosesnya secara lokal. Format file CSV, dikompresi dengan algoritma gzip. Di dalam file itu, ada satu baris per pengamatan input dalam file input yang sesuai.

Untuk menggabungkan prediksi dengan file input prediksi batch, Anda dapat melakukan record-by-record penggabungan sederhana dari dua file. File keluaran prediksi batch selalu berisi jumlah catatan yang sama dengan file input prediksi, dalam urutan yang sama. Jika pengamatan input gagal dalam pemrosesan, dan tidak ada prediksi yang dapat dihasilkan, file output dari prediksi batch akan memiliki baris kosong di lokasi yang sesuai.

Menafsirkan Isi File Prediksi Batch untuk model ML Klasifikasi Biner

Kolom file prediksi batch untuk model klasifikasi biner diberi nama BestAnswer dan skor.

Kolom BestAnswer berisi label prediksi ("1" atau "0") yang diperoleh dengan mengevaluasi skor prediksi terhadap skor cut-off. Untuk informasi selengkapnya tentang skor cut-off, lihat [Menyesuaikan Cut-off Skor](#). Anda menetapkan skor cut-off untuk model ML dengan menggunakan Amazon ML API atau fungsionalitas evaluasi model di konsol Amazon Amazon. Jika Anda tidak menetapkan skor cut-off, Amazon ML menggunakan nilai default 0,5.

Kolom skor berisi skor prediksi mentah yang ditetapkan oleh model ML untuk prediksi ini. Amazon ML menggunakan model regresi logistik, jadi skor ini mencoba memodelkan probabilitas pengamatan yang sesuai dengan nilai true ("1"). Perhatikan bahwa skor dilaporkan dalam notasi ilmiah, jadi pada baris pertama dari contoh berikut, nilainya $8.7642E-3$ sama dengan 0,0087642.

Misalnya, jika skor cut-off untuk model ML adalah 0,75, isi file keluaran prediksi batch untuk model klasifikasi biner mungkin terlihat seperti ini:

```
bestAnswer, score
0, 8.7642E-3
1, 7.899012E-1
0, 6.323061E-3
0, 2.143189E-2
1, 8.944209E-1
```

Pengamatan kedua dan kelima dalam file input telah menerima skor prediksi di atas 0,75, sehingga kolom BestAnswer untuk pengamatan ini menunjukkan nilai "1", sedangkan pengamatan lain memiliki nilai "0".

Menafsirkan Isi File Prediksi Batch untuk Model ML Klasifikasi Multiclass

File prediksi batch untuk model multiclass berisi satu kolom untuk setiap kelas yang ditemukan dalam data pelatihan. Nama kolom muncul di baris header file prediksi batch.

Saat Anda meminta prediksi dari model multiclass, Amazon ML menghitung beberapa skor prediksi untuk setiap pengamatan dalam file input, satu untuk setiap kelas yang ditentukan dalam kumpulan data input. Ini setara dengan bertanya “Berapa probabilitas (diukur antara 0 dan 1) bahwa pengamatan ini akan jatuh ke dalam kelas ini, sebagai lawan dari kelas lainnya?” Setiap skor dapat diartikan sebagai “probabilitas bahwa pengamatan milik kelas ini.” Karena skor prediksi memodelkan probabilitas yang mendasari pengamatan milik satu kelas atau lainnya, jumlah semua skor prediksi di satu baris adalah 1. Anda perlu memilih satu kelas sebagai kelas yang diprediksi untuk model. Paling umum, Anda akan memilih kelas yang memiliki probabilitas tertinggi sebagai jawaban terbaik.

Misalnya, pertimbangkan untuk mencoba memprediksi peringkat pelanggan dari suatu produk, berdasarkan skala bintang 1-ke-5. Jika kelas diberi nama `1_star`, `2_stars`, `3_stars`, dan `4_stars` `5_stars`, file keluaran prediksi multiclass mungkin terlihat seperti ini:

```
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
```

Dalam contoh ini, pengamatan pertama memiliki skor prediksi tertinggi untuk `3_stars` kelas (skor prediksi = `4.77781E-1`), jadi Anda akan menafsirkan hasilnya sebagai menunjukkan bahwa kelas `3_stars` adalah jawaban terbaik untuk pengamatan ini. Perhatikan bahwa skor prediksi dilaporkan dalam notasi ilmiah, sehingga skor prediksi `4.77781E-1` sama dengan `0.477781`.

Mungkin ada keadaan ketika Anda tidak ingin memilih kelas dengan probabilitas tertinggi. Misalnya, Anda mungkin ingin menetapkan ambang minimum di bawah ini yang Anda tidak akan menganggap kelas sebagai jawaban terbaik meskipun memiliki skor prediksi tertinggi. Misalkan Anda mengklasifikasikan film ke dalam genre, dan Anda ingin skor prediksi setidaknya `5E-1` sebelum

Anda menyatakan genre sebagai jawaban terbaik Anda. Anda mendapatkan skor prediksi $3E-1$ untuk komedi, $2.5E-1$ untuk drama, $2.5E-1$ untuk dokumenter, dan $2E-1$ untuk film aksi. Dalam hal ini, model ML memprediksi bahwa komedi adalah pilihan Anda yang paling mungkin, tetapi Anda memutuskan untuk tidak memilihnya sebagai jawaban terbaik. Karena tidak ada skor prediksi yang melebihi skor prediksi dasar Anda sebesar $5E-1$, Anda memutuskan bahwa prediksi tersebut tidak cukup untuk memprediksi genre dengan percaya diri dan Anda memutuskan untuk memilih sesuatu yang lain. Aplikasi Anda kemudian dapat memperlakukan bidang genre untuk film ini sebagai “tidak diketahui.”

Menafsirkan Isi File Prediksi Batch untuk Model Regresi

File prediksi batch untuk model regresi berisi satu kolom bernama skor. Kolom ini berisi prediksi numerik mentah untuk setiap pengamatan dalam data input. Nilai dilaporkan dalam notasi ilmiah, sehingga nilai skor $-1.526385E1$ sama dengan -15.26835 pada baris pertama dalam contoh berikut.

Contoh ini menunjukkan file keluaran untuk prediksi batch yang dilakukan pada model regresi:

```
score
-1.526385E1
-6.188034E0
-1.271108E1
-2.200578E1
8.359159E0
```

Meminta Prediksi Waktu Nyata

Prediksi real-time adalah panggilan sinkron ke Amazon Machine Learning (Amazon ML). Prediksi dibuat ketika Amazon ML mendapatkan permintaan, dan respons segera dikembalikan. Prediksi real-time biasanya digunakan untuk mengaktifkan kemampuan prediktif dalam aplikasi web, seluler, atau desktop interaktif. Anda dapat melakukan kueri model ML yang dibuat dengan Amazon ML untuk prediksi secara real time dengan menggunakan API latensi rendah `Predict`. `Predict` menerima pengamatan input tunggal dalam payload permintaan, dan mengembalikan prediksi secara serempak dalam respons. Ini membedakannya dari API prediksi batch, yang dipanggil dengan ID objek sumber data Amazon MS yang menunjuk ke lokasi pengamatan input, dan mengembalikan

URI secara asinkron ke file yang berisi prediksi untuk semua pengamatan ini. Amazon ML merespons sebagian besar permintaan prediksi waktu nyata dalam 100 milidetik.

Anda dapat mencoba prediksi waktu nyata tanpa menimbulkan biaya di konsol Amazon Amazon. Jika Anda kemudian memutuskan untuk menggunakan prediksi real-time, Anda harus terlebih dahulu membuat titik akhir untuk pembuatan prediksi waktu nyata. Anda dapat melakukan ini di konsol Amazon ML atau dengan menggunakan `CreateRealtimeEndpoint` API. Setelah Anda memiliki titik akhir, gunakan API prediksi waktu nyata untuk menghasilkan prediksi waktu nyata.

Note

Setelah Anda membuat titik akhir real-time untuk model Anda, Anda akan mulai dikenakan biaya reservasi kapasitas yang didasarkan pada ukuran model. Untuk informasi selengkapnya, silakan lihat [Harga](#). Jika Anda membuat titik akhir real-time di konsol, konsol akan menampilkan rincian perkiraan biaya yang akan diperoleh titik akhir secara berkelanjutan. Untuk berhenti menimbulkan muatan saat Anda tidak perlu lagi mendapatkan prediksi waktu nyata dari model itu, hapus titik akhir waktu nyata dengan menggunakan konsol atau operasi `DeleteRealtimeEndpoint`

Untuk contoh `Predict` permintaan dan tanggapan, lihat [Memprediksi](#) di Referensi API Amazon Machine Learning. Untuk melihat contoh format respons yang tepat yang menggunakan model Anda, lihat [Mencoba Prediksi Real-Time](#).

Topik

- [Mencoba Prediksi Real-Time](#)
- [Membuat Endpoint Real-Time](#)
- [Menemukan Titik Akhir Prediksi Real-time \(Konsol\)](#)
- [Menemukan Titik Akhir Prediksi Real-time \(API\)](#)
- [Membuat Permintaan Prediksi Real-time](#)
- [Menghapus Titik Akhir Real-Time](#)


Mencoba Prediksi Real-Time

Untuk membantu Anda memutuskan apakah akan mengaktifkan prediksi waktu nyata, Amazon ML memungkinkan Anda mencoba membuat prediksi pada catatan data tunggal tanpa menimbulkan

biaya tambahan yang terkait dengan pengaturan titik akhir prediksi waktu nyata. Untuk mencoba prediksi real-time, Anda harus memiliki model ML. Untuk membuat prediksi real-time dalam skala yang lebih besar, gunakan [Predict](#) API di Referensi API Amazon Machine Learning.

