



Perkiraan permintaan kapasitas pengiriman dengan menggunakan Amazon AI SageMaker

# AWS Panduan Preskriptif



# AWS Panduan Preskriptif: Perkiraan permintaan kapasitas pengiriman dengan menggunakan Amazon AI SageMaker

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 di antara pelanggan, atau dengan cara apa pun yang merendahkan 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

|                                                |     |
|------------------------------------------------|-----|
| Pengantar .....                                | 1   |
| Arsitektur .....                               | 3   |
| Data .....                                     | 5   |
| Data internal .....                            | 5   |
| Data eksternal .....                           | 5   |
| Model pembelajaran mesin .....                 | 6   |
| Model ML untuk perkiraan fitur masukan .....   | 6   |
| Model ML untuk perkiraan variabel target ..... | 7   |
| Masukan pengguna .....                         | 8   |
| Praktik terbaik .....                          | 9   |
| Langkah selanjutnya .....                      | 11  |
| Sumber daya .....                              | 12  |
| Dokumentasi Amazon Cepat .....                 | 12  |
| Dokumentasi Amazon SageMaker AI .....          | 12  |
| AWS contoh kode .....                          | 12  |
| Riwayat dokumen .....                          | 13  |
| .....                                          | xiv |

# Perkiraan permintaan kapasitas pengiriman dengan menggunakan Amazon AI SageMaker

Tianxia Jia dan Hengzhi Chen, Amazon Web Services (AWS)

Mei 2024 ([riwayat dokumen](#))


Peramalan permintaan sangat penting dalam industri transportasi dan logistik, terutama selama periode kendala rantai pasokan. Perkiraan permintaan pengiriman yang akurat menguntungkan perusahaan yang terlibat dalam logistik dan rantai pasokan, seperti yang mengirimkan kontainer dan kargo udara melintasi perbatasan. Ini membantu perusahaan secara efektif mengelola biaya mengamankan jaringan transportasi mereka, yang membantu mereka mengelola biaya pengiriman dan memaksimalkan pendapatan dan keuntungan.

Model pembelajaran mesin (ML) yang mampu membuat perkiraan akurat bergantung pada data pelatihan berkualitas tinggi. Untuk peramalan permintaan, data pelatihan dapat mencakup volume permintaan historis dan data yang dihasilkan secara internal lainnya yang dapat dikaitkan dengan volume, seperti harga, inventaris, dan jumlah karyawan tim penjualan. Selain itu, data eksternal, seperti pesaing, lingkungan pasar, liburan, cuaca, dan ekonomi makro, juga dapat mempengaruhi volume permintaan. Faktor data internal dan eksternal ini dapat digunakan sebagai fitur dalam model ML.

Setelah semua fitur diidentifikasi, bisnis mungkin juga ingin memberikan masukan ke beberapa fitur ini yang berada dalam kendali mereka. Misalnya, bisnis dapat menetapkan harga pengiriman terlebih dahulu atau memutuskan kapan harus melakukan promosi dan diskon. Jenis input pengguna ini dapat dimasukkan ke dalam model saat membuat perkiraan.


Panduan ini menjelaskan strategi untuk membangun solusi AWS yang membuat perkiraan permintaan logistik yang akurat dengan menggunakan model ML. Anda melatih model pada kumpulan data historis yang berisi volume permintaan dan fitur yang terkait dengan permintaan. Fitur dan metrik ini mencakup data organik internal dan data eksternal. Solusi ini juga memberikan fleksibilitas bagi pengguna dan analis bisnis untuk memberikan masukan, yang kemudian dapat dimasukkan ke dalam model perkiraan.

Gambar berikut menunjukkan contoh deret waktu historis dan rentang perkiraan 12 bulan. Anda dapat menggunakan rekomendasi dalam panduan ini untuk membuat model ML yang menghasilkan jenis perkiraan ini.



# Arsitektur untuk meramalkan permintaan pengiriman

Gambar berikut menunjukkan alur kerja solusi, termasuk konsumsi data, persiapan data, pembuatan model, dan output akhir dan pemantauan.



Arsitektur solusi mencakup komponen utama berikut:

1. Konsumsi data - Anda menyimpan data organik dan data eksternal di Amazon [Simple Storage Service \(Amazon S3\)](#).
2. Persiapan data — [Amazon SageMaker AI](#) membersihkan data dan menyiapkannya untuk pelatihan model ML. Untuk informasi selengkapnya, lihat [Mempersiapkan data](#) dalam dokumentasi SageMaker AI.
3. Pembuatan model: Prakiraan fitur input - SageMaker AI menggunakan [Prophet](#) untuk menghasilkan perkiraan deret waktu untuk setiap fitur input. Anda memeriksa hasil perkiraan. Jika diperlukan, Anda memberikan input pengguna untuk menimpa perkiraan fitur.
4. Pembuatan model: Prakiraan variabel target - SageMaker AI membuat model regresi untuk inferensi dengan menggunakan fitur input yang dimodifikasi.
5. Output dan pemantauan model - Model regresi mengeluarkan hasil perkiraan ke Amazon S3. Anda dapat memvisualisasikan ramalan di [Amazon QuickSight](#). Analis dapat memantau hasil perkiraan dan mengevaluasi akurasi dengan membandingkan perkiraan dengan volume permintaan aktual.

