




Machine Learning para mejorar la toma de decisiones en una farmacia hospitalaria de Lima, 2025

Machine Learning to improve decision-making in a hospital pharmacy in Lima, 2025

 Ronald Raúl Fuentes Acuña
Universidad Nacional Federico Villarreal, Perú
2023044431@unfv.edu.pe

Resumen

El objetivo principal de la investigación fue determinar cómo el uso de machine learning contribuye a mejorar los procesos de toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025. Este estudio es del tipo aplicada desde un enfoque cuantitativo y de nivel descriptivo, empleando un diseño preexperimental. La población estuvo conformada por datos históricos de ventas de medicamentos, considerándose una muestra representativa para el análisis mediante técnicas de series temporales. En cuanto al procedimiento, se aplicaron modelos ARIMA, previa evaluación de criterios de estacionariedad, autocorrelación y estacionalidad, y su validación se realizó mediante métricas de error como RMSE y MAE. Los resultados evidenciaron una mejora significativa en la precisión de la predicción de la demanda de medicamentos, así como en el control de inventarios, reduciendo los niveles de desabastecimiento y sobre stock. Asimismo, las pruebas de hipótesis evidenciaron un valor sig. menor a 0.05 bajo un nivel de confianza del 95%. Se concluye que la implementación de modelos de machine learning basados en series temporales es efectiva para optimizar la gestión farmacéutica hospitalaria, mejorando la eficiencia operativa y la calidad de la toma de decisiones, siempre que se cuente con una adecuada gestión de datos y soporte institucional.

Palabras claves: Machine Learning, ARIMA, Predicción de demanda, Toma de decisiones, Farmacia hospitalaria.

Abstract


The main objective of this research was to determine how the use of machine learning contributes to improving decision-making processes in a hospital pharmacy in Lima during the year 2025. The study was classified as applied, with a quantitative and descriptive approach, employing a pre-experimental single-group design with pretest–posttest measurements, which allowed the evaluation of the impact of the analytical proposal. The population consisted of historical medication sales data, considering a representative sample for analysis through time series techniques. Regarding the procedure, ARIMA models were applied after evaluating stationarity, autocorrelation, and seasonality criteria, and their validation was carried out using error metrics such as RMSE and MAE. The results showed a significant improvement in the accuracy of medication demand forecasting, as well as in inventory control, reducing stockouts and overstock levels. Likewise, hypothesis testing showed significance values of $p < 0.05$, with a 95% confidence level, confirming statistically significant differences between the pretest and posttest. It is concluded that the implementation of machine learning models based on time series is effective in optimizing hospital pharmaceutical management, improving operational efficiency and the quality of decision-making, provided that adequate data management and institutional support are ensured.

Keywords: Machine Learning, ARIMA, Demand Forecasting, Make decisions, Hospital Pharmacy.



Publicado: 2026-04-16
Aceptado: 2026-04-15
Recibido: 2026-02-27

Open Access
Article scientific

 <https://doi.org/10.47422/jstri.v7i1.75>





Introducción

La gestión eficiente de los medicamentos en las farmacias hospitalarias constituye un componente crítico dentro del sistema de salud, ya que, de la adecuada planificación, control y toma de decisiones depende tanto la eficiencia operativa de las instituciones como la continuidad de los tratamientos y la seguridad del paciente (Manrique, 2025). Sin embargo, en diversos hospitales de Lima, este proceso presenta importantes limitaciones, asociadas al incremento de la demanda asistencial y la alta variabilidad en el consumo de medicamentos (Vásquez, 2025).

En este contexto, la toma de decisiones en la gestión de medicamentos continúa sustentándose en criterios empíricos y experiencia del personal, lo cual resulta insuficiente frente a escenarios caracterizados por grandes volúmenes de datos. La ausencia de herramientas tecnológicas avanzadas limita la capacidad de analizar esta información de manera integral y de anticiparse a problemas de abastecimiento (Lazo y Moreano, 2021). A pesar del avance de las Tecnologías de la Información y, en particular, de las técnicas de machine learning, muchas farmacias hospitalarias aún no han incorporado estas herramientas de manera sistemática, evidenciando una brecha entre la disponibilidad de datos y su uso efectivo para la toma de decisiones (Madariaga, 2021). En consecuencia, surge la necesidad de implementar modelos predictivos que permitan analizar patrones de consumo y mejorar la calidad de la información para la toma de decisiones (González y Delgado, 2024).