Untuk mencoba prediksi waktu nyata

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, di drop-down Amazon Machine Learning, pilih model ML.
3. Pilih model yang ingin Anda gunakan untuk mencoba prediksi real-time, seperti `Subscription propensity` model dari tutorial.
4. Pada halaman laporan model ML, di bawah Prediksi, pilih Ringkasan, lalu pilih Coba prediksi waktu nyata.



Amazon ML menampilkan daftar variabel yang menyusun catatan data yang digunakan Amazon untuk melatih model Anda.

5. Anda dapat melanjutkan dengan memasukkan data di setiap bidang dalam formulir atau dengan menempelkan satu catatan data, dalam format CSV, ke dalam kotak teks.

Untuk menggunakan formulir, untuk setiap bidang Nilai, masukkan data yang ingin Anda gunakan untuk menguji prediksi waktu nyata Anda. Jika catatan data yang Anda masukkan tidak berisi nilai untuk satu atau beberapa atribut data, biarkan bidang entri kosong.

Untuk menyediakan catatan data, pilih Tempel catatan. Tempelkan satu baris data berformat CSV ke dalam bidang teks, dan pilih Kirim. Amazon ML secara otomatis mengisi bidang Nilai untuk Anda.

Note

Data dalam catatan data harus memiliki jumlah kolom yang sama dengan data pelatihan, dan disusun dalam urutan yang sama. Satu-satunya pengecualian adalah Anda

harus menghilangkan nilai target. Jika Anda menyertakan nilai target, Amazon ML mengabaikannya.

- Di bagian bawah halaman, pilih **Buat prediksi**. Amazon ML segera mengembalikan prediksi.

Di panel Hasil prediksi, Anda melihat objek prediksi yang ditampilkan oleh panggilan `Predict` API, bersama dengan tipe model ML, nama variabel target, dan kelas atau nilai yang diprediksi. Untuk informasi tentang menafsirkan hasil, lihat [Menafsirkan Isi File Prediksi Batch untuk model ML Klasifikasi Biner](#).



Membuat Endpoint Real-Time

Untuk menghasilkan prediksi real-time, Anda perlu membuat titik akhir real-time. Untuk membuat titik akhir real-time, Anda harus sudah memiliki model ML yang ingin Anda hasilkan prediksi waktu nyata. Anda dapat membuat titik akhir real-time dengan menggunakan konsol Amazon ML atau dengan memanggil `CreateRealtimeEndpoint` API. Untuk informasi selengkapnya tentang penggunaan


CreateRealtimeEndpoint API, lihat https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_CreateRealtimeEndpoint.html di Referensi API Amazon Machine Learning.

Untuk membuat titik akhir real-time

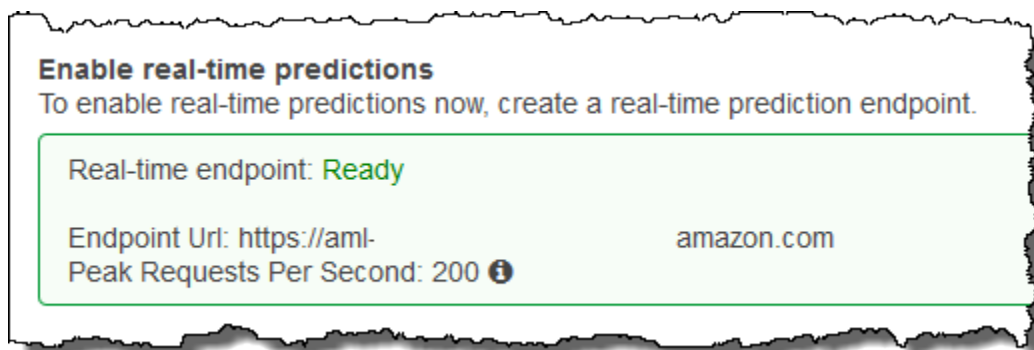
1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, di drop-down Amazon Machine Learning, pilih model ML.
3. Pilih model yang ingin Anda hasilkan prediksi waktu nyata.
4. Pada halaman ringkasan model ML, di bawah Prediksi, pilih Buat titik akhir waktu nyata.

Kotak dialog yang menjelaskan bagaimana prediksi real-time diberi harga muncul.

5. Pilih Buat. Permintaan endpoint real-time dikirim ke Amazon ML dan dimasukkan ke dalam antrian. Status titik akhir real-time adalah Memperbarui.



6. Saat titik akhir real-time siap, status berubah menjadi Siap, dan Amazon ML akan menampilkan URL endpoint. Gunakan URL endpoint untuk membuat permintaan prediksi real-time dengan API. Predict Untuk informasi selengkapnya tentang penggunaan Predict API, lihat https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_Predict.html di Referensi API Amazon Machine Learning.



Menemukan Titik Akhir Prediksi Real-time (Konsol)

Untuk menggunakan konsol Amazon Amazon untuk menemukan URL titik akhir untuk model ML, navigasikan ke halaman ringkasan model ML model.

Untuk menemukan URL titik akhir waktu nyata

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, di drop-down Amazon Machine Learning, pilih model ML.
3. Pilih model yang ingin Anda hasilkan prediksi waktu nyata.
4. Pada halaman ringkasan model ML, gulir ke bawah hingga Anda melihat bagian Prediksi.
5. URL titik akhir untuk model tercantum dalam prediksi Real-time. Gunakan URL sebagai URL Endpoint Url untuk panggilan prediksi real-time Anda. Untuk informasi tentang cara menggunakan titik akhir untuk menghasilkan prediksi, lihat https://docs.aws.amazon.com/machine-learning/latest/APIReference/API_Predict.html di Referensi API Amazon Machine Learning.

Menemukan Titik Akhir Prediksi Real-time (API)

Saat Anda membuat titik akhir real-time dengan menggunakan `CreateRealtimeEndpoint` operasi, URL dan status titik akhir dikembalikan kepada Anda dalam respons. Jika Anda membuat titik akhir real-time menggunakan konsol atau jika Anda ingin mengambil URL dan status titik akhir yang Anda buat sebelumnya, panggil `GetMLModel` operasi dengan ID model yang ingin Anda kueri untuk prediksi waktu nyata. Informasi titik akhir terkandung di `EndpointInfo` bagian respons. Untuk model yang memiliki titik akhir real-time yang terkait dengannya, `EndpointInfo` mungkin terlihat seperti ini:

```
"EndpointInfo":{
  "CreatedAt": 1427864874.227,
  "EndpointStatus": "READY",
  "EndpointUrl": "https://endpointUrl",
  "PeakRequestsPerSecond": 200
}
```

Model tanpa titik akhir real-time akan mengembalikan yang berikut:

```
EndpointInfo":{
```

```
"EndpointStatus": "NONE",  
"PeakRequestsPerSecond": 0  
}
```

Membuat Permintaan Prediksi Real-time

Contoh payload Predict permintaan mungkin terlihat seperti ini:

```
{  
  "MLModelId": "model-id",  
  "Record": {  
    "key1": "value1",  
    "key2": "value2"  
  },  
  "PredictEndpoint": "https://endpointUrl"  
}
```

PredictEndpointBidang harus sesuai dengan EndpointUrl bidang EndpointInfo struktur. Amazon ML menggunakan bidang ini untuk merutekan permintaan ke server yang sesuai dalam armada prediksi waktu nyata.

MLModelIdIni adalah pengidentifikasi model yang dilatih sebelumnya dengan titik akhir waktu nyata.

A Record adalah peta nama variabel ke nilai variabel. Setiap pasangan mewakili pengamatan. RecordPeta berisi input ke model Amazon MLmu. Ini analog dengan satu baris data dalam kumpulan data pelatihan Anda, tanpa variabel target. Terlepas dari jenis nilai dalam data pelatihan, Record berisi string-to-string pemetaan.

Note

Anda dapat menghilangkan variabel yang Anda tidak memiliki nilai, meskipun ini mungkin mengurangi keakuratan prediksi Anda. Semakin banyak variabel yang dapat Anda sertakan, semakin akurat model Anda.

Format respons yang dikembalikan oleh Predict permintaan tergantung pada jenis model yang sedang ditanyakan untuk prediksi. Dalam semua kasus, details bidang berisi informasi tentang permintaan prediksi, terutama termasuk PredictiveModelType bidang dengan jenis model.

Contoh berikut menunjukkan respons untuk model biner:

```
{
  "Prediction":{
    "details":{
      "PredictiveModelType": "BINARY"
    },
    "predictedLabel": "0",
    "predictedScores":{
      "0": 0.47380468249320984
    }
  }
}
```

Perhatikan `predictedLabel` bidang yang berisi label yang diprediksi, dalam hal ini 0. Amazon ML menghitung label yang diprediksi dengan membandingkan skor prediksi dengan batas klasifikasi:

- Anda dapat memperoleh batas klasifikasi yang saat ini dikaitkan dengan model ML dengan memeriksa `ScoreThreshold` bidang dalam respons `GetMLModel` operasi, atau dengan melihat informasi model di konsol Amazon Amazon. Jika Anda tidak menetapkan ambang skor, Amazon ML menggunakan nilai default 0,5.
- Anda dapat memperoleh skor prediksi yang tepat untuk model klasifikasi biner dengan memeriksa peta. `predictedScores` Dalam peta ini, label yang diprediksi dipasangkan dengan skor prediksi yang tepat.

Untuk informasi lebih lanjut tentang prediksi biner, lihat [Menafsirkan Prediksi](#).

