



Forecasting para bienestar social: series de tiempo para optimizar la distribución equitativa de medicamentos de alto costo

Forecasting for Social Welfare: Time Series for Optimizing the Equitable Distribution of High-Cost Medicines

Forecasting para bem-estar social: séries temporais para otimizar a distribuição equitativa de medicamentos de alto custo

Donovan-Steven Picón-Sossa¹

Marco-Javier Suarez Barón²

Juan-Sebastián González-Sanabria³

Recibido: 7 de mayo de 2025

Aceptado: 27 de noviembre de 2025

Para citar este artículo: Picón-Sossa, D. S., Suarez Barón, S. B. y González-Sanabria, J. S. (2025). *Forecasting para bienestar social: series de tiempo para optimizar la distribución equitativa de medicamentos de alto costo*. *Revista Científica*, 52(2), 38-57. <https://doi.org/10.14483/23448350.23604>

Resumen

El acceso a medicamentos de alto costo representa uno de los desafíos más complejos y críticos en la gestión de los sistemas de salud, especialmente en regiones con limitaciones económicas y estructurales. Con el fin de mitigar dicho impacto, este estudio propone el uso de modelos de *forecasting*, integrando series de tiempo para anticipar la demanda y promover una distribución más eficiente, equitativa y justa. Para ello, se utiliza un conjunto de datos mensuales que incluye un registro de cuatro años de consumo hospitalario, el cual ha sido tratado y enriquecido con información pública de costos, en aras de identificar los medicamentos de mayor impacto económico. Se utiliza la metodología MLOps para la creación, automatización y validación de tres modelos: Prophet, XGBoost y SARIMAX. Cada uno de estos modelos es optimizado con búsqueda de hiperparámetros y es evaluado mediante validación cruzada y métricas como el MAPE, el RMSE y el MAE. Los resultados muestran que Prophet destaca en precisión relativa, al captar tendencias y estacionalidades suaves; que XGBoost se ajusta mejor en unidades absolutas ante variaciones abruptas; y que SARIMAX modela ciclos recurrentes con solidez. Estas fortalezas permiten adaptar el enfoque según los objetivos de planificación, e.g., optimizar precisión porcentual o reducir el error en volumen.

Palabras clave: AI4SG, bienestar social, distribución justa, *forecasting*, medicamentos de alto costo, modelos predictivos, series de tiempo

1. Universidad Pedagógica y Tecnológica de Colombia, Tunja, Colombia. donovan.picon@uptc.edu.co
2. PhD Universidad Pedagógica y Tecnológica de Colombia, Tunja, Colombia. marco.suarez@uptc.edu.co
3. MSc Universidad Pedagógica y Tecnológica de Colombia, Tunja, Colombia. juansebastian.gonzalez@uptc.edu.co

Abstract

Access to high-cost medication represents one of the most complex and critical challenges in managing health systems, especially in regions with economic and structural limitations. To mitigate said impact, this study proposes the use of forecasting models, integrating time series to anticipate demand and promote a more efficient, equitable, and fair distribution. To this effect, a monthly dataset is used which includes a four-year record of hospital consumption, which has been processed and enriched with public cost information in order to identify the medications with the highest economic impact. The MLOps methodology is employed for the creation, automation, and validation of three models: Prophet, XGBoost, and SARIMAX. Each of these models is optimized through hyperparameter search and evaluated using cross-validation and metrics such as MAPE, RMSE, and MAE. The results show that Prophet stands out in relative accuracy by capturing smooth trends and seasonalities, that XGBoost fits better in absolute units when facing abrupt variations, and that SARIMAX robustly models recurring cycles. These strengths allow adapting the approach according to planning objectives, e.g., optimizing percentage accuracy or reducing volume-related error.

Keywords: AI4SG, social welfare, fair distribution, forecasting, high-cost medicines, predictive models, time series

Resumo

O acesso a medicamentos de alto custo representa um dos desafios mais complexos e críticos na gestão dos sistemas de saúde, especialmente em regiões com limitações econômicas e estruturais. Com o objetivo de mitigar esse impacto, este estudo propõe o uso de modelos de forecasting, integrando séries temporais para antecipar a demanda e promover uma distribuição mais eficiente, equitativa e justa. Para isso, utiliza-se um conjunto de dados mensais que inclui um registro de quatro anos de consumo hospitalar, tratado e enriquecido com informações públicas de custos, com o propósito de identificar os medicamentos de maior impacto econômico. A metodologia MLOps é empregada para a criação, automação e validação de três modelos: Prophet, XGBoost e SARIMAX. Cada um desses modelos é otimizado por meio de busca de hiperparâmetros e avaliado mediante validação cruzada e métricas como MAPE, RMSE e MAE. Os resultados mostram que o Prophet se destaca em precisão relativa, ao captar tendências e sazonalidades suaves; que o XGBoost apresenta melhor desempenho em unidades absolutas diante de variações abruptas; e que o SARIMAX modela ciclos recorrentes com robustez. Essas fortalezas permitem adaptar a abordagem segundo os objetivos de planejamento, por exemplo, otimizar a precisão percentual ou reduzir o erro em volume.

Palavras-chaves: AI4SG, bem-estar social, distribuição justa, *forecasting*, medicamentos de alto custo, modelos preditivos, séries temporais

INTRODUCCIÓN

El acceso a medicamentos de alto costo ha cobrado una relevancia creciente en las últimas décadas, pues su disponibilidad condiciona no solo la equidad en el tratamiento de enfermedades críticas, sino también la sostenibilidad financiera de los sistemas de salud a nivel global. Así, el acceso a estos medicamentos se convierte en un factor clave para el éxito o fracaso de tratamientos para enfermedades que requieren terapias complejas y costosas ([Mousa & Al-Khateeb, 2023](#)). La escalada de precios y la complejidad de los procesos de producción e importación exigen estrategias que vayan más allá de la simple asignación presupuestaria, orientándose hacia modelos predictivos capaces de optimizar la distribución de recursos y mejorar la calidad de vida de los pacientes ([Zhu et al., 2021](#)).

Este es un problema que afecta gravemente a los países en desarrollo, especialmente en América Latina, y en particular a Colombia, donde las limitaciones estructurales, como las infraestructuras sanitarias

insuficientes, la escasez de personal calificado y las restricciones presupuestales generan retrasos en la entrega de insumos esenciales, expandiendo las brechas de acceso entre zonas urbanas y rurales ([Wong et al., 2025](#)). A nivel mundial, la incertidumbre en la demanda y la falta de técnicas de pronóstico públicas y robustas provocan desajustes frecuentes en los inventarios, lo que genera tanto acumulaciones innecesarias como desabastecimientos críticos que comprometen la atención oportuna de los pacientes ([Nguyen et al., 2022](#); [Argiyantari et al., 2020](#)).

En este contexto, los métodos tradicionales de planificación que están basados proyecciones lineales (modelos ingenuos) resultan insuficientes ante entornos cambiantes y cada vez más complejos como las cadenas de suministro de medicamentos ([Li et al., 2023](#)). Por otro lado, el uso de modelos predictivos avanzados en sectores como el comercial y el logístico ha sido exitoso en la toma de decisiones, lo que evidencia la urgencia de implementar mejores modelos de *forecasting* en el sector de la salud ([Hezam et al., 2024](#)).

Por ello, es necesario replantear cómo se aborda la planificación del abastecimiento en situaciones de alta incertidumbre, enfocándose principalmente en la identificación temprana de cambios en los patrones de consumo de medicamentos de alto costo y su impacto en la equidad en el acceso. Asimismo, comprender las variaciones de forma precisa y oportuna es el desafío clave para mejorar la asignación de recursos y la toma de decisiones informadas en salud pública.

Frente a este escenario, las técnicas de predicción basadas en lógica bayesiana surgen como enfoques prometedores para realizar predicciones precisas, además de permitir la mejora continua mediante la incorporación recurrente de nuevos datos históricos, mejorando las predicciones con cada nueva adición, lo que permite gestionar la incertidumbre y adaptar las predicciones al ritmo real de la demanda ([Seyedan & Mafakheri, 2020](#)). Los modelos de *forecasting* basados en lógica bayesiana tienen el potencial de capturar tanto patrones regulares como variaciones abruptas en el consumo, lo cual resulta fundamental para anticiparse a la demanda de medicamentos de alto costo en contextos donde la escasez y la desigualdad predominan.

Con este enfoque no solo se busca optimizar los procesos de abastecimiento y distribución en la cadena de suministros; también se busca democratizar el acceso a tecnologías enfocadas en la mejora del sistema sanitario, permitiendo mejorar la toma de decisiones a nivel estratégico y operativo y abriendo nuevas posibilidades para la planificación con base en la evidencia histórica, lo que permitirá reducir las desigualdades en el acceso a tratamientos y mejorar la eficiencia en la asignación de recursos públicos ([Rostami-Tabar et al., 2022](#)).