En la práctica, los sistemas de información no son analizados de manera integral y ello puede impedir la detección de patrones o anticipación de situaciones críticas como quiebres de stock (Mendoza y Salazar, 2022). Como consecuencia, se generan deficiencias operativas recurrentes, tales como desabastecimientos de medicamentos esenciales, retrasos en la reposición y dificultades en la planificación presupuestaria (Cortés, 2022).

En este sentido, el desarrollo de técnicas de machine learning representa una oportunidad para optimizar la gestión de medicamentos mediante el análisis inteligente. No obstante, su adopción en el contexto de las farmacias hospitalarias de Lima aún es limitada, lo que evidencia la necesidad de investigaciones aplicadas que demuestren su efectividad en escenarios reales (Inga et al., 2023). Por ello, se plantea como problema general determinar en qué medida el uso de machine learning contribuye a mejorar los procesos de toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025, con objetivos específicos orientados a incrementar la precisión en la predicción de la demanda, mejorar el control de

inventarios, reducir los desabastecimientos y sobre stock, y elevar la calidad de la información utilizada en la gestión farmacéutica.

Diversos estudios internacionales y nacionales respaldan la pertinencia de abordar esta problemática mediante modelos predictivos y técnicas de ML. Investigaciones como las de (Shen, 2024) evidencian mejoras significativas en la eficiencia de la cadena de suministro mediante la implementación de modelos basados en IA. Mientras que en otro estudio se demostró que la capacidad de los modelos predictivos para anticipar desabastecimientos es aceptable (Pall, 2023). De manera similar, estudios como los de (Tri, 2024) y (Fourkiotis, 2024) destacaron el desempeño superior de algoritmos avanzados en la predicción de la demanda farmacéutica. En el ámbito nacional, investigaciones como las de (Quispe, 2021), (Ramos, 2022) y (Salazar, 2023) evidenciaron mejoras significativas en la gestión farmacéutica tras la implementación de modelos de ML, los cuales redujeron los errores de predicción, o mejoraron la calidad de la información para la toma de decisiones.

La justificación del estudio se sustenta en tres dimensiones: teórica, práctica y metodológica. Desde el punto de vista teórico, la investigación contribuye al desarrollo del conocimiento científico. En el ámbito práctico, responde a la necesidad de mejorar los procesos de gestión de medicamentos proporcionando una herramienta tecnológica que mejora la calidad del servicio. Finalmente, desde la perspectiva metodológica, se justifica como una investigación aplicada con enfoque cuantitativo y diseño preexperimental orientada a evaluar el impacto de la solución propuesta.

Marco Teórico

2.1. Gestión de medicamentos en la farmacia hospitalaria

La farmacia hospitalaria constituye una unidad clínico-administrativa encargada de garantizar la selección, adquisición, almacenamiento, distribución y uso racional de los medicamentos dentro de una institución de salud (Soha, 2024). Su adecuada gestión es fundamental para asegurar la continuidad de los tratamientos y la eficiencia en el uso de los recursos económicos. En este contexto, la gestión de medicamentos involucra procesos críticos como la planificación de la demanda, el control de inventarios y la reducción de pérdidas por vencimiento.

2.2. Toma de decisiones en la gestión farmacéutica hospitalaria

Esta estuvo sustentada tradicionalmente en la experiencia del personal, el análisis de registros históricos y el uso de métodos estadísticos básicos (Leixiao, 2024). No obstante,



este enfoque resulta limitado frente a la complejidad actual del entorno hospitalario.

2.3. Sistemas de información y analítica de datos en salud

Estos permiten el registro y almacenamiento de grandes volúmenes de datos relacionados con prescripciones médicas, dispensación y consumo de medicamentos (Abrar, 2026). En este sentido, la analítica de datos en salud busca transformar dichos registros en información útil para la toma de decisiones (Madhumathi, 2025).

2.4. Machine Learning en la gestión de medicamentos

Esta es una rama de la IA que permite a los sistemas aprender a partir de datos históricos e identificar patrones o generar predicciones sin necesidad de programación (Bharech et al., 2025). Sus principales enfoques incluyen el aprendizaje supervisado, no supervisado y por refuerzo (Recupito, 2025).

2.5. Beneficios del uso de Machine Learning en el sector salud

Algunos de estos beneficios son: la mejora en la precisión de la toma de decisiones, la optimización de inventarios (Bader, 2025). Asimismo, estas tecnologías permiten adoptar un enfoque proactivo (Babic et al., 2025).