Contoh berikut menunjukkan respons untuk model regresi. Perhatikan bahwa nilai numerik yang diprediksi ditemukan di `predictedValue` bidang:

```
{
  "Prediction":{
    "details":{
      "PredictiveModelType": "REGRESSION"
    },
    "predictedValue": 15.508452415466309
  }
}
```

Contoh berikut menunjukkan respons untuk model multiclass:

```
{
```

```
"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
  }
}
```

Mirip dengan model klasifikasi biner, prediksi label/class ditemukan di `predictedLabel` lapangan. Anda dapat lebih memahami seberapa kuat prediksi terkait dengan setiap kelas dengan melihat `predictedScores` peta. Semakin tinggi skor kelas dalam peta ini, semakin kuat prediksi terkait dengan kelas, dengan nilai tertinggi akhirnya dipilih sebagai `predictedLabel`.

Untuk informasi lebih lanjut tentang prediksi multiclass, lihat [Wawasan Model Multiclass](#)

Menghapus Titik Akhir Real-Time

Ketika Anda telah menyelesaikan prediksi real-time Anda, hapus titik akhir waktu nyata untuk menghindari dikenakan biaya tambahan. Biaya berhenti bertambah segera setelah Anda menghapus titik akhir Anda.

Untuk menghapus titik akhir real-time

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, di drop-down Amazon Machine Learning, pilih model ML.
3. Pilih model yang tidak lagi membutuhkan prediksi waktu nyata.
4. Pada halaman laporan model ML, di bawah Prediksi, pilih Ringkasan.
5. Pilih Hapus titik akhir waktu nyata.
6. Di kotak dialog Hapus titik akhir waktu nyata, pilih Hapus.

Mengelola Objek Amazon Amazon

Amazon ML menyediakan empat objek yang dapat Anda kelola melalui konsol Amazon ML atau Amazon ML API:

- Sumber Data
- Model ML
- Evaluasi
- Prediksi Batch

Setiap objek melayani tujuan yang berbeda dalam siklus hidup membangun aplikasi pembelajaran mesin, dan setiap objek memiliki atribut dan fungsionalitas tertentu yang hanya berlaku untuk objek itu. Terlepas dari perbedaan ini, Anda mengelola objek dengan cara yang sama. Misalnya, Anda menggunakan proses yang hampir identik untuk mencantumkan objek, mengambil deskripsinya, dan memperbarui atau menghapusnya.

Bagian berikut menjelaskan operasi manajemen yang umum untuk keempat objek dan mencatat perbedaan.

Topik

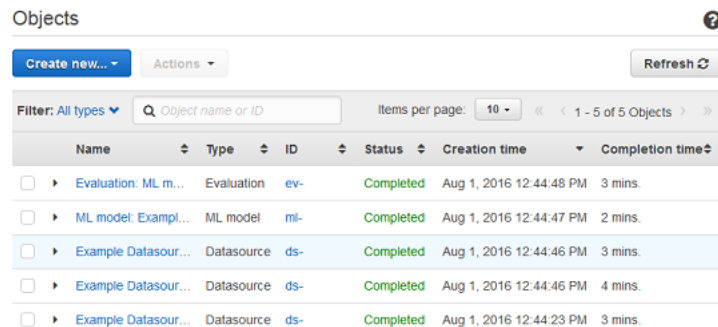
- [Daftar Objek](#)
- [Mengambil Deskripsi Objek](#)
- [Memperbarui Objek](#)
- [Menghapus Objek](#)

Daftar Objek

Untuk informasi mendalam tentang sumber data Amazon Machine Learning (Amazon ML), model, evaluasi, dan prediksi batch, buat daftar. Untuk setiap objek, Anda akan melihat nama, jenis, ID, kode status, dan waktu pembuatannya. Anda juga dapat melihat detail yang spesifik untuk jenis objek tertentu. Misalnya, Anda dapat melihat wawasan Data untuk sumber data.

Daftar Objek (Konsol)

Untuk melihat daftar 1.000 objek terakhir yang telah Anda buat, di konsol Amazon, buka dasbor Objects. Untuk menampilkan dasbor Objek, masuk ke konsol Amazon ML.



The screenshot shows the Amazon ML Objects console interface. At the top, there is a header 'Objects' with a help icon. Below it are buttons for 'Create new...' and 'Actions', and a 'Refresh' button. A search bar contains 'Object name or ID'. Below the search bar is a table with columns: Name, Type, ID, Status, Creation time, and Completion time. The table lists five objects, all with a status of 'Completed'.

Name	Type	ID	Status	Creation time	Completion time
▶ Evaluation: ML m...	Evaluation	ev-	Completed	Aug 1, 2016 12:44:48 PM	3 mins.
▶ ML model: Examl...	ML model	ml-	Completed	Aug 1, 2016 12:44:47 PM	2 mins.
▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	3 mins.
▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:46 PM	4 mins.
▶ Example Datasour...	Datasource	ds-	Completed	Aug 1, 2016 12:44:23 PM	3 mins.

Untuk melihat detail selengkapnya tentang objek, termasuk detail yang spesifik untuk jenis objek tersebut, pilih nama atau ID objek. Misalnya, untuk melihat Wawasan data untuk sumber data, pilih nama sumber data.

Kolom pada dashboard Objects menunjukkan informasi berikut tentang setiap objek.

Nama

Nama objek.

Jenis

Jenis objek. Nilai yang valid termasuk Sumber Data, model ML, Evaluasi, dan prediksi Batch.

Note

Untuk melihat apakah model diatur untuk mendukung prediksi real-time, buka halaman ringkasan model ML dengan memilih nama atau ID model.

ID

ID proyek.

Status

Status objek. Nilai termasuk Tertunda, Dalam Proses, Selesai, dan Gagal. Jika statusnya Gagal, periksa data Anda dan coba lagi.

Waktu pembuatan

Tanggal dan waktu ketika Amazon ML selesai membuat objek ini.

Waktu penyelesaian

Lamanya waktu yang dibutuhkan Amazon ML untuk membuat objek ini. Anda dapat menggunakan waktu penyelesaian model untuk memperkirakan waktu pelatihan untuk model baru.

ID Sumber Data

Untuk objek yang dibuat menggunakan sumber data, seperti model dan evaluasi, ID sumber data. Jika Anda menghapus sumber data, Anda tidak dapat lagi menggunakan model ML yang dibuat dengan sumber data tersebut untuk membuat prediksi.

Urutkan berdasarkan kolom apa pun dengan memilih ikon segitiga ganda di sebelah header kolom.

Daftar Objek (API)

Di [Amazon ML API](#), Anda dapat mencantumkan objek, berdasarkan jenis, dengan menggunakan operasi berikut:

- DescribeDataSources
- DescribeMLModels
- DescribeEvaluations
- DescribeBatchPredictions

Setiap operasi mencakup parameter untuk memfilter, menyortir, dan paginasi melalui daftar panjang objek. Tidak ada batasan jumlah objek yang dapat Anda akses melalui API. Untuk membatasi ukuran daftar, gunakan Limit parameter, yang dapat mengambil nilai maksimum 100.

Respons API terhadap Describe* perintah mencakup token pagination (nextPageToken), jika sesuai, dan deskripsi singkat dari setiap objek. Deskripsi objek menyertakan informasi yang sama untuk setiap jenis objek yang ditampilkan di konsol, termasuk detail yang spesifik untuk jenis objek.

Note

Bahkan jika respons mencakup objek yang lebih sedikit daripada batas yang ditentukan, itu mungkin termasuk a `nextPageToken` yang menunjukkan bahwa lebih banyak hasil yang tersedia. Bahkan respons yang berisi 0 item mungkin berisi a `nextPageToken`.

Untuk informasi selengkapnya, lihat [Referensi API Amazon ML](#).

Mengambil Deskripsi Objek

Anda dapat melihat deskripsi terperinci dari objek apa pun melalui konsol atau melalui API.

Deskripsi Terperinci di Konsol

Untuk melihat deskripsi di konsol, navigasikan ke daftar untuk jenis objek tertentu (sumber data, model ML, evaluasi, atau prediksi batch). Selanjutnya, cari baris dalam tabel yang sesuai dengan objek, baik dengan menelusuri daftar atau dengan mencari nama atau ID-nya.

Deskripsi Terperinci dari API

Setiap jenis objek memiliki operasi yang mengambil detail lengkap dari objek Amazon Amazon:

- `GetDataSource`
- Dapatkan `MLModel`
- `GetEvaluation`
- `GetBatchPrediction`

Setiap operasi mengambil tepat dua parameter: ID objek dan bendera Boolean yang disebut `Verbose`. Panggilan dengan `Verbose` disetel ke `true` akan mencakup detail tambahan tentang objek, menghasilkan latensi yang lebih tinggi dan respons yang lebih besar. Untuk mempelajari bidang mana yang disertakan dengan menyetel flag `Verbose`, lihat Referensi [API Amazon ML](#).

Memperbarui Objek

Setiap jenis objek memiliki operasi yang memperbarui detail objek Amazon ML (Lihat [Referensi API Amazon ML](#)):

- UpdateDataSource
- Perbarui MLModel
- UpdateEvaluation
- UpdateBatchPrediction


Setiap operasi memerlukan ID objek untuk menentukan objek mana yang sedang diperbarui. Anda dapat memperbarui nama semua objek. Anda tidak dapat memperbarui properti objek lainnya untuk sumber data, evaluasi, dan prediksi batch. Untuk Model ML, Anda dapat memperbarui ScoreThreshold bidang, selama model ML tidak memiliki titik akhir prediksi real-time yang terkait dengannya.