Así las cosas, esta investigación se enfoca en el diseño y la implementación de modelos de *forecasting* que integran la lógica bayesiana con el propósito de anticipar las variaciones en la demanda del consumo de medicamentos de alto costo y transformar la planificación logística en los sistemas de salud, sentando las bases para un sistema de atención más equitativo, resiliente y enfocado en el bienestar social de la población ([Wang et al., 2024](#)).

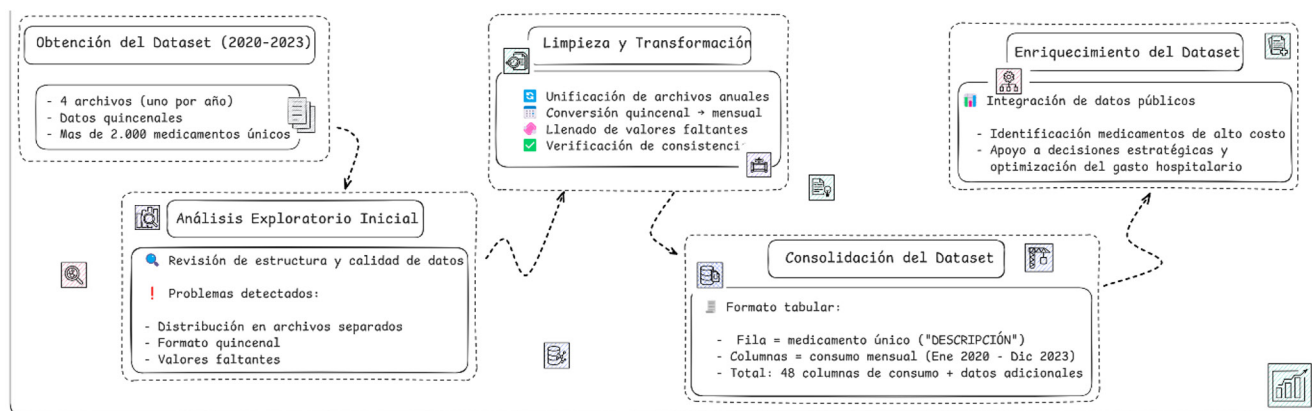
MATERIALES Y MÉTODOS

El enfoque de investigación de este trabajo fue cuantitativo y aplicado, dado que buscaba desarrollar una solución basada en *machine learning operations* (MLOps) para la implementación eficiente y automatizada de modelos de *forecasting* con lógica bayesiana. La lógica bayesiana permite incorporar información previa a los modelos de predicción, mejorando su capacidad para capturar la incertidumbre y adaptar las estimaciones a nuevos datos. El caso de estudio estuvo centrado en la aplicación de técnicas de

forecasting basadas en la lógica bayesiana y en la combinación de estrategias de optimización y aprendizaje automático para pronosticar la demanda de medicamentos de alto costo. Asimismo, se utilizaron los registros mensuales de consumo de medicamentos e insumos obtenidos del Hospital Universitario San Rafael de Tunja (Boyacá, Colombia). De igual manera, se extrajeron los consumos de los medicamentos catalogados como de alto costo, en aras de centrar el análisis en los medicamentos más críticos en términos de valor monetario al interior del sistema de salud.

El objetivo del proyecto fue brindar información para la toma de decisiones estratégicas que afectan la cadena de suministro de medicamentos a nivel regional. Al considerar una estacionalidad mensual en los consumos, los modelos permitieron capturar e identificar tendencias y patrones en el comportamiento de la demanda, lo cual facilitó la planificación y optimización de la producción, el almacenamiento y la distribución de estos medicamentos esenciales. Así, se buscó no solo mejorar la eficiencia en la asignación de recursos, sino también contribuir a una distribución más equitativa y a un mejor bienestar social en el ámbito sanitario (Rostami-Tabar *et al.*, 2022).

Figura 1. Consolidación de datos



Después de recopilar los datos (Figura 1), la primera etapa de la metodología consistió en el análisis exploratorio, donde se identificaron más de 2000 medicamentos e insumos médicos únicos. Durante esta primera fase, se detectaron problemas en la estructura y calidad de los datos. Inicialmente, la información se encontraba distribuida en diversos archivos de cálculo independientes, así como en un registro quincenal de los datos, lo cual dificultaba su análisis como una serie temporal mensual. Fue necesario llevar a cabo un proceso de limpieza, transformación y consolidación del *dataset*, que incluyó la unificación de los archivos, la conversión de los valores quincenales en datos mensuales, la asignación de datos faltantes y la verificación de consistencia en los registros.

A raíz de estas transformaciones, se obtuvo un conjunto de datos consolidado en formato mensual, lo que facilitó su análisis como serie temporal. Finalmente, el *dataset* quedó organizado de tal manera que cada fila representaba un medicamento único, identificado mediante la columna *Descripción*, y cada columna adicional correspondía al consumo registrado mes a mes, abarcando un total de 48 meses entre enero de 2020 y diciembre de 2023.

Con el objetivo de complementar el análisis sobre medicamentos de alto impacto económico, se integró información pública (https://www.datos.gov.co/Salud-y-Proteccion-Social/Clicsalud-Term-metro-de-Precios-de-Medicamentos/n4dj-8r7k/about_data). El recurso mencionado contiene más de 12 500

registros de medicamentos comercializados en el país, con variables como principio activo, concentración, canal de distribución y precio unitario.

De igual manera, se compararon las descripciones del hospital con los nombres comerciales del *dataset*, utilizando algoritmos de similitud textual. Solo se consideraron coincidencias con una puntuación de más del 65 %. Además, el emparejamiento redujo el universo de análisis de 2258 a 1131 medicamentos, excluyendo aquellos sin correspondencia confiable. Finalmente, se aplicó un filtro sobre la columna *factoresprecio*, seleccionando únicamente aquellos medicamentos clasificados como de alto costo. Este campo clasifica el impacto económico de los medicamentos en tres niveles (bajo, medio, alto), con base en su precio unitario en el mercado institucional y comercial.

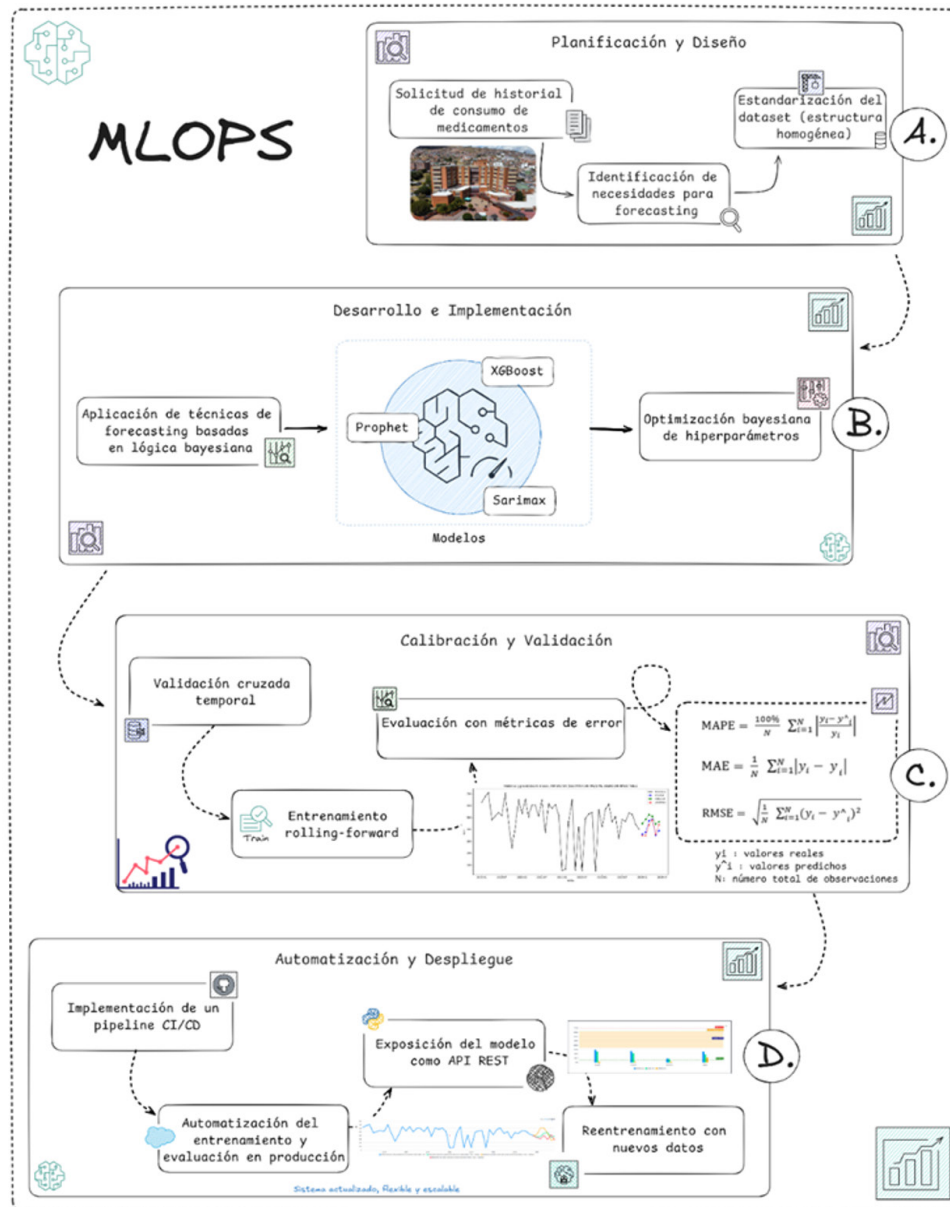
Se identificaron 173 medicamentos de alto costo, sobre los cuales se realizó un análisis predictivo. En la [Tabla 1](#) se presenta una muestra representativa del *dataset* tras el filtrado por costo, incluyendo variables como puntaje de similitud, principio activo, nombre comercial, precio unitario y descripción estándar.