Seluruh pipa pemrosesan dari konsumsi data hingga keluaran model akhir dapat diatur untuk berjalan secara otomatis. Misalnya, Anda dapat mengaturnya untuk berjalan secara otomatis setiap bulan untuk perkiraan permintaan bulanan. Jika Anda membutuhkan perkiraan untuk lebih dari satu produk, Anda dapat menjalankan pipeline secara paralel untuk beberapa produk. Untuk informasi selengkapnya, lihat [Menerapkan MLOP](#) dalam dokumentasi SageMaker AI.

# Data untuk memperkirakan permintaan pengiriman

Data berkualitas tinggi sangat penting untuk setiap model ML untuk membuat prediksi dan perkiraan yang bermakna. Untuk perkiraan permintaan, dataset terdiri dari data yang relevan yang dapat mempengaruhi permintaan akhir. Data ini bisa berasal dari berbagai sumber. Anda dapat mengklasifikasikan data ini menjadi dua kategori, data internal dan eksternal.

## Data internal

Data internal adalah data organik yang dihasilkan bisnis. Data ini biasanya disimpan di gudang data, seperti [Amazon Redshift](#).

Anda dapat langsung menghasilkan atau mengekstrak nilai output target dari tabel di gudang data yang berisi volume historis untuk produk yang diminati. Untuk perusahaan pelayaran, output atau nilai target dapat dalam satuan muatan kontainer penuh untuk pengiriman laut atau berat total untuk kargo udara.


Anda juga dapat menghasilkan berbagai metrik bisnis historis. Ini dapat digunakan sebagai fitur dalam model pembelajaran mesin saat memperkirakan permintaan. Contoh fitur termasuk harga historis, biaya, kapasitas, dan inventaris.

## Data eksternal

Sumber data eksternal dapat digunakan sebagai fitur tambahan untuk meningkatkan akurasi perkiraan. Contoh sumber data eksternal termasuk data cuaca, data ekonomi makro, data industri, dan data pasar. Faktor-faktor ini dapat berdampak langsung atau tidak langsung terhadap industri logistik dan transportasi, sehingga mempengaruhi permintaan. Misalnya, tarif pengiriman pasar memberikan tolok ukur pasar pengiriman global, yang pada akhirnya mempengaruhi permintaan spesifik perusahaan. Data ekonomi makro, seperti data impor dan ekspor untuk ekonomi utama, juga dapat digunakan sebagai ukuran aktivitas pasar. Untuk menggabungkan sumber data eksternal ini, Anda dapat menggunakan berbagai API untuk mencerna data. Misalnya, St. Louis Fed menyediakan [Federal Reserve Economic Data \(FRED\) API](#) untuk mengakses data ekonomi makro, dan National Oceanic and Atmospheric Administration (NOAA) menyediakan [Climate Data Online \(CDO\) API](#) untuk mengakses data cuaca di seluruh dunia.

# Model pembelajaran mesin untuk memperkirakan permintaan pengiriman

Gambar berikut menunjukkan contoh data pelatihan. Targetnya adalah apa yang ingin Anda prediksi, dan deret waktu terkait 1 dan 2 adalah fitur input yang relevan untuk memprediksi target. Data historis digunakan untuk pelatihan dan validasi, dan Anda menahan periode data historis untuk validasi model.



Dalam peramalan permintaan, output (atau target) adalah volume permintaan yang ingin Anda prediksi. Fitur input adalah data deret waktu yang terkait dengan output. Untuk melatih model ML untuk membuat perkiraan volume permintaan yang akurat, dua model pembelajaran mesin diperlukan dalam solusinya. Model pertama membuat perkiraan deret waktu untuk fitur input, termasuk data internal dan eksternal. Model kedua membuat perkiraan permintaan akhir dengan menggunakan semua fitur. Dengan menggunakan kedua model ini bersama-sama, Anda dapat secara efektif menangkap tren deret waktu dan hubungan antara target dan input.

## Model ML untuk perkiraan fitur masukan

Fitur input mencakup data deret waktu historis internal dan eksternal. Untuk membuat prakiraan untuk setiap fitur, Anda dapat menggunakan model deret waktu satu dimensi (1D). Ada berbagai algoritma yang tersedia. Misalnya, [Prophet](#) bekerja paling baik dengan deret waktu dengan efek musiman yang kuat dan beberapa musim data historis. Perkiraan dihasilkan untuk setiap fitur individu.