Menghapus Objek

Jika Anda tidak lagi membutuhkan sumber data, model, evaluasi, dan prediksi batch, Anda dapat menghapusnya. Meskipun tidak ada biaya tambahan untuk menyimpan objek Amazon ML selain prediksi batch setelah Anda selesai menggunakannya, menghapus objek membuat ruang kerja Anda tetap rapi dan lebih mudah dikelola. Anda dapat menghapus satu atau beberapa objek menggunakan konsol Amazon Machine Learning (Amazon ML) atau API.

Warning

Saat Anda menghapus objek Amazon Amazon, efeknya langsung, permanen, dan tidak dapat diubah.

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.

Menghapus Objek (Konsol)

Anda dapat menggunakan konsol Amazon Amazon untuk menghapus objek, termasuk model. Prosedur yang Anda gunakan untuk menghapus model tergantung pada apakah Anda menggunakan model untuk menghasilkan prediksi waktu nyata atau tidak. Untuk menghapus model yang digunakan untuk menghasilkan prediksi real-time, pertama-tama hapus titik akhir real-time.

Untuk menghapus objek Amazon ML (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Pilih objek Amazon ML yang ingin Anda hapus. Untuk memilih lebih dari satu objek, gunakan tombol Shift. Untuk membatalkan pilihan semua objek yang dipilih, gunakan  tombol  or.
3. Untuk Tindakan, pilih Hapus.
4. Di kotak dialog, pilih Hapus untuk menghapus model.

Untuk menghapus model Amazon Amazon dengan titik akhir real-time (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Pilih model yang ingin Anda hapus.
3. Untuk Tindakan, pilih Hapus titik akhir waktu nyata.
4. Pilih Hapus untuk menghapus titik akhir.
5. Pilih model lagi.
6. Untuk Tindakan, pilih Hapus.
7. Pilih Hapus untuk menghapus model.

Menghapus Objek (API)

Anda dapat menghapus objek Amazon ML menggunakan panggilan API berikut:

- DeleteDataSource- Mengambil parameterDataSourceId.
- DeleteMLModel- Mengambil parameterMLModelId.
- DeleteEvaluation- Mengambil parameterEvaluationId.
- DeleteBatchPrediction- Mengambil parameterBatchPredictionId.

Untuk informasi selengkapnya, lihat [Referensi API Amazon Machine Learning](#).

Memantau Amazon ML dengan Amazon CloudWatch Metrics

Amazon ML secara otomatis mengirimkan metrik ke Amazon CloudWatch sehingga Anda dapat mengumpulkan dan menganalisis statistik penggunaan untuk model ML Anda. Misalnya, untuk melacak prediksi batch dan real-time, Anda dapat memantau PredictCount metrik sesuai dengan RequestMode dimensi. Metrik secara otomatis dikumpulkan dan dikirim ke Amazon CloudWatch setiap lima menit. Anda dapat memantau metrik ini dengan menggunakan CloudWatch konsol Amazon, AWS CLI, atau AWS SDKs

Tidak ada biaya untuk metrik Amazon ML yang dilaporkan melalui CloudWatch. [Jika Anda menyetel alarm pada metrik, Anda akan ditagih dengan tarif standar. CloudWatch](#)

Untuk informasi selengkapnya, lihat daftar metrik Amazon ML di [CloudWatch Ruang Nama, Dimensi, dan Referensi Metrik Amazon di Panduan Pengembang](#) Amazon. CloudWatch

Mencatat Panggilan API Amazon ML dengan AWS CloudTrail

Amazon Machine Learning (Amazon Learning) terintegrasi AWS CloudTrail dengan, layanan yang menyediakan catatan tindakan yang diambil oleh pengguna, peran, atau AWS layanan di Amazon ML. CloudTrail menangkap semua panggilan API untuk Amazon ML sebagai peristiwa. Panggilan yang diambil termasuk panggilan dari konsol Amazon MLL dan panggilan kode ke operasi Amazon ML API. Jika Anda membuat jejak, Anda dapat mengaktifkan pengiriman CloudTrail acara secara terus menerus ke bucket Amazon S3, termasuk acara untuk Amazon ML. Jika Anda tidak mengonfigurasi jejak, Anda masih dapat melihat peristiwa terbaru di CloudTrail konsol dalam Riwayat acara. Dengan menggunakan informasi yang dikumpulkan oleh CloudTrail, Anda dapat menentukan permintaan yang dibuat ke Amazon, alamat IP dari mana permintaan dibuat, siapa yang membuat permintaan, kapan dibuat, dan detail tambahan.

Untuk mempelajari selengkapnya CloudTrail, termasuk cara mengonfigurasi dan mengaktifkannya, lihat [Panduan AWS CloudTrail Pengguna](#).

Informasi Amazon ML di CloudTrail

CloudTrail diaktifkan di AWS akun Anda saat Anda membuat akun. Ketika aktivitas peristiwa yang didukung terjadi di Amazon, aktivitas tersebut direkam dalam suatu CloudTrail peristiwa bersama dengan peristiwa AWS layanan lainnya dalam riwayat Acara. Anda dapat melihat, mencari, dan mengunduh acara terbaru di AWS akun Anda. Untuk informasi selengkapnya, lihat [Melihat Acara dengan Riwayat CloudTrail Acara](#).

Untuk catatan peristiwa yang sedang berlangsung di AWS akun Anda, termasuk acara untuk Amazon, buat jejak. Jejak memungkinkan CloudTrail untuk mengirimkan file log ke bucket Amazon S3. Secara default, ketika Anda membuat jejak di konsol tersebut, jejak tersebut diterapkan ke semua Wilayah AWS. Jejak mencatat peristiwa dari semua Wilayah di AWS partisi dan mengirimkan file log ke bucket Amazon S3 yang Anda tentukan. Selain itu, Anda dapat mengonfigurasi AWS layanan lain untuk menganalisis lebih lanjut dan menindaklanjuti data peristiwa yang dikumpulkan dalam CloudTrail log. Untuk informasi selengkapnya, lihat berikut:

- [Gambaran Umum untuk Membuat Jejak](#)
- [CloudTrail Layanan dan Integrasi yang Didukung](#)
- [Mengonfigurasi Notifikasi Amazon SNS untuk CloudTrail](#)

- [Menerima File CloudTrail Log dari Beberapa Wilayah](#) dan [Menerima File CloudTrail Log dari Beberapa Akun](#)

Amazon ML mendukung pencatatan tindakan berikut sebagai peristiwa dalam file CloudTrail log:

- [AddTags](#)
- [CreateBatchPrediction](#)
- [CreateDataSourceFromRDS](#)
- [CreateDataSourceFromRedshift](#)
- [CreateDataSourceFromS3](#)
- [CreateEvaluation](#)
- [Buat MLModel](#)
- [CreateRealtimeEndpoint](#)
- [DeleteBatchPrediction](#)
- [DeleteDataSource](#)
- [DeleteEvaluation](#)
- [Hapus MLModel](#)
- [DeleteRealtimeEndpoint](#)
- [DeleteTags](#)
- [DescribeTags](#)
- [UpdateBatchPrediction](#)
- [UpdateDataSource](#)
- [UpdateEvaluation](#)
- [Perbarui MLModel](#)

Operasi Amazon ML berikut menggunakan parameter permintaan yang berisi kredensial. Sebelum permintaan ini dikirim ke CloudTrail, kredensialnya diganti dengan tiga tanda bintang (“***”):

- [CreateDataSourceFromRDS](#)
- [CreateDataSourceFromRedshift](#)

Saat operasi Amazon MLL berikut dilakukan dengan konsol Amazon, atribut `ComputeStatistics` tidak disertakan dalam `RequestParameters` komponen CloudTrail log:

- [CreateDataSourceFromRedshift](#)
- [CreateDataSourceFromS3](#)

Setiap entri peristiwa atau log berisi informasi tentang siapa yang membuat permintaan tersebut. Informasi identitas membantu Anda menentukan berikut ini:

- Apakah permintaan itu dibuat dengan kredensial pengguna root atau AWS Identity and Access Management (IAM).
- Apakah permintaan tersebut dibuat dengan kredensial keamanan sementara untuk satu peran atau pengguna gabungan.
- Apakah permintaan itu dibuat oleh AWS layanan lain.

Untuk informasi lain, lihat [Elemen userIdentity CloudTrail](#).

Contoh: Entri File Log Amazon

Trail adalah konfigurasi yang memungkinkan pengiriman peristiwa sebagai file log ke bucket Amazon S3 yang Anda tentukan. CloudTrail file log berisi satu atau lebih entri log. Peristiwa mewakili permintaan tunggal dari sumber mana pun dan mencakup informasi tentang tindakan yang diminta, tanggal dan waktu tindakan, parameter permintaan, dan sebagainya. CloudTrail file log bukanlah jejak tumpukan yang diurutkan dari panggilan API publik, jadi file tersebut tidak muncul dalam urutan tertentu.

Contoh berikut menunjukkan entri CloudTrail log yang menunjukkan tindakan.

```
{
  "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"
    }
]
}
```

Menandai Objek Amazon MLmu

Atur dan kelola objek Amazon Machine Learning (Amazon ML) Anda dengan menetapkan metadata ke objek tersebut dengan tag. Tag adalah pasangan kunci-nilai yang Anda tentukan untuk suatu objek.