2.6. Deep Learning y su aplicación en la predicción de demanda

El deep learning es una subárea de la IA basada en redes neuronales profundas que permiten modelar relaciones complejas y no lineales en grandes volúmenes de datos (Paramesha et al., 2025). A diferencia de los modelos tradicionales, el DL aprende representaciones jerárquicas de los datos de forma automática (Tran et al., 2025). En el ámbito hospitalario, ha demostrado un alto desempeño en tareas de predicción y análisis de series temporales (Wei et al., 2025).

2.7. Transformación digital en el sector salud

Esto implica la incorporación de tecnologías digitales para mejorar procesos, servicios y modelos de gestión (Tu y He, 2025). En el sector salud, este proceso busca optimizar la eficiencia operativa y la calidad de la atención (George y Antoaneta, 2025). La adopción de machine learning en la farmacia hospitalaria forma parte de esta transformación, al permitir una gestión basada en datos.

2.8. Calidad del servicio en salud

La calidad del servicio en salud se refiere a la capacidad de las instituciones para satisfacer las necesidades de los pacientes de manera oportuna, segura y eficiente (Jaafar et al., 2024). En este contexto, la disponibilidad de

medicamentos constituye un componente crítico porque puede afectar directamente la continuidad de los tratamientos (Kenyon, 2025).

2.9. Analítica predictiva aplicada a la gestión de inventarios

La analítica predictiva integra modelos estadísticos avanzados y técnicas de ML (Kwon et al., 2021). Esto contribuye a reducir pérdidas económicas y garantizar la continuidad del tratamiento (Zhang et al., 2022).

2.10. Toma de decisiones basada en datos (DDDM)

Esta se fundamenta en el uso sistemático de información analizada para orientar decisiones organizacionales (Provost & Fawcett, 2021). En el sector salud, este enfoque permite mejorar la planificación y el control de procesos (Raghupathi & Raghupathi, 2020).

2.11. Modelos predictivos en la planificación farmacéutica

Estos permiten analizar múltiples variables y establecer relaciones complejas en los datos, superando las limitaciones de los métodos tradicionales (Zhang et al., 2022). En la farmacia hospitalaria, estos modelos facilitan la planificación de compras o la reducción de eventos críticos (Fourkiotis & Tsadiras, 2024).

2.12. Gestión de riesgos operativos mediante inteligencia artificial

Esta gestión permite identificar y mitigar riesgos operativos mediante el análisis predictivo y la detección de anomalías en grandes volúmenes de datos (Wang et al., 2023). En la farmacia hospitalaria, esto se traduce en la capacidad de anticipar desabastecimientos y mejorar la resiliencia operativa (González-Pérez et al., 2024).

2.13. Interoperabilidad de sistemas en entornos hospitalarios

Esta permite la integración de sistemas clínicos, administrativos y farmacéuticos, facilitando el acceso a datos confiables y actualizados (Raghupathi & Raghupathi, 2020).

2.14. Impacto del Machine Learning en la eficiencia del servicio farmacéutico

El uso de ML ha demostrado mejorar indicadores clave como la rotación de inventarios, los tiempos de reposición y la reducción de pérdidas económicas (González-Pérez et al., 2024). Asimismo, ML contribuye a mejorar la calidad de la información (Kwon et al., 2021).

2.15. Gobernanza de datos en el sector salud

La gobernanza de datos comprende el conjunto de políticas y procesos que garantizan la calidad, seguridad y uso



adecuado de la información (Abouelmehdi et al., 2021). En el ámbito hospitalario, una adecuada gestión de datos es esencial para asegurar la confiabilidad de los modelos de ML (Dash et al., 2021).

2.16. Ética en el uso de inteligencia artificial en salud

Estos desafíos pueden estar relacionados con la transparencia, la privacidad y la responsabilidad en la toma de decisiones automatizada (Floridi et al., 2021). En la farmacia hospitalaria, los modelos deben ser explicables y auditables, garantizando decisiones responsables y seguras (Morley et al., 2020).

2.17. Calidad y preparación de datos

La calidad de los datos es un factor crítico en el desempeño de los modelos de ML. Datos incompletos o inconsistentes pueden afectar la precisión de las predicciones (Batini et al., 2022). Por ello, es necesario realizar procesos de limpieza, transformación y validación antes de su uso (Shmueli et al., 2021).