Tabla 1. Muestra de filtrado por factor de precio

Score	Principio Activo	Medicamento	Precio Tableta	Factor Precio	Descripción
84	Acetaminofén y codeína	Aprix-F (Novamed) - Cada tableta contiene: codeína fosfato 30 mg + acetaminofén 325 mg	2310.618	Alto	ACETAMINOFEN + CODEINA (325MG+30MG) TABLETA
100	Acetaminofén y cafeína	Dolofén Forte (Procaps) - Cada tableta contiene: cafeína 50 mg + acetaminofén 500 mg	1010	Alto	ACETAMINOFEN 500 MG TABLETA
100	Acetazolamida	Glaucomed (Mega Labs) - Cada tableta contiene: acetazolamida 250 mg	3064.4	Alto	ACETAZOLAMIDA 250 MG TABLETA
100	Acetazolamida	Glaucomed (Mega Labs) - Cada tableta contiene: acetazolamida 500 mg	530.191	Alto	ACETAZOLAMIDA 500 MG TABLETA
72	Acetilcisteína	Fluimucil (Zambon) - Ampolla 3 ml - Cada 3 ml contiene: n-acetilcisteína 300 mg	5476.6	Alto	ACETILCISTEINA 300 MG /3 ML SOLUCIÓN INYECTABLE
92	Ácido fusídico	Fucidin crema (Leo) - Tubo 15 g - Cada 100 g contiene: ácido fusídico 2 g	86290	Alto	ACIDO FUSÍDICO CREMA 2% TUBO X 15 GR

Se adoptó el paradigma MLOps, pues reúne los principios de desarrollo de *software* y la gestión de sistemas para la integración efectiva de modelos predictivos en entornos reales. Durante el proceso de desarrollo e implementación, se aplicaron técnicas de *forecasting* basadas en lógica bayesiana, siguiendo un flujo metodológico en el que se definieron, estructuraron y calibraron los modelos predictivos para anticipar la demanda de medicamentos de alto costo.

Figura 2. Arquitectura de flujo de trabajo



Según se muestra en la [Figura 2](#), el flujo de trabajo se organizó en cuatro fases:

- 1. Planificación y diseño:** obtención del *dataset*, selección de los modelos y ETL (extracción, transformación y carga) de los datos para el entrenamiento de los modelos.
- 2. Desarrollo e implementación:** entrenamiento de los modelos seleccionados (Prophet, XGBoost y SARIMAX), aplicando técnicas de optimización de hiperparámetros con lógica bayesiana. A partir de este enfoque, se logró una búsqueda más eficiente para mejorar el desempeño de cada uno de los modelos, reduciendo el tiempo de entrenamiento en comparación con métodos de búsqueda tradicionales.

3. **Calibración y validación de modelos:** validación y pruebas de los modelos. Se usaron técnicas de validación cruzada temporal, además de estrategias de entrenamiento *rolling-forward*, que permiten simular escenarios de predicción reales (Muraina et al., 2023). Para medir la discrepancia entre los valores observados y las predicciones, se utilizaron las métricas de la [Tabla 2](#).
4. **Automatización y despliegue:** diseño de un *pipeline* de MLOps que automatizó el entrenamiento; evaluación del modelo en producción, conforme a los principios de integración continua y despliegue continuo (CI/CD). Esta arquitectura se implementó como una API REST, lo que permitió que los usuarios consultaran predicciones de manera flexible y en tiempo real. Además, la automatización del despliegue garantizó que los modelos se reentrenaran dinámicamente a medida que se incorporaban nuevos datos, manteniendo el sistema actualizado y escalable.

Tabla 2. Métricas de predicción

Métrica	Fórmula
Mean absolute percentage error (MAPE)	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $
Mean absolute error (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Root mean squared error (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$

Entre las herramientas seleccionadas, Prophet es un modelo de series temporales desarrollado por Facebook, diseñado para facilitar la predicción de tendencias en datos que presentan estacionalidad y efectos de eventos atípicos. Este modelo descompone la serie en componentes de tendencia, estacionalidad y efectos adicionales, permitiendo ajustes flexibles. Además, Prophet permite incorporar distribuciones de probabilidad sobre sus parámetros, lo que mejora la estimación en presencia de incertidumbre (Taylor & Letham, 2018). Asimismo, consta de diferentes componentes, como tendencia, estacionalidad, autorregresión y regresores adicionales, entre otros. Prophet tiene tres componentes principales: tendencia, estacionalidad y días festivos. Estos componentes se combinan en la Ecuación (1) (Shoha et al., 2022).

$$y(t) = g(t) + s(t) + h(t) + e(t) \quad (1)$$

Donde:

- $g(t)$ es una función de modelado de tendencias que se puede especificar como una función lineal o una función logística.
- $s(t)$ representa una función de estacionalidad que puede ser diaria, semanal y/o anual, la cual se maneja con términos de Fourier.
- $h(t)$ es una función de feriados que considera el efecto de los feriados, que ocurren de manera irregular.
- $e(t)$ representa los cambios de error que no ajusta el modelo.

En esta línea, Neural Prophet (NP) es un sucesor de FbProphet que no se ha introducido en el campo de la previsión de carga de energía. La diferencia fundamental entre estos dos métodos es que NP integra términos de aprendizaje profundo en las ecuaciones que se ajustan a datos rezagados. Los hiperparámetros de este modelo también se pueden ajustar automáticamente para lograr un rendimiento óptimo. Por lo demás, NP tiene el mismo flujo de diseño básico y proceso de pronóstico, con componentes de modelo similares. La [Figura 3](#) representa el flujo de diseño de pronóstico en FbProphet y NP.

Por su parte, SARIMAX (*seasonal autoregressive integrated moving average with exogenous factors*) es una extensión del modelo ARIMA que permite capturar patrones estacionales y efectos de variables exógenas en series temporales. Su capacidad para incorporar componentes estacionales y factores externos lo hace útil en una amplia variedad de aplicaciones, y se ha adoptado en contextos donde es necesario cuantificar la incertidumbre en las predicciones ([Box et al., 2015](#)).

El modelo SARIMAX es una versión mejorada del modelo ARIMA, con factores exógenos (X) como parámetros de características externas para mejorar el rendimiento del modelo, reducir los errores de predicción, superar los problemas de autocorrelación y mejorar los resultados de la predicción. SARIMAX consta tanto de efectos estacionales como de factores exógenos, que pueden usarse como SARIMAX (p, d, q) * (P, D, Q)—los factores exógenos son parámetros opcionales. Estos pueden ser datos externos de series temporales paralelas, como la velocidad del viento o los valores de temperatura, que tienen la misma correlación con los datos originales a predecir. Los factores exógenos se utilizan para respaldar el modelo de predicción y proporcionarle más detalles ([Alharbi & Csala, 2022](#)). El modelo SARIMAX se puede presentar como se muestra en la Ecuación (2), donde $y_{k,t}$ se refiere al número de factores exógenos externos en el momento t , y α_k es el valor del coeficiente de correlación de los factores de entrada exógenos.

$$\varphi_p(G)\varphi_p(G^s)(1-G)^d(1-G^s)^D X_t = \alpha_k y_{k,t} + \gamma_q(G)w_Q(G^s)e_t \quad (2)$$

Por último, XGBoost (*eXtreme gradient boosting*) es un algoritmo de aprendizaje supervisado basado en árboles de decisión que mejora la precisión mediante técnicas de *boosting*. Su alta eficiencia y su capacidad para trabajar con grandes conjuntos de datos lo han convertido en una herramienta muy utilizada. En aplicaciones bayesianas, XGBoost puede integrarse con métodos de optimización bayesiana para la selección de hiperparámetros, lo que mejora su capacidad predictiva ([Chen & Guestrin, 2016](#)). Además, se introduce un sistema de seguridad híbrido basado en *eXtreme gradient boosting* que es capaz de detectar actividad maliciosa en transacciones realizadas con tarjetas de crédito. El método se probó en un conjunto público creado a partir de datos del mundo real sobre transacciones con tarjetas de crédito en Europa. Para manejar el alto desequilibrio del conjunto de datos, se implementó un algoritmo de inteligencia de enjambre llamado *algoritmo de optimización basado en la enseñanza-aprendizaje* ([Petrovic et al., 2023](#)).

