



Previsión de la demanda de capacidad de carga mediante Amazon AI
SageMaker

AWS Orientación prescriptiva



AWS Orientación prescriptiva: Previsión de la demanda de capacidad de carga mediante Amazon AI SageMaker

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

Las marcas comerciales y la imagen comercial de Amazon no se pueden utilizar en relación con ningún producto o servicio que no sea de Amazon, de ninguna manera que pueda causar confusión entre los clientes y que menosprecie o desacredite a Amazon. Todas las demás marcas registradas que no son propiedad de Amazon son propiedad de sus respectivos propietarios, que pueden o no estar afiliados, conectados o patrocinados por Amazon.

Table of Contents

Introducción 1

Arquitectura 3

Datos 5

Datos internos 5

Datos externos 5

Modelos de aprendizaje automático 6

Modelo ML para el pronóstico de las características de entrada 6

Modelo ML para la previsión de la variable objetivo 7

Entradas de usuario 8

Prácticas recomendadas 9

Siguientes pasos 11

Recursos 12

Documentación de Amazon Quick 12

Documentación de Amazon SageMaker AI 12

AWS ejemplos de código 12

Historial de documentos 13

..... xiv

Previsión de la demanda de capacidad de carga mediante Amazon AI SageMaker

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

Mayo de 2024 ([historia del documento](#))


La previsión de la demanda es fundamental en la industria del transporte y la logística, especialmente durante los períodos de restricciones en la cadena de suministro. Las estimaciones precisas de la demanda de carga benefician a las empresas que participan en la logística y la cadena de suministro, como las que envían contenedores y cargas aéreas a través de las fronteras. Esto ayuda a las empresas a gestionar eficazmente el coste de proteger su red de transporte, lo que les ayuda a gestionar los costes de envío y a maximizar los ingresos y las ganancias.

Un modelo de aprendizaje automático (ML) capaz de realizar un pronóstico preciso depende de datos de formación de alta calidad. Para la previsión de la demanda, los datos de formación pueden incluir el volumen histórico de la demanda y otros datos generados internamente que podrían estar relacionados con el volumen, como el precio, el inventario y la plantilla del equipo de ventas. Además, los datos externos, como la competencia, el entorno del mercado, las vacaciones, el clima y la macroeconomía, también podrían afectar al volumen de la demanda. Estos factores de datos internos y externos se pueden utilizar como características en un modelo de aprendizaje automático.

Una vez identificadas todas las funciones, es posible que la empresa también desee proporcionar información sobre algunas de estas funciones que están bajo su control. Por ejemplo, la empresa puede fijar el precio de envío por adelantado o decidir cuándo realizar promociones y descuentos. Estos tipos de entradas de los usuarios se pueden incorporar al modelo al realizar la previsión.


Esta guía describe una estrategia para crear una solución AWS que haga una previsión precisa de la demanda logística mediante el uso de un modelo de aprendizaje automático. El modelo se basa en un conjunto de datos históricos que contiene el volumen de la demanda y las características relacionadas con la demanda. Estas características y métricas incluyen datos orgánicos internos y datos externos. La solución también proporciona la flexibilidad necesaria para que el usuario y el analista empresarial proporcionen información, que luego se puede incorporar al modelo de previsión.

La siguiente imagen muestra un ejemplo de una serie temporal histórica y un rango previsto de 12 meses. Puede utilizar las recomendaciones de esta guía para crear un modelo de aprendizaje automático que produzca este tipo de previsión.



Arquitectura para pronosticar la demanda de carga

La siguiente imagen muestra el flujo de trabajo de la solución, que incluye la ingesta de datos, la preparación de los datos, la creación de modelos y el resultado final y la supervisión.



La arquitectura de la solución incluye los siguientes componentes principales:

1. Ingesta de datos: los datos orgánicos y los datos externos se almacenan en [Amazon Simple Storage Service \(Amazon S3\)](#).
2. Preparación de datos: [Amazon SageMaker AI](#) limpia los datos y los prepara para el entrenamiento de modelos de aprendizaje automático. Para obtener más información, consulte [Preparar datos](#) en la documentación sobre SageMaker IA.
3. Creación de modelos: previsión de entidades de entrada: la SageMaker IA utiliza [Prophet](#) la IA para generar una previsión de series temporales para cada entidad de entrada. Se examinan los resultados de la previsión. Si es necesario, proporciona las entradas del usuario para sobrescribir la previsión de la función.
4. Creación de modelos: previsión de variables objetivo: la SageMaker IA crea un modelo de regresión para la inferencia mediante las funciones de entrada modificadas.
5. Salida y supervisión del modelo: el modelo de regresión envía los resultados de la previsión a Amazon S3. Puedes visualizar la previsión en [Amazon QuickSight](#). Los analistas pueden supervisar los

resultados de las previsiones y evaluar la precisión comparándolas con el volumen de demanda real.