2.18. Madurez digital en organizaciones hospitalarias

La madurez digital se refiere al nivel de integración de tecnologías en los procesos organizacionales (Kane et al., 2021). En farmacias hospitalarias, una mayor madurez digital mejora su sostenibilidad (Vial, 2021).

2.19. Aceptación tecnológica del personal de salud

Esta aceptación depende de la percepción de utilidad y facilidad de uso por parte de los usuarios (Davis, 1989). En el entorno hospitalario, la aceptación del personal es clave para el éxito del ML y por ello es necesario las capacitaciones (Venkatesh et al., 2022).

2.20. Sostenibilidad y mejora continua en la gestión farmacéutica

El uso de ML permite la mejora continua mediante la evaluación constante del desempeño y la actualización de modelos con nuevos datos, contribuyendo a una gestión más resiliente y eficiente (Porter & Lee, 2021).

Resultados

3.2.1. Estadísticas descriptivas de la demanda de medicamentos

Se calcularon medidas estadísticas básicas para cada categoría terapéutica del conjunto de datos. Estas medidas permitieron evaluar la variabilidad de la demanda y detectar diferencias entre los distintos grupos de medicamentos.

	M01AB	M01AE	N02BA	N02BE	N05B	N05C	R03	R06
count	89.000000	89.000000	89.000000	89.000000	89.000000	89.000000	89.000000	89.000000
mean	149.846812	116.209739	114.742884	887.725841	262.453623	17.811594	166.554348	87.077971
std	31.582282	27.976162	31.387511	338.904188	85.637553	8.539313	81.823731	46.062454
min	0.000000	0.000000	0.000000	0.000000	1.000000	0.000000	0.000000	0.000000
25%	137.440000	103.517000	93.500000	647.650000	223.000000	12.000000	112.000000	49.500000
50%	154.520000	114.719000	116.700000	883.750000	250.600000	18.000000	159.000000	74.500000
75%	168.040000	128.233000	133.800000	1058.262000	295.200000	23.000000	216.000000	120.800000
max	211.130000	222.351000	191.600000	1856.815000	492.000000	50.000000	388.000000	213.040000

Figura 1. Estadísticas descriptivas de las variables mensuales del estudio

A partir de la anterior figura se evidencia que los valores mínimos y máximos registraron rangos amplios en ciertas variables. Por ejemplo, la columna 'N02BE' presentó un valor mínimo de 0 y un máximo de 1856.82, mientras que la columna 'N05C' se mantuvo en un rango más reducido, entre 0 y 50.

Además, los percentiles 25, 50 y 75 permitieron observar la distribución de los datos, mostrando que la mitad de las observaciones se concentró en valores intermedios, con algunas variables como la columna 'R03' alcanzando un 75% de los datos por debajo de 216 y otras como la columna 'M01AE' en 128.23.

En general, este análisis proporcionó información inicial sobre la tendencia central, dispersión y rango de las variables mensuales, lo cual fue fundamental para la comprensión exploratoria de los datos y la planificación de análisis posteriores.

3.2.2. Análisis de patrones temporales

3.2.2.1. Visualización de series temporales por categoría ATC

Se graficaron las series temporales correspondientes a cada categoría para analizar la evolución histórica de la demanda de medicamentos. Los gráficos permitieron identificar tendencias generales, estacionalidad, quiebres estructurales y posibles valores atípicos en los datos de consumo mensual. A continuación, se describen los principales patrones observados para cada categoría:

1. M01AB – Anti-inflamatorios derivados del ácido acético

La serie mostró una tendencia creciente moderada durante los primeros años, con picos de demanda intermitentes.

Se observó un quiebre temporal alrededor del año de 2023, en esta se evidenció una caída abrupta en la dispensación seguida de una recuperación gradual.




Figura 2. Serie temporal mensual de la demanda de M01AB (antiinflamatorios de ácido acético)

2. M01AE – Antiinflamatorios derivados del ácido propiónico

La serie evidenció variabilidad durante los meses de manera considerable, en esta serie se manifestó con varios picos agudos de demanda. Se detectaron quiebres similares a la gráfica de “M01AB” en 2023 y picos de consumo inusuales en 2025, esto reflejó episodios de alta rotación que podrían relacionarse con estacionalidad o necesidades específicas de pacientes.