El algoritmo XGBoost funciona así ([Espinosa-Zúñiga, 2020](#)):

- Se obtiene un árbol inicial F_0 para predecir la variable objetivo y . El resultado se asocia con un residual $(y - F_0)$.
- Se obtiene un nuevo árbol h_1 que ajusta al error del paso previo.

- Los resultados de F_0 y h_1 se combinan para obtener el árbol F_1 , donde el error cuadrático medio de F_1 será menor que el de F_0 :

$$F_1(x) < -F_0(x) + h_1(x) \quad (3)$$

- Este proceso se sigue iterativamente hasta que el error es minimizado lo máximo posible, así:

$$F_m(x) < -F_{m-1}(x) + h_m(x) \quad (4)$$

RESULTADOS Y DISCUSIÓN

En esta fase se desarrollaron los modelos predictivos para pronosticar la demanda de medicamentos a partir del comportamiento histórico identificado en el *dataset*. Se implementaron tres enfoques complementarios, *i.e.*, Prophet, XGBoost y SARIMAX, optimizados mediante lógica bayesiana ([Shahriari et al., 2015](#)), lo que permitió ajustar sus hiperparámetros con precisión y mejorar su capacidad de predicción. Esta estrategia fue implementada utilizando la librería *BayesianOptimization* de Python, la cual aplica la lógica bayesiana mediante la construcción de un modelo sustituto—generalmente un proceso gaussiano—que estima la función objetivo en el espacio de hiperparámetros.

Prophet

Para optimizar los hiperparámetros del modelo Prophet, se empleó la biblioteca *BayesianOptimization*, con el fin explorar el espacio de parámetros de manera inteligente y minimizar el error de predicción—en este caso, el RMSE promedio obtenido mediante validación cruzada). Se definió una función *prophet_cv* para un par de valores de hiperparámetros (*cps* y *sps*), se entrenó un modelo Prophet y se evaluó su desempeño mediante validación cruzada. La función retornaba el negativo del RMSE promedio, pues la optimización bayesiana maximiza la función objetivo. Se configuró el optimizador estableciendo los rangos de búsqueda para *changepoint_prior_scale* (entre 0.001 y 0.05) y *seasonality_prior_scale* (entre 0.1 y 10). Luego, se ejecutaron varias iteraciones para identificar los valores que minimizaban mejor el error. Cabe resaltar que Prophet se basa en inferencia bayesiana de manera nativa, lo que significa que actualiza sus distribuciones *a priori* con la evidencia proporcionada por los datos para generar intervalos de predicción ([Taylor & Letham, 2018](#)). Como ejemplo del proceso realizado con el modelo Prophet, para el medicamento ACETAZOLAMIDA 250 MG TABLETA, se presentan los resultados mostrados de la [Tabla 3](#).

Tabla 3. Resultados del modelo Prophet

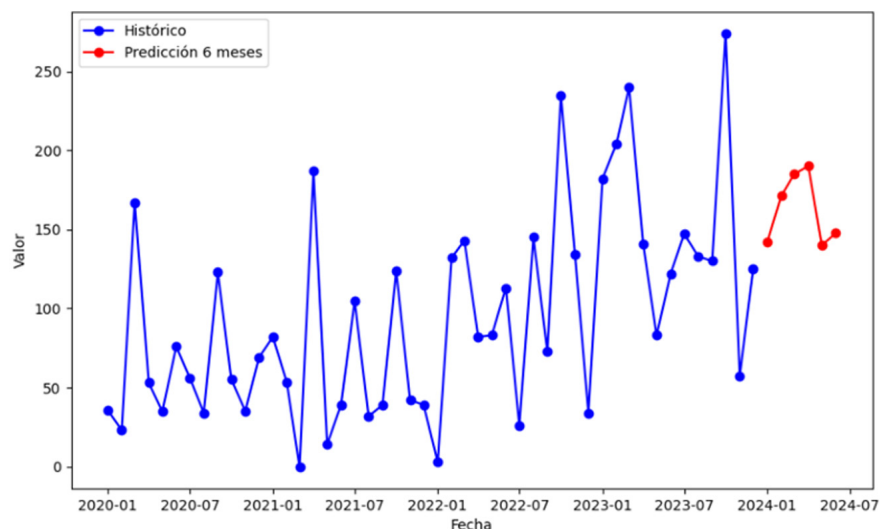
Medicamento	Mape CV	Rmse CV	MAE CV	Best_cps	Best_sps
ACETAZOLAMIDA 250 MG TABLETA	0.570655	82.164118	67.794	0.038512	0.100115

- ***changepoint_prior_scale* (cps).** Este parámetro controla la flexibilidad en la detección de cambios en la tendencia. Un valor de 0.0385 indica que se permite cierta flexibilidad para adaptarse a cambios reales en la serie temporal, sin llegar a un sobreajuste a ruidos o fluctuaciones menores. Esto ayuda a equilibrar la sensibilidad del modelo a cambios bruscos y a mantener la robustez en las predicciones.
- ***seasonality_prior_scale* (sps).** Este parámetro regula la intensidad de la estacionalidad en el modelo. Un valor de 0.1001 sugiere una penalización moderada en la estimación de los patrones estacionales,

lo que permite capturar las variaciones periódicas sin exagerar su influencia, evitando posibles sobreajustes en la parte estacional del modelo.

En la [Figura 3](#) se presenta la predicción del modelo Prophet para ACETAZOLAMIDA 250 MG TABLETA.

Figura 3. Visualización histórica y predicción del modelo Prophet



XGBoost

A diferencia de Prophet, que utiliza internamente un marco bayesiano para la generación de predicciones, XGBoost es un algoritmo de ensamble basado en árboles, cuya precisión puede mejorarse significativamente mediante la optimización de parámetros ([Chen & Guestrin, 2016](#)). En este caso, se definió una función `xgb_cv` que, para un conjunto de valores de hiperparámetros (e.g., `max_depth`, `learning_rate` y `n_estimators`) transforma la serie temporal en un problema supervisado (generando variables de retardo). Se entrenó un modelo XGBoost y se evaluó su desempeño utilizando validación cruzada en el contexto de series temporales. La función retornaba el negativo del error cuadrático medio (MSE), en aras de que la optimización bayesiana maximizara este valor (equivalente a minimizar el error).

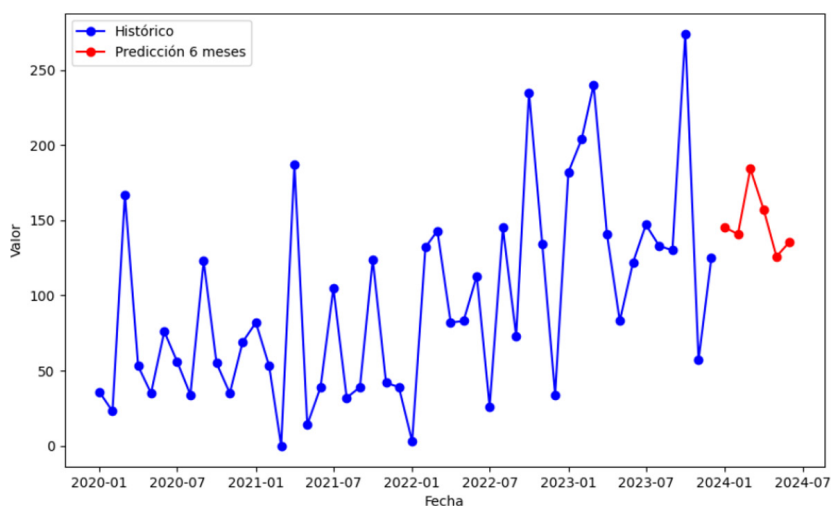
Los hiperparámetros ajustados en el modelo XGBoost tuvieron un impacto directo en términos de capacidad predictiva y estabilidad, a saber:

- **`max_depth` (profundidad máxima del árbol)** determina la complejidad de los árboles utilizados en el ensamble. Un valor alto permite capturar patrones complejos, pero puede generar sobreajuste. En este caso, se encontró un valor óptimo de 3, lo que indica que los árboles más simples fueron suficientes para modelar los datos sin sobreajuste.
- **`learning_rate` (tasa de aprendizaje)** controla la magnitud de los ajustes en cada iteración del entrenamiento. Un valor bajo (como el 0.0769 encontrado en este trabajo) ayuda a evitar grandes oscilaciones en el proceso de optimización y permite un mejor ajuste progresivo.
- **`n_estimators` (número de árboles en el ensamble)** indica cuántos árboles se entrenan. Un número mayor puede mejorar la precisión, pero también aumenta el tiempo de cómputo. El valor óptimo encontrado fue 89, lo que sugiere un balance entre rendimiento y eficiencia.