Selain menggunakan tag untuk mengatur dan mengelola objek Amazon Amazon, Anda dapat menggunakannya untuk mengkategorikan dan melacak biaya AWS Anda. Saat Anda menerapkan tag ke objek AWS Anda, termasuk model ML, laporan alokasi biaya AWS Anda mencakup penggunaan dan biaya yang dikumpulkan berdasarkan tag. Dengan menerapkan tag yang mewakili kategori bisnis (seperti pusat biaya, nama aplikasi, atau pemilik), Anda dapat mengatur biaya Anda di beberapa layanan. Untuk informasi selengkapnya, lihat [Menggunakan Tanda Alokasi Biaya untuk Laporan Penagihan Khusus](#) dalam Panduan Pengguna AWS Billing .

Daftar Isi

- [Dasar-Dasar Tanda](#)
- [Pembatasan Tag](#)
- [Menandai Objek Amazon ML \(Konsol\)](#)
- [Menandai Objek Amazon ML \(API\)](#)

Dasar-Dasar Tanda

Gunakan tag untuk mengkategorikan objek Anda agar lebih mudah mengelolanya. Misalnya, Anda dapat mengkategorikan objek berdasarkan tujuan, pemilik, atau lingkungan. Kemudian, Anda dapat menentukan satu set tag yang membantu Anda melacak model berdasarkan pemilik dan aplikasi terkait. Berikut adalah beberapa contoh:

- Proyek: Nama proyek
- Pemilik: Nama
- Tujuan: Prediksi pemasaran
- Aplikasi: Nama aplikasi
- Lingkungan: Produksi

Anda menggunakan konsol Amazon Amazon atau API untuk menyelesaikan tugas-tugas berikut:

- Menambahkan tag ke objek
- Lihat tag untuk objek Anda
- Edit tag untuk objek Anda
- Hapus tag dari objek

Secara default, tag yang diterapkan ke objek Amazon Amazon akan disalin ke objek yang dibuat menggunakan objek tersebut. Misalnya, jika sumber data Amazon Simple Storage Service (Amazon S3) memiliki tag “Biaya pemasaran: Kampanye pemasaran yang ditargetkan”, model yang dibuat menggunakan sumber data tersebut juga akan memiliki tag “Biaya pemasaran: Kampanye pemasaran yang ditargetkan”, seperti halnya evaluasi untuk model tersebut. Ini memungkinkan Anda menggunakan tag untuk melacak objek terkait, seperti semua objek yang digunakan untuk kampanye pemasaran. Jika ada konflik antara sumber tag, seperti model dengan tag “Biaya pemasaran: Kampanye pemasaran yang ditargetkan” dan sumber data dengan tag “Biaya pemasaran: Target pelanggan pemasaran”, Amazon ML menerapkan tag dari model tersebut.

Pembatasan Tag

Batasan berikut berlaku untuk tanda.

Pembatasan dasar:

- Jumlah maksimum tag per objek adalah 50.
- Kunci dan nilai tanda peka huruf besar-kecil.
- Anda tidak dapat mengubah atau mengedit tag untuk objek yang dihapus.

Batasan kunci tag:

- Setiap kunci tanda harus unik. Jika Anda menambahkan tag dengan kunci yang sudah digunakan, tag baru Anda akan menimpa pasangan nilai kunci yang ada untuk objek tersebut.
- Anda tidak dapat memulai kunci tag `aws :` karena awalan ini dicadangkan untuk digunakan oleh AWS. AWS membuat tag yang dimulai dengan awalan ini atas nama Anda, tetapi Anda tidak dapat mengedit atau menghapusnya.
- Kunci tanda harus memiliki panjang antara 1 dan 128 karakter Unicode.
- Kunci tanda harus terdiri dari karakter berikut: huruf Unicode, digit, spasi, dan karakter khusus berikut: `_ . / = + - @`.

Batasan nilai tag:

- Panjang nilai tanda harus antara 0 dan 255 karakter Unicode.
- Nilai tanda dapat kosong. Jika tidak, nilai tanda harus terdiri dari karakter berikut: huruf Unicode, digit, spasi, dan salah satu karakter khusus berikut: `_ . / = + - @`.

Menandai Objek Amazon ML (Konsol)

Anda dapat melihat, menambah, mengedit, dan menghapus tag menggunakan konsol Amazon Amazon.

Untuk melihat tag untuk objek (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, perluas pemilih wilayah dan pilih wilayah.
3. Pada halaman Objek, pilih objek.
4. Gulir ke bagian Tag dari objek yang dipilih. Tag untuk objek tersebut tercantum di bagian bawah bagian.

Untuk menambahkan tag ke objek (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, perluas pemilih wilayah dan pilih wilayah.
3. Pada halaman Objek, pilih objek.
4. Gulir ke bagian Tag dari objek yang dipilih. Tag untuk objek tersebut tercantum di bagian bawah bagian.
5. Pilih Tambahkan atau edit tag.
6. Di bawah Tambahkan Tag, tentukan kunci tag di bidang Kunci, secara opsional tentukan nilai tag di bidang Nilai, lalu pilih Terapkan perubahan.

Jika tombol Terapkan perubahan tidak diaktifkan, kunci tag atau nilai tag yang Anda tentukan tidak memenuhi batasan tag. Untuk informasi selengkapnya, lihat [Pembatasan Tag](#).

7. Untuk melihat tag baru Anda dalam daftar di bagian Tag, segarkan halaman.

Untuk mengedit tag (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, perluas pemilih wilayah dan pilih wilayah.
3. Pada halaman Objek, pilih objek.
4. Gulir ke bagian Tag dari objek yang dipilih. Tag untuk objek tersebut tercantum di bagian bawah bagian.
5. Pilih Tambahkan atau edit tag.
6. Di bawah Tag yang diterapkan, edit nilai tag di bidang Nilai, lalu pilih Terapkan perubahan.

Jika tombol Terapkan perubahan tidak diaktifkan, nilai tag yang Anda tentukan tidak memenuhi batasan tag. Untuk informasi selengkapnya, lihat [Pembatasan Tag](#).

7. Untuk melihat tag terbaru Anda dalam daftar di bagian Tag, segarkan halaman.

Untuk menghapus tag dari objek (konsol)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon Machine Learning di <https://console.aws.amazon.com/machinelearning/>.
2. Di bilah navigasi, perluas pemilih wilayah dan pilih wilayah.
3. Pada halaman Objek, pilih objek.
4. Gulir ke bagian Tag dari objek yang dipilih. Tag untuk objek tersebut tercantum di bagian bawah bagian.
5. Pilih Tambahkan atau edit tag.
6. Di bawah Tag Terapan, pilih tag yang ingin Anda hapus, lalu pilih Terapkan perubahan.

Menandai Objek Amazon ML (API)

Anda dapat menambahkan, membuat daftar, dan menghapus tag menggunakan Amazon ML API. Untuk contoh, lihat dokumentasi berikut:

[AddTags](#)

Menambahkan atau mengedit tag untuk objek tertentu.

[DescribeTags](#)

Daftar tag untuk objek yang ditentukan.

[DeleteTags](#)

Menghapus tag dari objek yang ditentukan.

Referensi Amazon Machine Learning

Topik

- [Memberikan Izin Amazon ML untuk Membaca Data Anda dari Amazon S3](#)
- [Memberikan Izin Amazon ML untuk Prediksi Output ke Amazon S3](#)
- [Mengontrol Akses ke Sumber Daya Amazon ML-dengan IAM](#)
- [Pencegahan "confused deputy" lintas layanan](#)
- [Manajemen Ketergantungan Operasi Asinkron](#)
- [Memeriksa Status Permintaan](#)
- [Batas Sistem](#)
- [Nama dan IDs untuk semua Objek](#)
- [Objek Lifetimes](#)

Memberikan Izin Amazon ML untuk Membaca Data Anda dari Amazon S3

Untuk membuat objek sumber data dari data input Anda di Amazon S3, Anda harus memberikan Amazon ML izin berikut ke lokasi S3 tempat data input Anda disimpan:

- `GetObject` izin pada ember dan awalan S3.
- `ListBucket` izin pada ember S3. Tidak seperti tindakan lainnya, `ListBucket` harus diberikan izin di seluruh ember (bukan pada awalan). Namun, Anda dapat membuat cakupan izin ke awalan tertentu dengan menggunakan klausa Kondisi.

Jika Anda menggunakan konsol Amazon Amazon untuk membuat sumber data, izin ini dapat ditambahkan ke bucket untuk Anda. Anda akan diminta untuk mengonfirmasi apakah Anda ingin menambahkannya saat Anda menyelesaikan langkah-langkah di wizard. Kebijakan contoh berikut menunjukkan cara memberikan izin kepada Amazon ML untuk membaca data dari lokasi sampel `s3:examplebucket//exampleprefix`, sambil mencantumkan izin untuk hanya jalur input. `ListBucketexampleprefix`

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:*"
        }
      }
    }
  ]
}
```