Todo el proceso de procesamiento, desde la ingesta de datos hasta la producción final del modelo, se puede organizar para que se ejecute automáticamente. Por ejemplo, puede configurarlo para que se ejecute automáticamente de forma mensual para una previsión de la demanda mensual. Si necesita previsiones para más de un producto, puede ejecutar la canalización en paralelo para varios productos. Para obtener más información, consulte [Implementación de MLOP](#) en la documentación de SageMaker IA.

Datos para pronosticar la demanda de carga

Los datos de alta calidad son esenciales para que cualquier modelo de aprendizaje automático pueda realizar una predicción y un pronóstico significativos. En el caso de las previsiones de demanda, el conjunto de datos se compone de cualquier dato relevante que pueda afectar a la demanda final. Estos datos pueden provenir de varias fuentes. Puede clasificar estos datos en dos categorías, datos internos y externos.

Datos internos

Los datos internos son datos orgánicos generados por la empresa. Estos datos suelen almacenarse en un almacén de datos, como [Amazon Redshift](#).

Puede generar o extraer directamente los valores de salida objetivo de las tablas del almacén de datos que contienen los volúmenes históricos de los productos de interés. En el caso de las compañías navieras, los productos o valores objetivo pueden expresarse en unidades de carga de contenedores completos en el caso del transporte marítimo o en el peso total de la carga aérea.


También puede generar varias métricas comerciales históricas. Se pueden utilizar como características del modelo de aprendizaje automático a la hora de pronosticar la demanda. Las características de ejemplo incluyen el precio histórico, el costo, la capacidad y el inventario.

Datos externos

Las fuentes de datos externas se pueden utilizar como funciones adicionales para mejorar la precisión del pronóstico. Entre los ejemplos de fuentes de datos externas se incluyen los datos meteorológicos, los datos macroeconómicos, los datos del sector y los datos de mercado. Estos factores pueden tener un impacto directo o indirecto en la industria de la logística y el transporte y, por lo tanto, afectar a la demanda. Por ejemplo, la tarifa de flete del mercado proporciona un punto de referencia del mercado mundial de fletes, lo que, en última instancia, afecta a la demanda específica de la empresa. Los datos macroeconómicos, como los datos de importación y exportación de las principales economías, también podrían utilizarse como medida de la actividad del mercado. Para incorporar estas fuentes de datos externas, puede usar varias API para ingerir datos. Por ejemplo, St. Louis Fed proporciona el acceso [Federal Reserve Economic Data \(FRED\) API](#) a los datos macroeconómicos y National Oceanic and Atmospheric Administration (NOAA) proporciona el acceso [Climate Data Online \(CDO\) API](#) a los datos meteorológicos mundiales.

Modelos de aprendizaje automático para pronosticar la demanda de carga

La siguiente imagen muestra un ejemplo de los datos de entrenamiento. El objetivo es lo que se quiere predecir, y las series temporales 1 y 2 relacionadas son características de entrada que son relevantes para predecir el objetivo. Los datos históricos se utilizan para el entrenamiento y la validación, y se retiene un período de los datos históricos para la validación del modelo.



En la previsión de la demanda, el resultado (o el objetivo) es el volumen de demanda que se desea predecir. Las entidades de entrada son datos de series temporales relacionados con la salida. Para entrenar un modelo de aprendizaje automático para realizar una previsión precisa del volumen de la demanda, se necesitan dos modelos de aprendizaje automático en la solución. El primer modelo hace una previsión de series temporales para las características de entrada, que incluye datos internos y externos. El segundo modelo realiza la previsión final de la demanda utilizando todas las funciones. Al usar estos dos modelos juntos, puede capturar de manera efectiva tanto la tendencia de la serie temporal como la relación entre el objetivo y las entradas.

Modelo ML para el pronóstico de las características de entrada

Las características de entrada incluyen datos de series temporales históricas internas y externas. Para realizar pronósticos para cada entidad, puede utilizar un modelo de series temporales unidimensional (1D). Hay varios algoritmos disponibles. Por ejemplo, [Prophet](#) funciona mejor con series temporales con fuertes efectos estacionales y varias temporadas de datos históricos. Se genera una previsión para cada elemento individual.