- **subsample (fracción de datos usada en cada iteración)** controla el muestreo aleatorio de los datos. Un valor de 0.5434 implica que en cada iteración se usa aproximadamente el 54.34 % de los datos, reduciendo la varianza y evitando sobreajuste.
- **colsample_bytree (proporción de características utilizadas por árbol)** determina qué porcentaje de variables se consideran en cada árbol. El valor óptimo de 0.5642 indica que se utilizó aproximadamente el 56.42 % de las características en cada árbol, reduciendo la posibilidad de correlaciones falsas.
- **gamma (reducción mínima de pérdida requerida para hacer una división en un nodo)** es un parámetro de regularización que evita divisiones innecesarias en los árboles. En este caso, el valor de 0.3520 sugiere que solo se realizaron divisiones cuando había una ganancia significativa en la reducción del error.

En la [Figura 4](#) se presenta la predicción del modelo para ACETAZOLAMIDA 250 MG TABLETA con los mejores hiperparámetros.

Figura 4. Visualización histórica y predicción del modelo XGBoost



SARIMAX

Para optimizar el modelo SARIMAX, se exploró el espacio de parámetros y se minimizó el error—en este caso, el RMSE promedio, obtenido mediante validación cruzada. Es importante recordar que en SARIMAX se busca definir adecuadamente el orden del modelo; para simplificarlo, se fijan los parámetros de diferenciación (d y D) y estacionalidad ($s=12$), optimizando los parámetros de orden (p , q) y los estacionales (P , Q). En este trabajo, se definió una función *sarimax_cv* que, para un conjunto de valores de hiperparámetros (p , q , P , Q), entrenaba un modelo SARIMAX con *order* = (p , 1, q) y *seasonal_order* = (P , 1, Q , 12). Esta función evaluaba el desempeño mediante validación cruzada (usando una función de *forecast* en ventana móvil) y retornaba el negativo del RMSE promedio para que la optimización bayesiana lo maximizara.

Se consideraron los siguientes valores de *order* (p , d , q):

- **p (componente autorregresivo en *order*).** Este parámetro indica el número de términos pasados (observaciones previas) que se utilizan para predecir el valor actual. Un valor de 1 significa que el

modelo considera la observación inmediatamente anterior para capturar la tendencia o dependencia temporal.

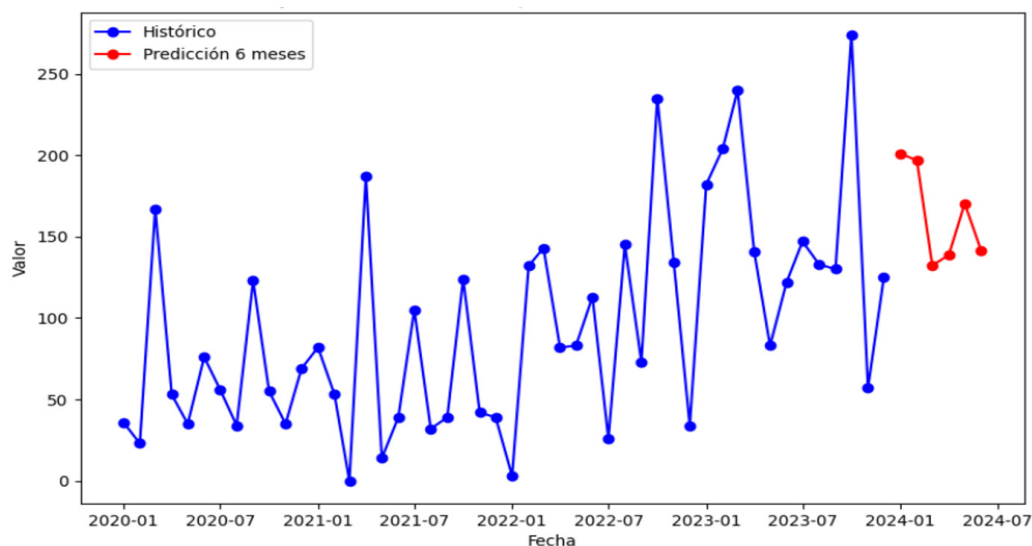
- **d (diferenciación en order)** se refiere al número de veces que se diferencian los datos para construir la serie estacionaria. Cuando toma un valor de 1, se realiza una diferenciación que ayuda a eliminar tendencias y estabilizar la media de la serie.
- **q (componente de media móvil en order)** representa el número de términos pasados de error (residuos) que se usan para ajustar la predicción actual. Un valor de 3 implica que se incorporan tres rezagos del error para suavizar y corregir las predicciones.

Asimismo, *seasonal_order* (P, D, Q, s) permite obtener:

- **P (componente autorregresivo estacional en *seasonal_order*)**: similar a p, pero para el componente estacional. Un valor de 1 indica que se utiliza la observación de la misma estación (e.g., el mismo mes del año anterior) para capturar patrones estacionales.
- **D (diferenciación estacional en *seasonal_order*)** define el número de veces que se diferencian los datos a nivel estacional para eliminar la tendencia estacional. En este caso, $D = 0$ significa que no se realiza diferenciación estacional adicional, lo que puede indicar que la estacionalidad ya es estable o no requiere ajuste.
- **Q (componente de media móvil estacional en *seasonal_order*)** indica cuántos términos pasados de error estacional se incorporan en el modelo. Con un valor de 2, el modelo utiliza dos rezagos estacionales de los errores para mejorar la captura de variaciones periódicas.
- **s (periodicidad de la estacionalidad)** fija la frecuencia de la estacionalidad. Comúnmente se utiliza un valor de 12 para series mensuales, lo que permite capturar ciclos anuales.

En la [Figura 5](#) se presenta la predicción del modelo para ACETAZOLAMIDA 250 MG TABLETA con los mejores hiperparámetros.

Figura 5. Visualización histórica y predicción del modelo SARIMAX



Para evaluar la precisión de los modelos predictivos, se emplearon técnicas de validación cruzada adaptadas a series temporales. En particular, se utilizó la validación cruzada en ventana móvil (*rolling forecast*). Esto permitió medir el rendimiento de los modelos no solo en un único punto de corte, sino a lo largo de múltiples periodos, proporcionando una estimación más realista y robusta de la capacidad predictiva y de generalización de los modelos ajustados. Las métricas utilizadas para evaluar el desempeño en cada uno de los pliegues incluyeron el MAE, el RMSE y el MAPE, seleccionados por su capacidad de ofrecer información complementaria sobre la precisión y el sesgo del modelo.

Análisis exploratorio

El análisis exploratorio desempeñó un papel crucial en el estudio de la dinámica del consumo de medicamentos de alto costo y en la preparación del conjunto de datos para la implementación de los modelos predictivos. En esta etapa se buscó no solo capturar el comportamiento general de las series temporales de los datos históricos del consumo de medicamentos, sino también identificar patrones relevantes en la distribución y la relación entre los medicamentos que tuvieron implicaciones en la fase de modelado.

De igual manera, el análisis exploratorio permitió extraer métricas clave que facilitaron una visión integral del consumo de medicamentos:

- **Total, de medicamentos (únicos).** Se identificaron 2258 medicamentos presentes en al menos una de las hojas, lo que refleja la amplitud del conjunto de datos.
- **Medicamentos presentes en todas las hojas.** Se encontró que 1824 medicamentos cuentan con registros en cada uno de los años (2020 a 2023).
- **Medicamentos con consumo > 0 en cada año.** De los medicamentos presentes en todas las hojas, 1215 presentan un consumo promedio mayor a 0 en cada año. Este subconjunto es especialmente valioso para analizar qué medicamentos tienen una actividad registrada de manera consistente.

Adicionalmente, se realizó un estudio de valores faltantes por medicamento para identificar aquellos con registros más completos. Por ejemplo, se extrajo una Tabla que muestra los diez medicamentos con menor porcentaje de datos faltantes, su descripción y el porcentaje de valores perdidos ([Tabla 4](#)).