## Model ML untuk perkiraan variabel target

Model ML untuk output, atau volume permintaan, dibangun untuk menangkap hubungan antara semua fitur dan output. Anda dapat menggunakan berbagai model regresi yang diawasi, seperti, lasso ridge regression, random forest dan. XGBoost Saat membangun model dan menemukan parameter dan hiperparameter terbaik, Anda dapat menggunakan data penahanan. Data Holdout adalah bagian dari data historis berlabel yang ditahan dari dataset yang digunakan untuk melatih model pembelajaran mesin. Anda dapat menggunakan data penahanan untuk mengevaluasi kinerja model dengan membandingkan prediksi terhadap data penahanan.

# Input pengguna untuk memperkirakan permintaan pengiriman

Meskipun masa depan sebagian besar fitur tidak diketahui, mungkin ada beberapa fitur yang dapat dikendalikan oleh bisnis. Misalnya, harga adalah salah satu fitur yang biasanya memiliki hubungan yang kuat dengan volume permintaan. Karena bisnis menetapkan harga, Anda tahu kapan harga akan naik atau kapan akan ada diskon atau promosi. Selain itu, ukuran tim penjualan juga dapat memengaruhi volume permintaan, dan bisnis mengontrol seberapa besar tim penjualan mereka. Untuk titik data yang dikelola bisnis ini, Anda dapat memberikan input pengguna. Pada langkah pemodelan ML, model deret waktu 1D memberikan perkiraan untuk setiap fitur, kemudian pengguna dapat memeriksa nilai yang diperkirakan ini dan menimpa mereka dengan input pengguna. Input yang ditimpa ini kemudian digunakan dalam model saat membuat perkiraan akhir.

Langkah masukan pengguna ini dapat menjadi penting dalam situasi di mana perkiraan model deret waktu 1D tidak sesuai dengan harapan bisnis tentang perilaku masa depan fitur tersebut. Anda dapat menimpa nilai perkiraan ini, yang dapat meningkatkan perkiraan output keseluruhan.

# Praktik terbaik untuk model ML yang memperkirakan permintaan pengiriman

Dengan mengikuti praktik terbaik ini, Anda dapat meningkatkan akurasi, keandalan, dan interpretasi model pembelajaran mesin Anda untuk memperkirakan permintaan pengiriman, yang pada akhirnya mengarah pada pengambilan keputusan dan efisiensi operasional yang lebih baik:

- **Kualitas data dan preprocessing** — Pastikan bahwa data yang digunakan untuk melatih model berkualitas tinggi dan bebas dari kesalahan, nilai yang hilang, dan inkonsistensi. Langkah-langkah pra-pemrosesan data, seperti menangani nilai yang hilang, deteksi outlier, dan rekayasa fitur, memainkan peran penting dalam meningkatkan akurasi model.
- **Data historis yang memadai** — Memiliki data historis yang memadai sangat penting untuk menangkap pola, tren, dan musim. Namun, penting juga untuk mempertimbangkan relevansi dan ketepatan waktu data historis. Jika ada perubahan signifikan di pasar, operasi bisnis, atau faktor eksternal, data lama mungkin tidak mewakili skenario saat ini. Dalam situasi ini, berikan bobot yang lebih tinggi ke data yang lebih baru.
- **Pemilihan dan rekayasa fitur** - Mengidentifikasi fitur yang relevan dan merekayasa fitur baru dari data yang ada dapat secara signifikan meningkatkan kinerja model. Berkolaborasi erat dengan pakar domain untuk menggunakan pengetahuan dan wawasan mereka saat memilih fitur yang sesuai. Selain itu, pertimbangkan untuk melakukan analisis kepentingan fitur untuk mengidentifikasi fitur yang paling berpengaruh dan berpotensi menghapus fitur yang berlebihan atau tidak relevan.
- **Model ansambel** — Alih-alih mengandalkan satu model, pertimbangkan untuk menggunakan teknik ansambel yang menggabungkan prediksi beberapa model. Model ansambel dapat mengungguli model individual dan memberikan perkiraan yang lebih kuat dan akurat.
- **Evaluasi dan validasi model** — Evaluasi dan validasi kinerja model secara teratur dengan menggunakan metrik yang sesuai, seperti mean squared error (MSE), mean absolute percentage error (MAPE), atau metrik spesifik domain lainnya. Gunakan validasi silang atau validasi penahanan untuk menilai kemampuan generalisasi model.
- **Pemantauan dan pelatihan ulang berkelanjutan** — Pola permintaan barang dapat berubah seiring waktu karena berbagai faktor, seperti kondisi ekonomi, dinamika pasar, atau perubahan dalam operasi bisnis. Terus memantau kinerja model dan melatih ulang secara berkala dengan data terbaru untuk meningkatkan akurasi dan relevansinya.
- **AI yang Dapat Dijelaskan** - Model peramalan permintaan harus dapat ditafsirkan dan dijelaskan, terutama dalam kasus di mana pemangku kepentingan perlu memahami alasan di balik perkiraan.