```
}
```

Untuk menerapkan kebijakan ini pada data Anda, Anda harus mengedit pernyataan kebijakan yang terkait dengan bucket S3 tempat data Anda disimpan.

Untuk mengedit kebijakan izin untuk bucket S3 (menggunakan konsol lama)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Pilih nama bucket tempat data Anda berada.
3. Pilih Properti.
4. Pilih kebijakan Edit bucket
5. Masukkan kebijakan yang ditunjukkan di atas, sesuaikan agar sesuai dengan kebutuhan Anda, lalu pilih Simpan.
6. Pilih Simpan.

Untuk mengedit kebijakan izin untuk bucket S3 (menggunakan konsol baru)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Pilih nama bucket lalu pilih Izin.
3. Pilih Kebijakan Bucket.
4. Masukkan kebijakan yang ditunjukkan di atas, sesuaikan agar sesuai dengan kebutuhan Anda.
5. Pilih Simpan.

Memberikan Izin Amazon ML untuk Prediksi Output ke Amazon S3

Untuk menampilkan hasil operasi prediksi batch ke Amazon S3, Anda harus memberikan Amazon ML izin berikut ke lokasi keluaran, yang disediakan sebagai input ke operasi Buat Prediksi Batch:

- GetObject izin pada bucket dan awalan S3 Anda.
- PutObject izin pada bucket dan awalan S3 Anda.
- PutObjectAcl pada ember dan awalan S3 Anda.

- Amazon ML memerlukan izin ini untuk memastikannya dapat memberikan bucket-owner-full-control izin [ACL](#) yang dikalengkan ke akun AWS Anda, setelah objek dibuat.
- ListBucketizin pada ember S3. Tidak seperti tindakan lainnya, ListBucket harus diberikan izin di seluruh ember (bukan pada awalan). Namun, Anda dapat mencakup izin ke awalan tertentu dengan menggunakan klausa Kondisi.

Jika Anda menggunakan konsol Amazon Amazon untuk membuat permintaan prediksi batch, izin ini dapat ditambahkan ke bucket untuk Anda. Anda akan diminta untuk mengonfirmasi apakah Anda ingin menambahkannya saat Anda menyelesaikan langkah-langkah di wizard.

Kebijakan contoh berikut menunjukkan cara memberikan izin kepada Amazon ML untuk menulis data ke lokasi sampel `s3://examplebucket/exampleprefix`, sambil mencantumkan ListBucketizin hanya ke jalur input `exampleprefix`, dan memberikan izin kepada Amazon ML untuk menyetel objek put ACLs pada awalan keluaran:

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:*"
        }
      }
    }
  ]
}

```

Untuk menerapkan kebijakan ini pada data Anda, Anda harus mengedit pernyataan kebijakan yang terkait dengan bucket S3 tempat data Anda disimpan.

Untuk mengedit kebijakan izin untuk bucket S3 (menggunakan konsol lama)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Pilih nama bucket tempat data Anda berada.
3. Pilih Properti.
4. Pilih kebijakan Edit bucket
5. Masukkan kebijakan yang ditunjukkan di atas, sesuaikan agar sesuai dengan kebutuhan Anda, lalu pilih Simpan.
6. Pilih Simpan.

Untuk mengedit kebijakan izin untuk bucket S3 (menggunakan konsol baru)

1. Masuk ke Konsol Manajemen AWS dan buka konsol Amazon S3 di <https://console.aws.amazon.com/s3/>
2. Pilih nama bucket lalu pilih Izin.
3. Pilih Kebijakan Bucket.
4. Masukkan kebijakan yang ditunjukkan di atas, sesuaikan agar sesuai dengan kebutuhan Anda.
5. Pilih Simpan.

Mengontrol Akses ke Sumber Daya Amazon ML-dengan IAM

AWS Identity and Access Management (IAM) memungkinkan Anda mengontrol akses ke layanan dan sumber daya AWS dengan aman bagi pengguna Anda. Menggunakan IAM, Anda dapat membuat dan mengelola pengguna, grup, dan peran AWS, serta menggunakan izin untuk mengizinkan dan menolak akses mereka ke sumber daya AWS. Dengan menggunakan IAM dengan Amazon Machine Learning (Amazon ML), Anda dapat mengontrol apakah pengguna di organisasi Anda dapat menggunakan sumber daya AWS tertentu dan apakah mereka dapat melakukan tugas menggunakan tindakan Amazon MLAPI tertentu.

IAM memungkinkan Anda untuk:

- Buat pengguna dan grup di bawah akun AWS Anda.
- Tetapkan kredensial keamanan unik untuk setiap pengguna di bawah akun AWS Anda

- Kontrol setiap izin pengguna untuk melakukan tugas menggunakan sumber daya AWS
- Bagikan sumber daya AWS Anda dengan mudah dengan pengguna di akun AWS Anda
- Buat peran untuk akun AWS Anda dan kelola izin kepada mereka untuk menentukan pengguna atau layanan yang dapat mengasumsikannya
- Anda dapat membuat peran di IAM dan mengelola izin untuk mengontrol operasi mana yang dapat dilakukan oleh entitas, atau layanan AWS, yang mengasumsikan peran tersebut. Anda juga dapat menentukan entitas mana yang diizinkan untuk mengambil peran.

Jika organisasi Anda sudah memiliki identitas IAM, Anda dapat menggunakannya untuk memberikan izin untuk melakukan tugas menggunakan sumber daya AWS.

Untuk informasi lebih lanjut tentang IAM, lihat [Panduan Pengguna IAM](#).

Sintaks Kebijakan IAM

kebijakan IAM adalah dokumen JSON yang terdiri dari satu atau beberapa pernyataan. Setiap pernyataan memiliki struktur sebagai berikut:

```
{
  "Statement": [{
    "Effect": "effect",
    "Action": "action",
    "Resource": "arn",
    "Condition": {
      "condition operator": {
        "key": "value"
      }
    }
  }]
}
```

Pernyataan kebijakan mencakup elemen-elemen berikut:

- Efek: Mengontrol izin untuk menggunakan sumber daya dan tindakan API yang akan Anda tentukan nanti dalam pernyataan. Nilai yang valid adalah Allow dan Deny. Secara default, para pengguna IAM tidak memiliki izin untuk menggunakan sumber daya dan tindakan API, jadi semua permintaan akan ditolak. Eksplisit Allow mengesampingkan default. Eksplisit Deny mengesampingkan apa pun. Allows
- Tindakan: Tindakan atau tindakan API tertentu yang Anda berikan atau penolakan izin.

- Sumber daya: Sumber daya yang dipengaruhi oleh tindakan. Untuk menentukan sumber daya dalam pernyataan, Anda menggunakan Nama Sumber Daya Amazon (ARN).
- Kondisi (opsional): Mengontrol kapan kebijakan Anda akan berlaku.

Untuk menyederhanakan pembuatan dan pengelolaan kebijakan IAM, Anda dapat menggunakan AWS Policy Generator dan IAM Policy Simulator.

Menentukan Tindakan Kebijakan IAM untuk Amazon MLAmazon

Dalam pernyataan kebijakan IAM, Anda dapat menentukan tindakan API untuk layanan apa pun yang mendukung IAM. Saat Anda membuat pernyataan kebijakan untuk tindakan Amazon ML API, tambahkan `machinelearning:` ke nama tindakan API, seperti yang ditunjukkan dalam contoh berikut:

- `machinelearning:CreateDataSourceFromS3`
- `machinelearning:DescribeDataSources`
- `machinelearning>DeleteDataSource`
- `machinelearning:GetDataSource`

Untuk menentukan beberapa tindakan dalam satu pernyataan, pisahkan dengan koma:

```
"Action": ["machinelearning:action1", "machinelearning:action2"]
```

Anda juga dapat menentukan beberapa tindakan menggunakan wildcard. Misalnya, Anda dapat menentukan semua tindakan yang namanya dimulai dengan kata "Dapatkan":

```
"Action": "machinelearning:Get*"
```

Untuk menentukan semua tindakan Amazon Amazon, gunakan wildcard *:

```
"Action": "machinelearning:*"
```

Untuk daftar lengkap tindakan Amazon ML API, lihat [Referensi API Amazon Machine Learning](#).

Menentukan ARNs Sumber Daya Amazon Amazon dalam Kebijakan IAM

Pernyataan kebijakan IAM berlaku untuk satu atau lebih sumber daya. Anda menentukan sumber daya untuk kebijakan Anda berdasarkan mereka ARNs.

ARNs Untuk menentukan sumber daya Amazon ML, gunakan format berikut:

“Sumber”: `arn:aws:machinelearning:region:account:resource-type/identifier`

Contoh berikut menunjukkan cara menentukan umum ARNs.

ID Sumber Data: `my-s3-datasource-id`

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:datasource/my-s3-datasource-id
```

ID model ML: `my-ml-model-id`

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:mlmodel/my-ml-model-id
```

ID prediksi Batch: `my-batchprediction-id`

```
"Resource":  
arn:aws:machinelearning:<region>:<your-account-id>:batchprediction/my-batchprediction-  
id
```

ID Evaluasi: `my-evaluation-id`

```
"Resource": arn:aws:machinelearning:<region>:<your-account-id>:evaluation/my-  
evaluation-id
```

Contoh Kebijakan untuk Amazon MLs

Contoh 1: Izinkan pengguna membaca metadata sumber daya pembelajaran mesin

Kebijakan berikut memungkinkan pengguna atau grup membaca metadata sumber data, model ML, prediksi batch, dan evaluasi dengan melakukan, [Deskripsikan](#), [DescribeDataSources](#),,, [Dapatkan MLModels](#), [DescribeBatchPredictionsDescribeEvaluationsGetDataSourceMLModelGetBatchPrediction](#), dan [GetEvaluation](#) tindakan pada sumber daya yang ditentukan. Izin operasi `Jelaskan` * tidak dapat dibatasi untuk sumber daya tertentu.

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": [ "*" ] } ]
}
```

Contoh 2: Izinkan pengguna membuat sumber pembelajaran mesin

Kebijakan berikut memungkinkan pengguna atau grup untuk membuat sumber data machine learning, model ML, prediksi batch, dan evaluasi dengan melakukan `CreateDataSourceFromS3`, `CreateDataSourceFromRedshift`, `CreateDataSourceFromRDS`, `CreateMLModel` dan tindakan `CreateBatchPrediction` `CreateEvaluation`. Anda tidak dapat membatasi izin untuk tindakan ini ke sumber daya tertentu.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "machinelearning:CreateDataSourceFrom*",
        "machinelearning:CreateMLModel",
        "machinelearning:CreateBatchPrediction",
        "machinelearning:CreateEvaluation"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}
```

```
}

```

Contoh 3: Izinkan pengguna membuat dan menghapus) titik akhir waktu nyata dan melakukan prediksi waktu nyata pada model ML

Kebijakan berikut memungkinkan pengguna atau grup untuk membuat dan menghapus titik akhir real-time dan melakukan prediksi real-time untuk model ML tertentu dengan melakukan `CreateRealtimeEndpoint`, `DeleteRealtimeEndpoint`, dan `Predict` tindakan pada model tersebut.