Tabla 4. Datos de medicamentos con menor porcentaje de valores faltantes

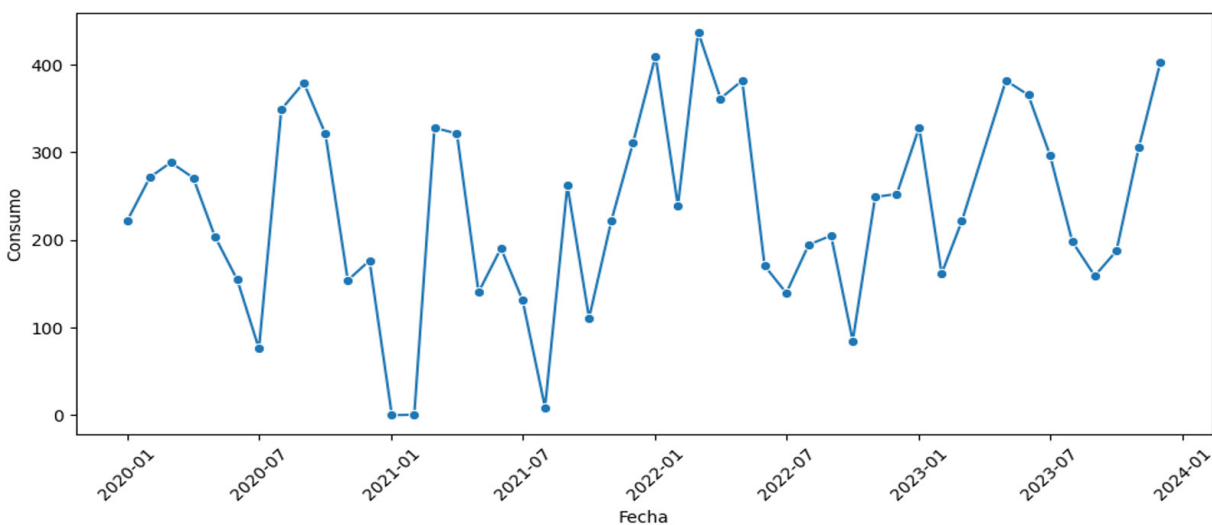
Código	Descripción	% Faltantes
L011708	LIDOCAÍNA SIN EPI 2% X 10 ML FRASCO SOLUCIÓN INYECTABLE	7.61
NP69N01	PROPOFOL 10 MG/ML X 20 ML EMULSIÓN INYECTABLE	7.61
NP20C10	CLORHEXIDINA ENJUAGUE BUCAL FRASCO X 180 ML	7.61
DMTR040	MANGUERA TUBO LISO PARA OXÍGENO	8.79
DMGR093	VENDA ALGODÓN 5 X 5 UNIDAD	8.79
DMCP228	ADAPTADOR CON VALVULA (LIBRE DE AGUJAS) PARA INYECTABLE	8.79
DMGR089	VENDA ELASTICA 5 X 5 UNIDAD	10.00
S004701	SODIO CLORURO 0.9% X 500 ML SOLUCION INYECTABLE	10.00
DMCP108	JERINGA 10 CC CON AGUJA 21 X 1 ½ TRES PARTES	10.00
DMGR041	ELECTRODO DESECHABLE ADULTO UNIDAD	10.00

En la [Tabla 4](#) también se evidencia que, para los medicamentos con datos faltantes, la mayoría presentan registros bastante completos. Los valores faltantes varían entre el 7.61 y el 10 %. Además, se destacan

productos como la lidocaína sin epinefrina al 2 %, el propofol y la clorhexidina, con un porcentaje de datos faltantes del 7.61 %. Por otro lado, algunos artículos como las vendas y las jeringas muestran un porcentaje ligeramente superior, alcanzando el 10 %.

En este orden de ideas, el análisis exploratorio consistió en representar gráficamente la evolución mensual del consumo de medicamentos a lo largo del periodo comprendido entre enero de 2020 y diciembre de 2023, con el fin de conocer el comportamiento de las series históricas y realizar un análisis visual para detectar comportamientos irregulares, picos de demandas y patrones de consumo. Asimismo, el análisis se realizó con conjuntos representativos que mostraban mayor calidad en sus registros, destacando el caso de LIDOCAÍNA SIN EPINEFRINA 2% X 10 ML FRASCO SOLUCIÓN INYECTABLE, que presentó una distribución de consumo relativamente constante, registrando un consumo total de 21 797 unidades y un consumo promedio global de aproximadamente 237 unidades mensuales ([Figura 6](#)).

Figura 6. Consumo para LIDOCAÍNA SIN EPINEFRINA 2% X 10 ML FRASCO SOLUCIÓN INYECTABLE



Evaluación de la calidad del registro

Durante esta fase se evaluó la calidad de los datos, identificando la presencia de valores faltantes en la estructura de las series temporales históricas. Se identificaron los medicamentos que contaban con alta completitud en sus registros mensuales, lo que los hacía adecuados para su uso como base en las tareas de *forecasting*. De este modo, la evaluación garantizó la confiabilidad de los modelos entrenados, permitiendo descartar registros con comportamientos erráticos o con insuficiente densidad de información temporal. Se generaron tablas con porcentajes de valores faltantes por medicamento, lo que sirvió como criterio técnico para priorizar los insumos clínicos con mayor estabilidad de información.

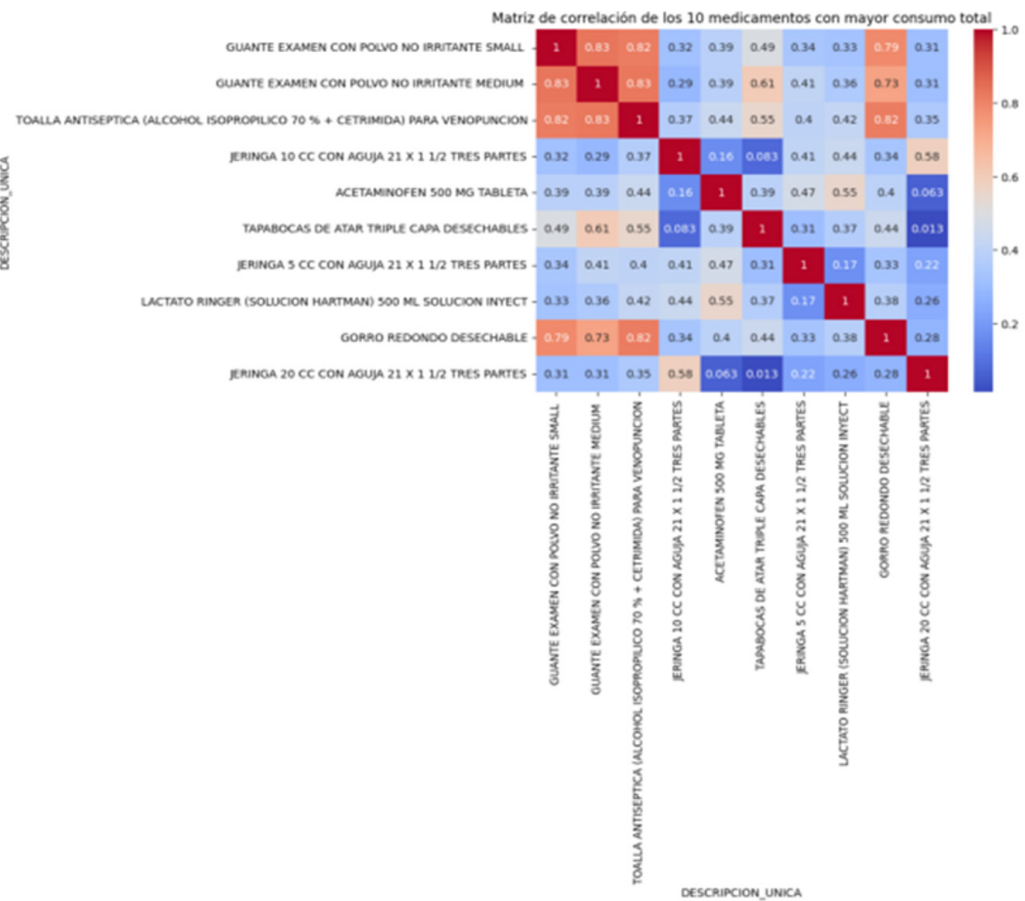
Análisis de correlaciones entre medicamentos

Con el objetivo de identificar relaciones potenciales entre los patrones de consumo de distintos medicamentos, se llevó a cabo un análisis de correlación sobre un subconjunto representativo de los fármacos con mayor volumen de uso. Este análisis permitió detectar similitudes y patrones de consumo

concurrente entre ciertos medicamentos, posiblemente asociados a tratamientos combinados o protocolos clínicos específicos (Figura 7).

De este modo, las correlaciones se visualizaron mediante mapas de calor (*heatmaps*), lo que facilitó la interpretación gráfica de las relaciones más relevantes. Además, se aportó una visión valiosa sobre el contexto clínico y operativo de la demanda hospitalaria. De igual manera, los hallazgos derivados de este análisis fueron incorporados en el desarrollo de la API como insumo para enriquecer la lógica de los modelos predictivos, fortaleciendo así la precisión y la relevancia de las predicciones.

Figura 7. Matriz de correlación para los implementos y medicamentos de mayor consumo



Evaluación del rendimiento de los modelos

Los resultados indican que cada modelo tiene fortalezas específicas: Prophet se destaca en la identificación de tendencias relativas, XGBoost logra una mayor precisión numérica y SARIMAX, a pesar de sus limitaciones, muestra una precisión notable en contextos donde los patrones estacionales son predominantes. Esta diversidad en el desempeño sugiere la conveniencia de seleccionar el modelo en función de las características particulares de la serie de demanda a predecir. Para evaluar el comportamiento de cada modelo en un caso individual, se seleccionó AMIKACINA (SULFATO) 500 MG/2 ML SOLUCIÓN INYECTABLE, cuyos resultados se presentan en la [Tabla 5](#).