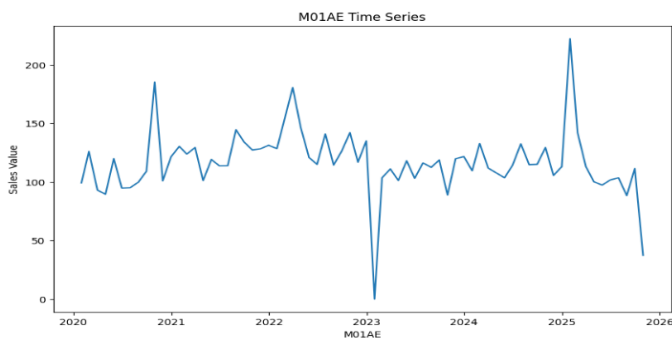


Figura 3. Serie temporal mensual de la demanda de M01AE (anti-inflamatorios ácidos propiónicos)

3. N02BA – Analgésicos derivados del ácido salicílico

La demanda mostró tendencia estable, pero con variaciones puntuales. Esta dinámica sugiere que el consumo se mantiene constante en general.




Figura 4. Serie temporal mensual de la demanda de N02BA (analgésicos ácido salicílico)

4. N02BE – Analgésicos pirazolonas

La serie presentó gran amplitud en los valores de venta, con picos altos y caídas abruptas, mostrando alta volatilidad. Se identificaron ciclos de consumo recurrentes y quiebres en 2023.

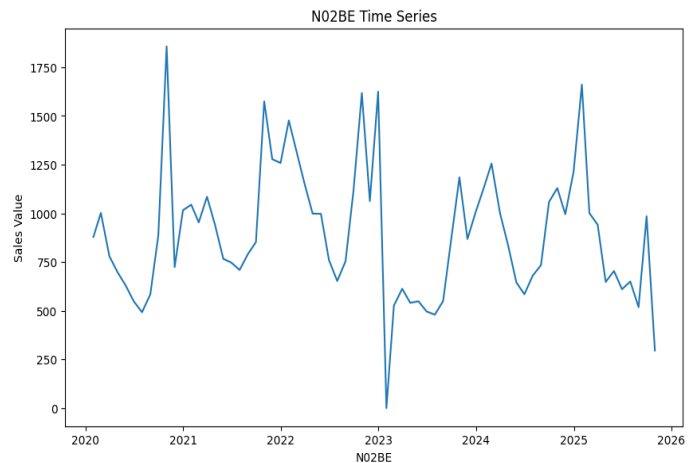


Figura 5. Serie temporal mensual de la demanda de N02BE (analgésicos pirazolonas)

5. N05B – Ansiolíticos

La demanda mostró tendencias ascendentes y descendentes intermitentes, con algunos picos importantes, reflejando variaciones estacionales y posibles efectos de cambios en protocolos médicos. La serie evidenció que la demanda no es uniforme, sino sensible a episodios específicos de consumo hospitalario.

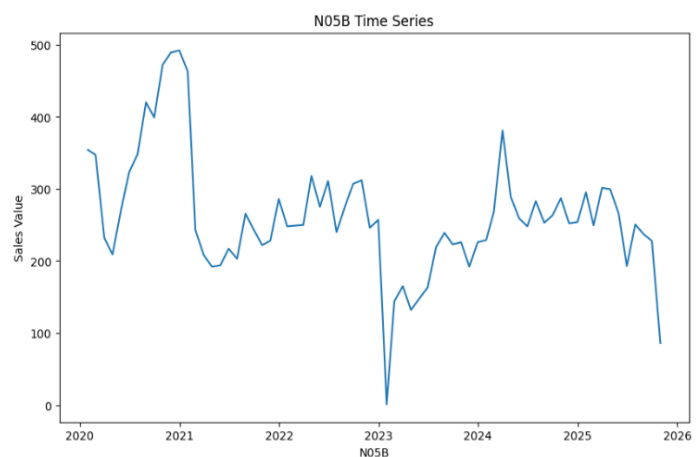


Figura 6. Serie temporal mensual de la demanda de N05B (ansiolíticos)

6. N05C – Hipnóticos y sedantes

La serie evidenció un patrón estable de bajo volumen, con pequeñas oscilaciones intermensuales. La



variabilidad fue mínima comparada con otras categorías, lo que indica un consumo más predecible y menos sujeto a picos extremos.