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"
  ] } ] }
```

Contoh 4: Izinkan pengguna memperbarui dan menghapus sumber daya tertentu

Kebijakan berikut memungkinkan pengguna atau grup untuk memperbarui dan menghapus sumber daya tertentu di akun AWS Anda dengan memberi mereka izin untuk melakukan `UpdateDataSource`, `UpdateMLModel`, `UpdateBatchPrediction`, `UpdateEvaluation`, `DeleteMLModel`, dan `DeleteEvaluation` tindakan pada sumber daya tersebut di akun Anda.

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"  
] } ] }
```

Contoh 5: Izinkan Amazon apa pun MLAction

Kebijakan berikut memungkinkan pengguna atau grup untuk menggunakan tindakan Amazon ML apa pun. Karena kebijakan ini memberikan akses penuh ke semua sumber pembelajaran mesin Anda, batasi hanya untuk administrator.

JSON

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

Pencegahan "confused deputy" lintas layanan

Masalah "confused deputy" adalah masalah keamanan di mana entitas yang tidak memiliki izin untuk melakukan tindakan dapat memengaruhi entitas yang memiliki hak akses lebih tinggi untuk melakukan tindakan. Pada tahun AWS, peniruan lintas layanan dapat mengakibatkan masalah wakil yang membingungkan. Peniruan identitas lintas layanan dapat terjadi ketika satu layanan (layanan yang dipanggil) memanggil layanan lain (layanan yang dipanggil). Layanan pemanggilan dapat dimanipulasi menggunakan izinnya untuk bertindak pada sumber daya pelanggan lain dengan cara yang seharusnya tidak dilakukannya kecuali bila memiliki izin untuk mengakses. Untuk mencegah hal ini, AWS menyediakan alat yang membantu Anda melindungi data untuk semua layanan dengan principal layanan yang telah diberi akses ke sumber daya di akun Anda.

Sebaiknya gunakan kunci konteks kondisi `aws:SourceAccount` global `aws:SourceArn` dan global dalam kebijakan sumber daya untuk membatasi izin yang diberikan Amazon Machine Learning layanan lain ke sumber daya. Jika nilai `aws:SourceArn` tidak berisi ID akun, seperti ARN bucket Amazon S3, Anda harus menggunakan kedua kunci konteks kondisi global tersebut untuk membatasi izin. Jika Anda menggunakan kunci konteks kondisi global dan nilai `aws:SourceArn` berisi ID akun, nilai `aws:SourceAccount` dan akun dalam nilai `aws:SourceArn` harus menggunakan ID akun yang sama saat digunakan dalam pernyataan kebijakan yang sama. Gunakan `aws:SourceArn` jika Anda ingin hanya satu sumber daya yang akan dikaitkan dengan akses lintas layanan. Gunakan `aws:SourceAccount` jika Anda ingin mengizinkan sumber daya apa pun di akun tersebut dikaitkan dengan penggunaan lintas layanan.

Cara paling efektif untuk melindungi dari masalah "confused deputy" adalah dengan menggunakan kunci konteks kondisi global `aws:SourceArn` dengan ARN lengkap sumber daya. Jika Anda tidak mengetahui ARN lengkap sumber daya atau jika Anda menentukan beberapa sumber daya, gunakan kunci kondisi konteks `aws:SourceArn` global dengan wildcard (*) untuk bagian ARN yang tidak diketahui. Misalnya, `arn:aws:service:*:123456789012:*`.

Contoh berikut menunjukkan bagaimana Anda dapat menggunakan kunci konteks kondisi `aws:SourceAccount` global `aws:SourceArn` dan global di Amazon ML untuk mencegah masalah deputy yang membingungkan saat membaca data dari bucket Amazon S3.