Tabla 5. Comparación de los resultados de los modelos para un medicamento específico

Modelo	MAPE (CV)	RMSE (CV)	MAE (CV)	Valor máximo	Valor mínimo	Valor promedio	Desviación estándar
Prophet	0.97%	263.56	224.75	711	52	479.56	173.94
XGBoost	25.55%	214.51	162.94	711	52	479.56	173.94
SARIMAX	14.51%	79.06	66.34	711	52	479.56	173.94

Comparación de desempeño global

La validación cruzada en ventana móvil permitió calcular las métricas de error promedio para los 123 medicamentos de alto costo evaluados. La [Tabla 6](#) presenta una comparativa de los resultados.

Tabla 6. Comparación de resultados globales de los modelos

Modelo	MAPE promedio (CV)	RMSE promedio (CV)	MAE promedio (CV)
Prophet	1.96 %	390.75	303.11
XGBoost	29.81 %	252.30	211.68
SARIMAX	46.70 %	112.23	88.64

Los resultados muestran que Prophet es el modelo con mejor desempeño en términos de error porcentual promedio (MAPE=1.96 %), lo que indica que capta bien la relación entre las predicciones y los valores reales. Esto le permite ajustarse con precisión a las tendencias generales de la demanda de medicamentos. Sin embargo, su RMSE y MAE son considerablemente mayores, lo que sugiere que, si bien predice correctamente la variación relativa de la demanda, su precisión en términos absolutos es menor. Lo anterior podría deberse a que Prophet tiende a suavizar las fluctuaciones extremas y puede verse afectado por medicamentos con volúmenes de demanda muy altos.

Por otro lado, XGBoost obtiene los menores valores de error absoluto (RMSE=252.30, MAE=211.68), lo que indica que sus predicciones son más cercanas a los valores reales en términos numéricos. Sin embargo, su MAPE de 29.81 % es considerablemente mayor que el de Prophet, por lo que puede no ser tan robusto para medicamentos con diferentes escalas de demanda, *i.e.*, aunque XGBoost se ajusta bien en términos absolutos, su desempeño puede ser menos consistente en medicamentos con demandas muy variables.

Finalmente, en el caso de SARIMAX, se observa el peor desempeño global, con un MAPE del 46.70 %, lo que indica que sus predicciones presentan una mayor desviación con respecto a los valores reales. A pesar de que su RMSE y MAE son más bajos que los de Prophet, sigue sin superar a XGBoost en precisión absoluta. Este comportamiento podría deberse a la naturaleza de los datos, ya que SARIMAX funciona mejor en series con patrones estacionales bien definidos y podría tener dificultades para adaptarse a series con alta variabilidad o cambios abruptos en la demanda.

Comparación de desempeño con base en un medicamento específico

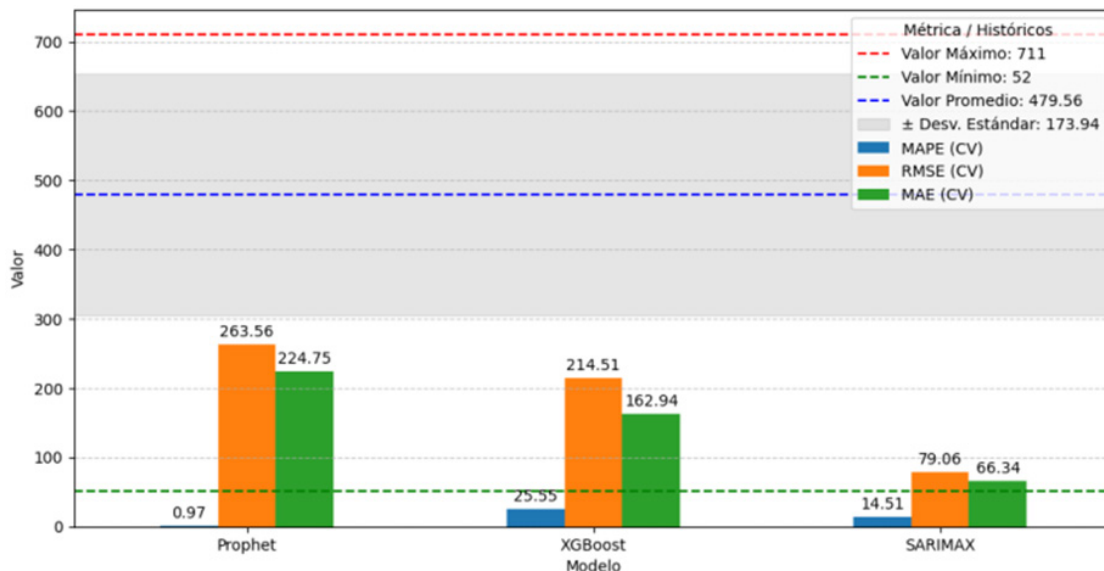
Para ilustrar estas diferencias en una serie concreta, la [Tabla 7](#) presenta los resultados de AMIKACINA (SULFATO) 500 MG/2 ML, cuyas estadísticas históricas son: máximo = 711, mínimo = 52, promedio = 479.56, desviación estándar = 173.94.

Tabla 7. Comparación individual de modelos para AMIKACINA (SULFATO) 500 MG/2 ML

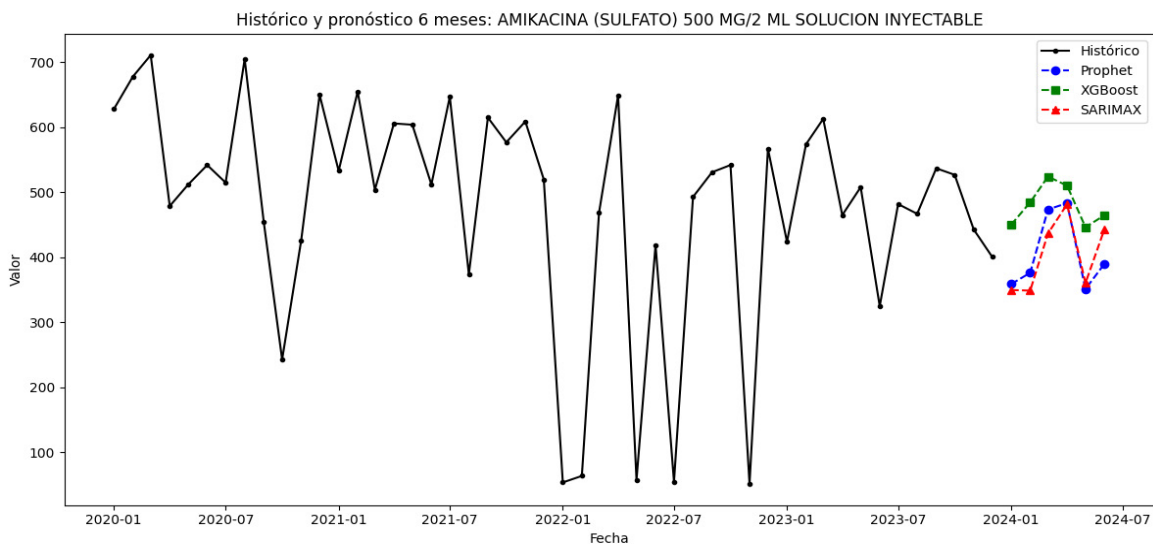
Modelo	MAPE Promedio (CV)	RMSE Promedio (CV)	MAE Promedio (CV)
Prophet	0.97 %	263.56	224.75
XGBoost	25.55 %	214.51	162.94
SARIMAX	14.51 %	79.06	66.34

En este caso, Prophet reduce el error porcentual a menos del 1 %, lo que demuestra su fortaleza en precisión relativa aun cuando el volumen de demanda es alto. No obstante, su RMSE (cercano a 263 unidades) y su MAE (superior a 224) implican errores absolutos que resultan en 1.5 a 1.3 veces la desviación estándar histórica.

El modelo XGBoost presenta errores absolutos por debajo de 1.2 veces la desviación estándar (RMSE) y de 0.94 veces la desviación estándar (MAE), lo que lo hace muy eficaz para pronosticar valores concretos, aunque su MAPE de 25.55 % significa que esos errores, expresados en porcentaje, representan una cuarta parte de la demanda media. Finalmente, SARIMAX logra el RMSE más bajo (equivalente a 0.45 veces la desviación estándar) y un MAE de 66.34 (0.38 veces la desviación estándar), ofreciendo el ajuste absoluto más preciso mientras mantiene un MAPE intermedio, ideal para series regulares con componente estacional.