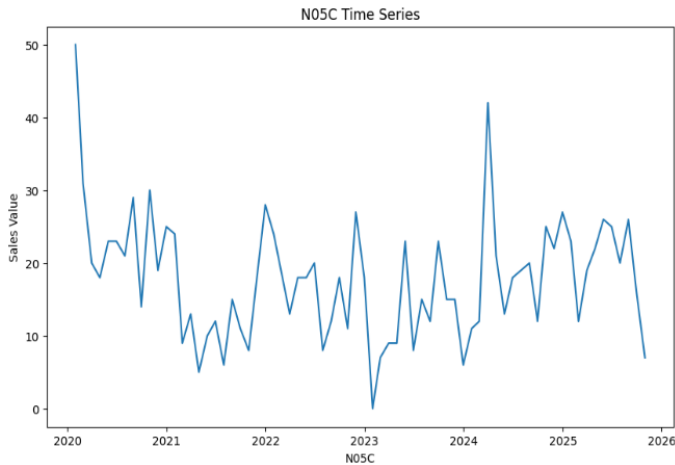


Figura 7. Serie temporal mensual de la demanda de N05C (hipnóticos y sedantes)

7. R03 – Medicamentos para enfermedades respiratorias

La serie presentó gran variabilidad, con picos pronunciados y descensos abruptos, especialmente alrededor de 2023 y 2025.

Este comportamiento refleja la influencia de factores estacionales, como brotes respiratorios, sobre la demanda.




Figura 8. Serie temporal mensual de la demanda de R03 (medicamentos respiratorios)

8. R06 – Antihistamínicos

La serie mostró ciclos marcados con picos regulares y caídas abruptas, reflejando patrones estacionales consistentes, probablemente asociados a cambios en la incidencia de alergias o condiciones respiratorias en la población hospitalaria.

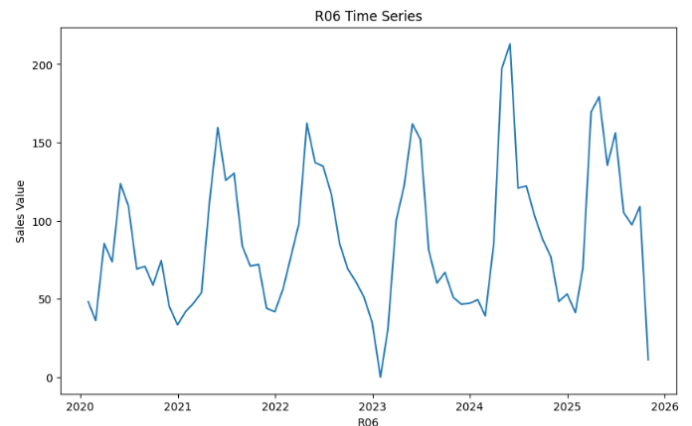


Figura 9. Serie temporal mensual de la demanda de R06 (antihistamínicos)

4.2.2.2. Identificación de tendencias y variaciones en la demanda

Con el fin de analizar la demanda agregada de todos los medicamentos incluidos en el estudio, se calculó una variable denominada total_sales, que representó la suma mensual de las dispensaciones de todas las categorías terapéuticas. Este indicador permitió observar la dinámica global de consumo en la farmacia hospitalaria, identificar periodos de alta presión asistencial y detectar posibles quiebres estructurales o picos de demanda simultáneos en múltiples grupos de medicamentos.

En la figura 15 se muestra la evolución de las ventas totales mensuales desde 2020 hasta 2025. Se observaron incrementos y disminuciones marcadas a lo largo del periodo, con picos importantes en años específicos que reflejan tanto la estacionalidad como eventos excepcionales que afectaron el consumo global. Asimismo, se identificaron descensos abruptos en 2023 y 2025, lo que evidencia la volatilidad en la demanda agregada y resalta la importancia de modelos predictivos que permitan anticipar estos cambios.

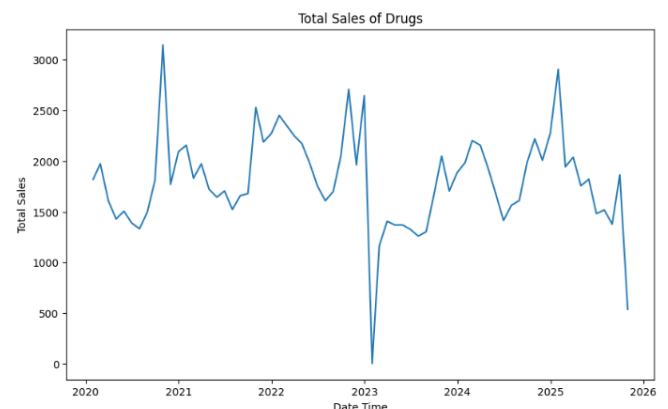


Figura 10. Evolución mensual de las ventas totales de medicamentos en la farmacia hospitalaria



La figura anterior que la demanda agregada presentó un comportamiento fluctuante con incrementos y descensos a lo largo del tiempo.