Teknik seperti analisis kepentingan fitur, plot ketergantungan paral, penjelasan Shapley Additive (SHAP) dapat membantu menjelaskan keputusan model.

- Menggabungkan pengetahuan domain — Berkolaborasi erat dengan pakar domain dan pemangku kepentingan bisnis untuk memasukkan pengetahuan dan wawasan mereka ke dalam proses pemodelan. Keahlian domain mereka dapat membantu mengidentifikasi potensi bias, menafsirkan hasil, dan membuat keputusan berdasarkan perkiraan.
- Analisis skenario dan simulasi bagaimana-jika — Menggabungkan kemampuan untuk melakukan analisis skenario dan simulasi bagaimana-jika ke dalam solusi peramalan. Hal ini memungkinkan pemangku kepentingan untuk mengeksplorasi efek dari keputusan bisnis yang berbeda atau faktor eksternal pada perkiraan permintaan, memungkinkan pengambilan keputusan yang lebih tepat.
- Pipeline otomatis dan terukur — Bangun pipeline otomatis dan terukur untuk konsumsi data, pra-pemrosesan, pelatihan model, dan penerapan. Ini secara konsisten dan efisien mengeksekusi proses peramalan, terutama ketika berhadapan dengan beberapa produk atau wilayah.

## Langkah selanjutnya

Sebelum Anda menerapkan solusi peramalan permintaan ini AWS, Anda disarankan untuk mengevaluasi masalah yang Anda coba pecahkan. Ini adalah ide yang baik untuk membawa pemilik bisnis dan ilmuwan data bersama-sama untuk bertukar pikiran apakah masalah dapat diselesaikan dengan model ML. Sangat penting untuk memahami kumpulan data apa yang Anda miliki dan panjang data historis yang tersedia. Penting juga bagi pemilik bisnis untuk berkolaborasi dengan ilmuwan data untuk memberikan pengetahuan domain, mengidentifikasi fitur yang berguna, dan membantu membuat fitur tersebut. Keandalan model meningkat dengan jumlah fitur relevan yang dapat Anda buat, yang memberikan perkiraan yang lebih akurat.

Untuk membangun arsitektur ini AWS, mulailah dengan menyiapkan Akun AWS dan menyediakan layanan yang diperlukan, seperti Amazon Simple Storage Service (Amazon S3) untuk penyimpanan data dan SageMaker Amazon AI untuk pelatihan model pembelajaran mesin. Selanjutnya, identifikasi dan kumpulkan sumber data internal dan eksternal yang akan digunakan sebagai fitur input untuk model peramalan. Simpan data ini di Amazon S3 dan gunakan kemampuan pemrosesan data di SageMaker AI untuk memproses dan menyiapkan data untuk pelatihan model. Dalam SageMaker AI, gunakan penyetelan model otomatis dan kemampuan pelatihan terdistribusi untuk melatih dan mengoptimalkan model peramalan. Anda juga dapat menggunakan Layanan AWS seperti AWS Step Functions atau AWS Lambda untuk mengatur pipa yang secara berkala melatih ulang model peramalan dengan data terbaru. Setelah pelatihan ulang, mulailah pekerjaan transformasi batch di SageMaker AI untuk menghasilkan hasil perkiraan, yang Anda simpan di Amazon S3. Gunakan Amazon Quick untuk memvisualisasikan dan memantau hasil perkiraan yang dihasilkan dari pekerjaan transformasi batch.

# Sumber daya

## Dokumentasi Amazon Cepat

- [Apa itu Amazon Quick?](#)
- [Bekerja dengan sumber data](#)

## Dokumentasi Amazon SageMaker AI

- [Apa itu Amazon SageMaker AI?](#)
- [Siapkan data](#)
- [Lakukan penyetelan model otomatis](#)
- [Gunakan transformasi batch](#)

## AWS contoh kode

- [Repositori contoh Amazon SageMaker AI](#) () GitHub

## Riwayat dokumen

Tabel berikut menjelaskan perubahan signifikan pada panduan ini. Jika Anda ingin diberi tahu tentang pembaruan masa depan, Anda dapat berlangganan [RSSumpnan](#).

| Perubahan                      | Deskripsi | Tanggal     |
|--------------------------------|-----------|-------------|
| <a href="#">Publikasi awal</a> | —         | 14 Mei 2024 |

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