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:*"
      }
    }
  }
]
```

Manajemen Ketergantungan Operasi Asinkron

Operasi Batch di Amazon ML bergantung pada operasi lain agar berhasil diselesaikan. Untuk mengelola dependensi ini, Amazon ML mengidentifikasi permintaan yang memiliki dependensi, dan memverifikasi bahwa operasi telah selesai. Jika operasi belum selesai, Amazon ML menyalurkan permintaan awal hingga operasi yang mereka andalkan selesai.

Ada beberapa dependensi antara operasi batch. Misalnya, sebelum Anda dapat membuat model ML, Anda harus telah membuat sumber data yang dapat digunakan untuk melatih model ML. Amazon ML tidak dapat melatih model ML jika tidak ada sumber data yang tersedia.

Namun, Amazon ML mendukung manajemen ketergantungan untuk operasi asinkron. Misalnya, Anda tidak perlu menunggu sampai statistik data telah dihitung sebelum Anda dapat mengirim permintaan untuk melatih model ML pada sumber data. Sebagai gantinya, segera setelah sumber data dibuat, Anda dapat mengirim permintaan untuk melatih model ML menggunakan sumber data.

Amazon ML tidak benar-benar memulai operasi pelatihan sampai statistik sumber data telah dihitung. MLModel Permintaan `create` dimasukkan ke dalam antrian sampai statistik telah dihitung; setelah itu selesai, Amazon ML segera mencoba untuk menjalankan operasi `createMLModel`. Demikian pula, Anda dapat mengirim prediksi batch dan permintaan evaluasi untuk model ML yang belum menyelesaikan pelatihan.

Tabel berikut menunjukkan persyaratan untuk melanjutkan dengan tindakan AmazonML yang berbeda

Dalam rangka untuk...	Anda harus memiliki...
Buat model ML (<code>createMLModel</code>)	Sumber data dengan statistik data yang dihitung
Buat prediksi batch (<code>createBatchPrediction</code>)	Sumber data Model ML
Buat evaluasi batch (<code>createBatchEvaluation</code>)	Sumber data Model ML

Memeriksa Status Permintaan

Saat mengirimkan permintaan, Anda dapat memeriksa statusnya dengan Amazon Machine Learning (Amazon ML) API. Misalnya, jika Anda mengirimkan `createMLModel` permintaan, Anda dapat memeriksa statusnya dengan menggunakan `describeMLModel` panggilan. Amazon ML merespons dengan salah satu status berikut.

Status	Definisi
PENDING	Amazon ML memvalidasi permintaan tersebut. ATAU Amazon ML sedang menunggu sumber daya komputasi tersedia sebelum menjalankan permintaan. Ini mungkin terjadi ketika akun Anda telah melebihi jumlah maksimum permintaan operasi batch

Status	Definisi
	yang berjalan bersamaan. Jika ini masalahnya, status akan beralih ke InProgress saat permintaan lain yang berjalan telah selesai atau dibatalkan. ATAU Amazon ML sedang menunggu operasi batch yang bergantung pada permintaan Anda untuk diselesaikan.
TIDAK BERKEMBANG	Permintaan Anda masih berjalan.
DISELESAIKAN	Permintaan telah selesai, dan objek siap digunakan (model dan sumber data ML) atau dilihat (prediksi dan evaluasi batch).
FAILED	Ada yang salah dengan data yang Anda berikan, atau Anda telah membatalkan operasi. Misalnya, jika Anda mencoba menghitung statistik data pada sumber data yang gagal diselesaikan, Anda mungkin menerima pesan status Tidak Valid atau Gagal. Pesan kesalahan menjelaskan mengapa operasi tidak berhasil diselesaikan.
DELETED	Objek sudah dihapus.

Amazon ML juga menyediakan informasi tentang objek, seperti ketika Amazon ML selesai membuat objek itu. Untuk informasi selengkapnya, lihat [Daftar Objek](#).

Batas Sistem

Untuk memberikan layanan yang kuat dan andal, Amazon ML memberlakukan batasan tertentu pada permintaan yang Anda buat ke sistem. Sebagian besar masalah ML cocok dengan mudah dalam kendala ini. Namun, jika Anda menemukan bahwa penggunaan Amazon ML dibatasi oleh batasan ini, Anda dapat menghubungi [layanan pelanggan AWS](#) dan meminta agar batas tersebut dinaikkan. Misalnya, Anda mungkin memiliki batas lima untuk jumlah pekerjaan yang dapat Anda jalankan secara bersamaan. Jika Anda menemukan bahwa Anda sering memiliki pekerjaan antrian yang menunggu sumber daya karena batas ini, maka mungkin masuk akal untuk menaikkan batas itu untuk akun Anda.

Tabel berikut menunjukkan batas default per akun di Amazon ML. Tidak semua batasan ini dapat dinaikkan oleh layanan pelanggan AWS.

Jenis Batas	Batas Sistem
Ukuran setiap pengamatan	100 KB
Ukuran data pelatihan*	100 GB
Ukuran input prediksi batch	1 TB
Ukuran input prediksi batch (jumlah catatan)	100 juta
Jumlah variabel dalam file data (skema)	1.000
Kompleksitas resep (jumlah variabel keluaran yang diproses)	10.000
TPS untuk setiap titik akhir prediksi waktu nyata	200
Total TPS untuk semua titik akhir prediksi waktu nyata	10.000
Total RAM untuk semua titik akhir prediksi waktu nyata	10 GB
Jumlah pekerjaan simultan	25
Waktu lari terpanjang untuk pekerjaan apa pun	7 hari
Jumlah kelas untuk model Multiclass Multiclass	100
Ukuran model ML	Minimal 1 MB, maksimal 2 GB
Jumlah tag per objek	50

- Ukuran file data Anda terbatas untuk memastikan bahwa pekerjaan selesai tepat waktu. Pekerjaan yang telah berjalan selama lebih dari tujuh hari akan dihentikan secara otomatis, menghasilkan status GAGAL.

Nama dan IDs untuk semua Objek

Setiap objek di Amazon ML harus memiliki pengenalan, atau ID. Konsol Amazon ML menghasilkan nilai ID untuk Anda, tetapi jika Anda menggunakan API, Anda harus membuatnya sendiri. Setiap ID harus unik di antara semua objek Amazon dengan jenis yang sama di akun AWS Anda. Artinya, Anda tidak dapat memiliki dua evaluasi dengan ID yang sama. Dimungkinkan untuk memiliki evaluasi dan sumber data dengan ID yang sama, meskipun tidak disarankan.

Kami menyarankan Anda menggunakan pengidentifikasi yang dibuat secara acak untuk objek Anda, diawali dengan string pendek untuk mengidentifikasi jenisnya. Misalnya, ketika konsol Amazon menghasilkan sumber data, ia menetapkan sumber data ID unik acak seperti “ds-ZSC F”. Wlu WiOx ID ini cukup acak untuk menghindari tabrakan untuk setiap pengguna tunggal, dan juga ringkas dan mudah dibaca. Awalan “ds-” adalah untuk kenyamanan dan kejelasan, tetapi tidak diperlukan. Jika Anda tidak yakin apa yang harus digunakan untuk string ID Anda, sebaiknya gunakan nilai UUID heksadesimal (seperti 28b1e915-57e5-4e6c-a7bd-6fb4e729cb23), yang sudah tersedia di lingkungan pemrograman modern apa pun.

String ID dapat berisi huruf ASCII, angka, tanda hubung dan garis bawah, dan dapat mencapai 64 karakter. Dimungkinkan dan mungkin nyaman untuk menyandikan metadata ke dalam string ID. Tetapi tidak disarankan karena sekali objek telah dibuat, ID-nya tidak dapat diubah.

Nama objek menyediakan cara mudah bagi Anda untuk mengaitkan metadata yang mudah digunakan dengan setiap objek. Anda dapat memperbarui nama setelah objek dibuat. Hal ini memungkinkan nama objek untuk mencerminkan beberapa aspek alur kerja ML Anda. Misalnya, Anda mungkin awalnya menamai model ML “eksperimen #3”, dan kemudian mengganti nama model “model produksi akhir”. Nama dapat berupa string apa pun yang Anda inginkan, hingga 1.024 karakter.

Objek Lifetimes

Setiap sumber data, model, evaluasi, atau objek prediksi batch apa pun yang Anda buat dengan Amazon ML akan tersedia untuk Anda gunakan setidaknya selama dua tahun setelah pembuatan. Amazon ML mungkin secara otomatis menghapus objek yang belum diakses atau digunakan selama lebih dari dua tahun.

Sumber daya

Sumber daya terkait berikut dapat membantu Anda ketika bekerja dengan layanan ini.

- [Informasi produk Amazon ML](#) — Menangkap semua informasi produk terkait tentang Amazon ML di lokasi pusat.
- [Amazon ML FAQs](#) - Meliputi pertanyaan teratas yang diajukan pengembang tentang produk ini.
- [Kode sampel Amazon ML—Contoh](#) aplikasi yang menggunakan Amazon ML. Anda dapat menggunakan kode sampel sebagai titik awal untuk membuat aplikasi ML Anda sendiri.
- [Referensi API Amazon ML](#) — Menjelaskan semua operasi API untuk Amazon ML secara detail. Ini juga menyediakan permintaan sampel dan tanggapan untuk protokol layanan web yang didukung.
- [AWS Developer Resource Center](#) — Menyediakan titik awal utama untuk menemukan dokumentasi, contoh kode, catatan rilis, dan informasi lainnya untuk membantu Anda membangun aplikasi inovatif dengan AWS.
- [Pelatihan dan Kursus AWS](#) — Menautkan ke kursus berbasis peran dan khusus serta laboratorium mandiri untuk membantu mempertajam keterampilan AWS Anda dan mendapatkan pengalaman praktis.
- [AWS Developer Tools](#) — Tautan ke alat pengembang dan sumber daya yang menyediakan dokumentasi, contoh kode, catatan rilis, dan informasi lainnya untuk membantu Anda membangun aplikasi inovatif dengan AWS.
- [AWS Support Center](#) — Hub untuk membuat dan mengelola kasus dukungan AWS Anda. Juga termasuk tautan ke sumber daya bermanfaat lainnya, seperti forum, teknis, status kesehatan layanan FAQs, dan AWS Trusted Advisor.
- [AWS Support](#) — Halaman web utama untuk informasi tentang AWS Support one-on-one, saluran dukungan respons cepat untuk membantu Anda membangun dan menjalankan aplikasi di cloud.
- [Hubungi Kami](#) — Titik kontak pusat untuk pertanyaan tentang penagihan AWS, akun Anda, peristiwa, penyalahgunaan, dan masalah lainnya.
- [Ketentuan Situs AWS](#) — Informasi terperinci tentang hak cipta dan merek dagang kami; akun, lisensi, dan akses situs Anda; dan topik lainnya.

Riwayat Dokumen

Tabel berikut menjelaskan perubahan penting pada dokumentasi dalam rilis Amazon Machine Learning (Amazon ML) ini.

- Versi API: 2015-04-09
- Update dokumentasi terakhir: 2016-08-02

Perubahan	Deskripsi	Tanggal Diubah
Metrik ditambahkan	Rilis Amazon ML ini menambahkan metrik baru untuk objek Amazon ML. Untuk informasi selengkapnya, lihat Daftar Objek .	2 Agustus 2016
Hapus beberapa objek	Rilis Amazon ML ini menambahkan kemampuan untuk menghapus beberapa objek Amazon ML. Untuk informasi selengkapnya, lihat Menghapus Objek .	20 Juli 2016
Tagging ditambahkan	Rilis Amazon ML ini menambahkan kemampuan untuk menerapkan tag ke objek Amazon ML. Untuk informasi selengkapnya, lihat Menandai Objek Amazon MLmu .	23 Juni 2016
Menyalin sumber data Amazon Redshift	Rilis Amazon ML ini menambahkan kemampuan menyalin pengaturan sumber data Amazon Redshift ke sumber data Amazon Redshift baru. Untuk informasi selengkapnya tentang menyalin setelah sumber data Amazon Redshift, lihat. Menyalin Sumber Data (Konsol)	11 April 2016
Shuffling ditambahkan	Rilis Amazon ML ini menambahkan kemampuan untuk mengacak data input Anda.	5 April 2016

Perubahan	Deskripsi	Tanggal Diubah
	Untuk informasi selengkapnya tentang penggunaan parameter Jenis acak, lihat Jenis Kocokan untuk Data Pelatihan .	
Pembuatan sumber data yang ditingkatkan dengan Amazon Redshift	Rilis Amazon ML ini menambahkan kemampuan untuk menguji setelan Amazon Redshift Anda saat Anda membuat sumber data Amazon ML di konsol untuk memverifikasi bahwa koneksi berfungsi. Untuk informasi selengkapnya, lihat Membuat Sumber Data dengan Amazon Redshift Data (Konsol) .	21 Maret 2016
Peningkatan konversi skema data Amazon Redshift	Rilis Amazon ML ini meningkatkan konversi skema data Amazon Redshift (Amazon Redshift) ke skema data Amazon Amazon. Untuk informasi selengkapnya tentang menggunakan Amazon Redshift dengan Amazon ML, lihat Membuat Sumber Data Amazon ML dari Data di Amazon Redshift	9 Februari 2016
CloudTrail logging ditambahkan	Rilis Amazon ML ini menambahkan kemampuan untuk mencatat permintaan menggunakan AWS CloudTrail (CloudTrail). Untuk informasi selengkapnya tentang menggunakan CloudTrail logging, lihat Mencatat Panggilan API Amazon ML dengan AWS CloudTrail .	10 Desember 2015
DataRearrangement Opsi tambahan ditambahkan	Rilis Amazon ML ini menambahkan kemampuan untuk membagi data input Anda secara acak dan membuat sumber data pelengkap. Untuk informasi selengkapnya tentang penggunaan DataRearrangement parameter, lihat Penataan Ulang Data . Untuk informasi tentang cara menggunakan opsi baru untuk validasi silang, lihat Validasi Lintas	3 Desember 2015

Perubahan	Deskripsi	Tanggal Diubah
Mencoba prediksi waktu nyata	<p>Rilis Amazon ML ini menambahkan kemampuan untuk mencoba prediksi real-time di konsol layanan.</p> <p>Untuk informasi selengkapnya tentang mencoba prediksi real-time, lihat Meminta Prediksi Waktu Nyata di Panduan Pengembang Amazon Machine Learning.</p>	19 November 2015
Wilayah Baru	<p>Rilis Amazon ML ini menambahkan dukungan untuk wilayah UE (Irlandia).</p> <p>Untuk informasi selengkapnya tentang Amazon ML di wilayah UE (Irlandia), Wilayah dan titik akhir lihat di Panduan Pengembang Amazon Machine Learning.</p>	20 Agustus 2015
Rilis Awal	<p>Ini adalah rilis pertama dari Amazon ML Developer Guide.</p>	9 April 2015