Se identificaron picos de demanda significativos en algunos meses, especialmente alrededor de 2021, 2022 y 2025, lo que evidenció periodos de mayor presión asistencial y mayor consumo de medicamentos.

Asimismo, se detectó una caída abrupta en 2023, seguida de una recuperación progresiva en los meses posteriores.

En general, la serie temporal reflejó variabilidad y posibles patrones estacionales en la demanda agregada, lo cual evidencia la importancia de emplear técnicas analíticas y modelos predictivos que permitan anticipar estos cambios y mejorar la planificación y gestión del inventario.

3.2.3. Detección de estacionalidad

La detección de estacionalidad permitió evaluar si el comportamiento de la demanda presentaba ciclos regulares a lo largo del tiempo, lo cual resulta fundamental para la construcción de modelos predictivos en series temporales.

Para este análisis se utilizaron diferentes técnicas estadísticas: el suavizamiento mediante media móvil simple (SMA), el test de estacionariedad de Dickey-Fuller aumentado (ADF) y el análisis de autocorrelación (ACF) y autocorrelación parcial (PACF).

Estas herramientas permitieron identificar tendencias subyacentes, patrones cíclicos y la estructura temporal de la serie de datos.

4.2.3.1. Análisis mediante media móvil (Simple Moving Average)

Para suavizar las fluctuaciones de corto plazo y resaltar la tendencia de la serie temporal, se aplicó la técnica de media móvil simple (SMA) utilizando una sección de cuatro periodos mensuales.

Esta técnica, en términos matemáticos, se expresa:

$$SMA_t = \frac{1}{k} \sum_{i=0}^{k-1} Y_{t-i}$$

Descripción de la fórmula:

k : representa al tamaño de la sección.

Y_t : corresponde al valor observado en un período t .




Figura 11. Serie temporal de ventas mensuales de medicamentos con media móvil simple (SMA)

A partir de la figura anterior se observó que la demanda presentó fluctuaciones importantes entre los años analizados, períodos que presentan alto consumo y descensos abruptos en otros. Sin embargo, la línea de media móvil permitió identificar una tendencia general oscilante con ciclos recurrentes y esto sugiere la presencia de patrones estacionales en el comportamiento de la demanda. Asimismo, se observó que los valores de la serie no se mantuvieron alrededor de una media constante a lo largo del tiempo, lo cual sugiere que la serie no es estrictamente estacionaria. Este resultado fue corroborado mediante el test de Dickey-Fuller aumentado (ADF) aplicado a la serie original.




Figura 12. Primera prueba estacionaria de la serie de datos




Figura 13. Segunda prueba estacionaria de la serie de datos

En ambos casos se obtuvieron valores de p-value cercanos o superiores a 0.05, lo que indica que no se puede rechazar la hipótesis nula de presencia de raíz unitaria, confirmando que la serie presenta no estacionariedad.

4.2.3.2. Identificación de patrones cíclicos en la demanda de medicamentos

Para analizar la dependencia temporal entre los valores de la serie y detectar posibles patrones cíclicos, se realizaron gráficos de función de autocorrelación (ACF) y función de autocorrelación parcial (PACF). Estas herramientas permiten evaluar la relación entre los valores actuales de la serie y sus valores pasados en distintos rezagos temporales.

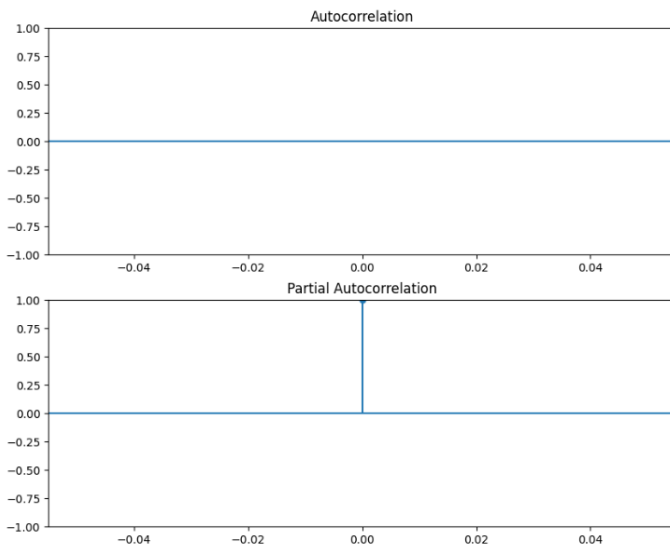


Figura 14. Función de autocorrelación (ACF) y autocorrelación parcial (PACF) de las ventas mensuales de medicamentos