Figura 8. Comparación de métricas para los modelos

La [Figura 8](#) presenta los errores de los tres modelos. Las barras verticales corresponden a los valores de MAPE, RMSE y MAE para cada modelo, lo que permite comparar la magnitud de los errores de manera clara y directa. Sobre la misma gráfica, se incluyen líneas horizontales punteadas que representan el valor máximo (711), mínimo (52) y promedio (479.56) de la demanda histórica del medicamento, así como una banda sombreada que indica el rango comprendido entre el promedio \pm la desviación estándar (± 173.94), proporcionando un marco de referencia sobre la escala de la serie temporal. Esta representación permite establecer qué tan lejos se encuentran los errores de cada modelo respecto a los valores esperados, y cuán dispersos son en relación con la variabilidad histórica de la serie.

Figura 9. Comparación de predicciones entre modelos

Para complementar el análisis, se incluyeron las visualizaciones correspondientes a la predicción de cada modelo sobre el medicamento AMIKACINA. En la [Figura 9](#) se muestra el comportamiento de la serie histórica (negro) y la proyección generada por cada modelo para los seis meses siguientes, facilitando una comparación directa de la capacidad de cada enfoque para replicar las tendencias pasadas y anticipar el comportamiento futuro. La visualización correspondiente al modelo Prophet muestra una línea de tendencia suavizada y continua, sin grandes sobresaltos, lo que indica una fuerte capacidad para modelar la tendencia subyacente, aunque con menor capacidad de adaptación a cambios abruptos. Asimismo, en el modelo XGBoost, las predicciones muestran un mayor ajuste a los valores recientes, variando menos en las unidades y capturando mejor los picos y caídas. Finalmente, el modelo SARIMAX generó una proyección que se alinea con los patrones estacionales y las tendencias observadas en la serie histórica, además de ofrecer una mejor precisión que el modelo XGBoost y los mejores resultados en términos de RMSE y MAE. Lo anterior que sugiere una buena captura de la estructura recurrente de la demanda. Las visualizaciones, junto con los indicadores numéricos y el análisis gráfico, proporcionan una base sólida para comprender el comportamiento de cada modelo y seleccionar el más adecuado en función del contexto de aplicación y las características específicas de cada medicamento.

CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se evaluaron y compararon tres enfoques complementarios para el pronóstico de la demanda de medicamentos de alto costo: Prophet, XGBoost y SARIMAX, cada uno optimizado mediante técnicas de lógica bayesiana para ajustar los hiperparámetros con base en criterios cuantitativos de desempeño (MAPE, RMSE y MAE). Prophet destacó por su elevada precisión relativa al capturar tendencias y estacionalidades suaves, XGBoost ofreció el menor error absoluto en unidades, al acomodarse con flexibilidad a variaciones no lineales, y SARIMAX demostró una capacidad sólida para modelar ciclos estacionales regulares con los errores absolutos más bajos. Esta diversidad de resultados subraya que la combinación de metodologías clásicas y modernas es esencial para mejorar la calidad de las proyecciones en contextos donde tanto la magnitud absoluta como la variación porcentual de la demanda resultan determinantes.

Los pronósticos generados resultaron ser una herramienta de gran valor para anticipar las necesidades de producción y distribución en cadenas de suministro farmacéuticas y entidades de salud pública. Al poner estos modelos a disposición de cualquier usuario a través de una API REST y una plataforma web accesible, se cumple un doble propósito: por un lado, se brinda un recurso técnico capaz de reducir desabastecimientos y optimizar niveles de inventario; y, por otro, se promueve la equidad en el acceso a tecnologías de análisis predictivo, en línea con los principios de la Inteligencia Artificial para el Bien Social.

El enfoque integrador desarrollado sienta las bases para futuras investigaciones tanto en el perfeccionamiento de los algoritmos como en su aplicación práctica. En cuanto a modelos, podría ser prometedor explorar variantes de redes neuronales o arquitecturas de autoatención (*transformers*) para series temporales, así como integrar procesos de *nowcasting* que incorporen fuentes de datos en tiempo real (e.g., registros de atención hospitalaria o indicadores de movilización poblacional). Asimismo, enriquecer las predicciones con variables exógenas (e.g., precios, indicadores socioeconómicos, políticas de salud pública) podría mejorar la sensibilidad de los modelos ante cambios abruptos en el entorno.

Contribución de autoría:

Donovan-Steven Picón-Sossa: Investigación, Software, Visualización, Redacción-Borrador Original.

Marco-Javier Suarez Barón: Investigación, Metodología, Validación, Supervisión, Redacción-Revisión y edición.

Juan-Sebastián González-Sanabria: Investigación, Metodología, Validación, Redacción-Revisión y edición.

REFERENCIAS

- Allwright, S. (2022). *RMSE vs MAPE, which is the best regression metric*. <https://stephenallwright.com/rmse-vs-mape/>
- Alharbi, F. R., & Csala, D. (2022). A seasonal autoregressive integrated moving average with exogenous factors (SARIMAX) forecasting model-based time series approach. *Inventions*, 7(4), 94. <https://doi.org/10.3390/inventions7040094>
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
- Espinosa-Zúñiga, J. J. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería, Investigación y Tecnología*, 21(3), 22. <https://doi.org/10.22201/ii.25940732e.2020.21.3.022>
- Chen, T., & Guestrin, C. (2016). XGboost: A scalable tree boosting system. En ACM (Eds.), *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). ACM.
- Hezam, I. M., et al. (2024). Artificial intelligence's impact on drug delivery in healthcare supply chain management: data, techniques, analysis, and managerial implications. *Journal of Big Data*, 11(1), 1-25. <https://doi.org/10.1186/S40537-024-01049-7>
- Li, L., Kand, Y., and Li, F. (2023). Bayesian forecast combination using time-varying features. *International Journal of Forecasting*, 39(3), 1287-1302. <https://doi.org/10.1016/j.ijforecast.2022.06.002>
- MLOps (2023). *MLOps Principles*. Retrieved from: <https://ml-ops.org/content/mlops-principles>
- Mousa, B. A., and Al-Khateeb, B. (2023). Predicting medicine demand using deep learning techniques: A review. *Journal of Intelligent Systems*, 32, e0297. <https://doi.org/10.1515/jisys-2022-0297>

- Muraina, I. O., Adesanya, O., & Abam, S. O. (2023). Data analytics evaluation metrics essentials: Measuring model performance in classification and regression [Artículo de conferencia]. *Congress on Scientific Researches and Recent Trends 11*, Cappadocia, Nevşehir, Türkiye.
- Nguyen, A., Lamouri, S., Pellerin, R., Tamayo, S., & Lekens, B. (2022). Data analytics in pharmaceutical supply chains: State of the art, opportunities, and challenges. *International Journal of Production Research*, 60(22), 6888-6907. <https://doi.org/10.1080/00207543.2021.1950937>
- Petrovic, A., Antonijevic, M., Strumberger, I., Jovanovic, L., Savanovic, N., & Janicijevic, S. (2023). *The XGboost approach tuned by TLB metaheuristics for fraud detection* [Artículo de conferencia]. 1st International Conference on Innovation in Information Technology and Business (ICIITB 2022).
- Rostami-Tabar, B., et al. (2022). Forecasting for social good. *International Journal of Forecasting*, 38(3), 1245-1257. <https://doi.org/10.1016/j.ijforecast.2021.02.010>
- Seyedan, M., & Mafakheri, F. (2020). Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. *Journal of Big Data* 2020, 7(1), 1-22. <https://doi.org/10.1186/S40537-020-00329-2>
- Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & De Freitas, N. (2015). Taking the human out of the loop: A review of Bayesian optimization. *Proceedings of the IEEE*, 104(1), 148-175. <https://doi.org/10.1109/JPROC.2015.2494218>
- Shohan, M. J. A., Faruque, M. O., & Foo, S. Y. (2022). Forecasting of electric load using a hybrid LSTM-neural prophet model. *Energies*, 15(6), 2158. <https://doi.org/10.3390/en15062158>
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45. <https://doi.org/10.1080/00031305.2017.1380080>
- Wang, B., Liu, X., Chi, M., & Li, Y. (2024). Bayesian network based probabilistic weighted high-order fuzzy time series forecasting. *Expert Systems with Applications*, 237, e121430. <https://doi.org/10.1016/j.eswa.2023.121430>
- Wong, A., Flanagan, T., Covington, E. W., Nguyen, E., Linn, D., Brummel, G., Hoffmaster, B., Isaacs, D., & Kane-Gill, S. L. (2025). Forecasting the impact of artificial intelligence on clinical pharmacy practice. *Journal of the American College of Clinical Pharmacy*, 8(4), 302-310. <https://doi.org/10.1002/jac5.70004>
- Zhu, X., Ninh, A., Zhao, H., & Liu, Z. (2021). Demand forecasting with supply-chain information and machine learning: Evidence in the pharmaceutical industry. *Production and Operations Management*, 30(9), 3231-3252. <https://doi.org/10.1111/poms.13426>