Modelo ML para la previsión de la variable objetivo

El modelo ML para la salida, o el volumen de demanda, está diseñado para capturar la relación entre todas las características y la salida. Puede utilizar varios modelos de regresión supervisada como ridge regression, random forest, y XGBoost. Al crear el modelo y buscar los mejores parámetros e hiperparámetros, puede utilizar datos de reserva. Los datos de reserva son una parte de los datos históricos etiquetados que se ocultan del conjunto de datos que se utiliza para entrenar un modelo de aprendizaje automático. Puede utilizar los datos de reserva para evaluar el rendimiento del modelo comparando las predicciones con los datos de reserva.

Entradas de usuario para pronosticar la demanda de carga

Aunque se desconoce el futuro de la mayoría de las funciones, es posible que la empresa controle algunas de ellas. Por ejemplo, el precio es una característica que suele tener una fuerte relación con el volumen de demanda. Debido a que la empresa establece los precios, usted sabe cuándo aumentarán los precios o cuándo habrá un descuento o promoción. Además, el tamaño del equipo de ventas también puede afectar al volumen de la demanda, y las empresas controlan el tamaño de sus equipos de ventas. Para estos puntos de datos que gestiona la empresa, puede proporcionar las entradas de los usuarios. En el paso de modelado mediante aprendizaje automático, los modelos de series temporales 1D proporcionan una previsión para cada entidad. A continuación, los usuarios pueden examinar estos valores pronosticados y sobrescribirlos con las entradas de los usuarios. Estas entradas sobrescritas se utilizan luego en el modelo al realizar la previsión final.

Este paso introducido por el usuario puede ser fundamental en situaciones en las que las previsiones del modelo de series temporales 1D no coinciden con las expectativas de la empresa sobre el comportamiento futuro de la función. Puede sobrescribir estos valores pronosticados, lo que puede mejorar la previsión de producción general.

Mejores prácticas para un modelo de aprendizaje automático que predice la demanda de carga

Si sigue estas prácticas recomendadas, puede mejorar la precisión, la confiabilidad y la interpretabilidad de su modelo de aprendizaje automático para pronosticar la demanda de carga y, en última instancia, mejorar la toma de decisiones y la eficiencia operativa:

- **Calidad de los datos y preprocesamiento:** asegúrese de que los datos utilizados para entrenar el modelo sean de alta calidad y estén libres de errores, valores faltantes e inconsistencias. Los pasos previos al procesamiento de los datos, como la gestión de los valores faltantes, la detección de valores atípicos y la ingeniería de características, desempeñan un papel crucial a la hora de mejorar la precisión del modelo.
- **Datos históricos suficientes:** disponer de datos históricos suficientes es esencial para captar patrones, tendencias y estacionalidad. Sin embargo, también es importante tener en cuenta la relevancia y la puntualidad de los datos históricos. Si se han producido cambios significativos en el mercado, las operaciones comerciales o los factores externos, es posible que los datos más antiguos no sean representativos del escenario actual. En esta situación, dé mayor importancia a los datos más recientes.
- **Selección de características e ingeniería:** identificar las características relevantes y diseñar nuevas características a partir de los datos existentes puede mejorar significativamente el rendimiento del modelo. Colabore estrechamente con expertos en el campo para utilizar sus conocimientos y perspectivas a la hora de seleccionar las características adecuadas. Además, considere la posibilidad de realizar un análisis de la importancia de las funciones para identificar las funciones más influyentes y, potencialmente, eliminar las funciones redundantes o irrelevantes.
- **Modelos de conjunto:** en lugar de confiar en un único modelo, considere la posibilidad de utilizar técnicas de conjunto que combinen las predicciones de varios modelos. Los modelos de conjunto pueden superar a los modelos individuales y proporcionar pronósticos más sólidos y precisos.
- **Evaluación y validación del modelo:** evalúe y valide periódicamente el rendimiento del modelo mediante el uso de las métricas adecuadas, como el error cuadrático medio (MSE), el error porcentual absoluto medio (MAPE) o cualquier otra métrica específica del dominio. Utilice la validación cruzada o la validación de espera para evaluar las capacidades de generalización del modelo.
- **Supervisión y reciclaje continuos:** los patrones de demanda de carga pueden cambiar con el tiempo debido a diversos factores, como las condiciones económicas, la dinámica del mercado o

los cambios en las operaciones comerciales. Supervise continuamente el rendimiento del modelo y vuelva a entrenarlo periódicamente con los datos más recientes para mejorar su precisión y relevancia.

- **IA explicable:** los modelos de previsión de la demanda deben ser interpretables y explicables, especialmente en los casos en que las partes interesadas necesitan entender el razonamiento que subyace a las previsiones. Técnicas como el análisis de la importancia de las características, los gráficos de dependencia parcial y las explicaciones aditivas de Shapley (SHAP) pueden ayudar a explicar las decisiones del modelo.
- **Incorpore el conocimiento del dominio:** colabore estrechamente con expertos en el campo y las partes interesadas de la empresa para incorporar sus conocimientos e ideas en el proceso de modelado. Su experiencia en el campo puede ayudar a identificar posibles sesgos, interpretar los resultados y tomar decisiones informadas en función de las previsiones.
- **Análisis de escenarios y simulaciones hipotéticas:** incorpore la capacidad de realizar análisis de escenarios y simulaciones hipotéticas en la solución de previsión. Esto permite a las partes interesadas explorar el efecto de diferentes decisiones empresariales o factores externos en la previsión de la demanda, lo que permite una toma de decisiones más informada.
- **Canalización automatizada y escalable:** cree una canalización automatizada y escalable para la ingesta, el preprocesamiento, la formación de modelos y la implementación de datos. Esto permite ejecutar el proceso de previsión de forma coherente y eficiente, especialmente cuando se trata de varios productos o regiones.

Siguientes pasos

Antes de implementar esta solución de previsión de la demanda AWS, se recomienda que evalúe el problema que intenta resolver. Es una buena idea reunir a los propietarios de empresas y a los científicos de datos para intercambiar ideas sobre si el problema se puede resolver con un modelo de aprendizaje automático. Es fundamental comprender los conjuntos de datos de los que dispone y la longitud de los datos históricos disponibles. También es importante que los propietarios de las empresas colaboren con los científicos de datos para proporcionarles conocimientos sobre el dominio, identificar funciones útiles y ayudar a crear esas funciones. La confiabilidad del modelo aumenta con la cantidad de características relevantes que se pueden crear, lo que proporciona una previsión más precisa.

Para construir esta arquitectura AWS, comience por configurar Cuenta de AWS y aprovisionar los servicios necesarios, como Amazon Simple Storage Service (Amazon S3) para el almacenamiento de datos y SageMaker Amazon AI para el entrenamiento de modelos de aprendizaje automático. A continuación, identifique y recopile las fuentes de datos internas y externas que se utilizarán como funciones de entrada para el modelo de previsión. Almacene estos datos en Amazon S3 y utilice las capacidades de procesamiento de datos de la SageMaker IA para preprocesar y preparar los datos para el entrenamiento del modelo. En el SageMaker caso de la IA, utilice el ajuste automático de los modelos y las capacidades de entrenamiento distribuido para entrenar y optimizar los modelos de previsión. También puede utilizarlas Servicios de AWS , por ejemplo, AWS Lambda para configurar una canalización que rediseñe periódicamente los modelos de previsión con los datos más recientes.

AWS Step Functions Tras volver a capacitarse, inicie un trabajo de transformación por lotes en SageMaker IA para generar los resultados de las previsiones, que almacenará en Amazon S3. Utilice Amazon Quick para visualizar y supervisar los resultados de previsión generados a partir del trabajo de transformación por lotes.

Recursos

Documentación de Amazon Quick

- [¿Qué es Amazon Quick?](#)
- [Trabajar con fuentes de datos](#)

Documentación de Amazon SageMaker AI

- [¿Qué es Amazon SageMaker AI?](#)
- [Prepare los datos](#)
- [Realice el ajuste automático del modelo](#)
- [Utilice la transformación por lotes](#)

AWS ejemplos de código

- [Repositorio de ejemplos de Amazon SageMaker AI](#) (GitHub)

Historial de documentos

En la siguiente tabla, se describen cambios significativos de esta guía. Si quieres recibir notificaciones sobre futuras actualizaciones, puedes suscribirte a un [RSSfeed](#).

Cambio	Descripción	Fecha
Publicación inicial	—	14 de mayo de 2024

Las traducciones son generadas a través de traducción automática. En caso de conflicto entre la traducción y la version original de inglés, prevalecerá la version en inglés.