A partir de la interpretación conjunta de los gráficos ACF y PACF presentados en la figura anterior, se identificó que el modelo ARMA (1,1) podría ser adecuado para representar la dinámica temporal de la demanda agregada de medicamentos. Este tipo de modelo combina un componente autorregresivo (AR) y un componente de media móvil (MA), permitiendo capturar tanto la dependencia temporal directa como los efectos de los errores pasados.

En conjunto, los resultados del análisis de autocorrelación confirmaron la existencia de patrones cíclicos en la demanda de medicamentos, lo que evidencia que el comportamiento de la serie no es aleatorio, sino que sigue estructuras temporales que pueden ser modeladas y utilizadas para fines de predicción.

3.3. Preparación del dataset para el modelado predictivo

Para modelar la demanda total de medicamentos, se evaluaron distintas alternativas dentro del enfoque de series temporales, considerando principalmente modelos autorregresivos y de medias móviles.

Inicialmente, a partir del análisis de las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF), se planteó como modelo candidato un modelo ARMA (1,1), dado que ambas funciones mostraban un corte significativo en el rezago 1. Sin embargo, al realizar la estimación del modelo, se observó que los coeficientes asociados al componente de media móvil (MA) no resultaron estadísticamente significativos ($p\text{-value} > 0.05$), por lo que se descartó dicho componente.

En consecuencia, se optó por un modelo autorregresivo de orden 1, AR (1), el cual permite capturar la dependencia temporal de la demanda en función de su valor inmediatamente anterior.

3.3.1. Transformación de la serie temporal

Con el objetivo de garantizar la correcta aplicación de técnicas de series temporales, se realizó la transformación estructural del dataset mensual, asegurando que los datos se encontraran organizados en función del tiempo y listos para el modelamiento predictivo.

3.3.1.1. Conversión de la fecha a índice temporal

Posteriormente, a la variable de la fecha se estableció como índice del dataset, transformando la estructura tabular en una serie temporal indexada.

Esta transformación permitió que cada observación quedara asociada a un punto específico en el tiempo, lo cual es fundamental para aplicar modelos autorregresivos y analizar patrones temporales como tendencia y estacionalidad.

3.3.1.2. Organización cronológica de los registros

Luego que la variable de fecha fue establecida como índice del dataset, se procedió a verificar y garantizar el orden cronológico de los registros. Para ello, se ordenaron las observaciones en orden ascendente para asegurar que los datos más antiguos se ubicaran al inicio de la serie y los más recientes al final.

Esto fue fundamental para preservar la coherencia temporal del análisis porque los modelos de series temporales requieren que las observaciones sigan una secuencia lógica en el tiempo. Adicionalmente, se verificó la continuidad temporal de los registros, identificando posibles periodos faltantes que pudieran alterar la estructura de la serie.

3.3.2. División del dataset

Posterior a la transformación de la serie temporal, se realizó la división del dataset con el objetivo de evaluar el desempeño del modelo predictivo en condiciones controladas.

Este proceso consistió en separar los datos en dos subconjuntos: entrenamiento y prueba.

A diferencia de los modelos tradicionales de ML, donde la división suele realizarse de manera aleatoria, en este caso se respetó la secuencia temporal de los datos. Esta decisión metodológica permitió evitar la fuga de información garantizando que el modelo únicamente aprendiera de datos pasados para predecir valores futuros.



4.3.2.1. Conjunto de entrenamiento (Train Set)

El conjunto de entrenamiento estuvo conformado por la mayor parte de los registros históricos del dataset, específicamente aquellos comprendidos hasta la fecha de corte establecida. Durante esta etapa, el modelo ajustó sus parámetros internos para representar la dinámica temporal de la serie.

4.3.2.2. Conjunto de prueba (Test Set)

El conjunto de prueba estuvo constituido por los registros posteriores a la fecha de corte, los cuales no fueron utilizados durante el entrenamiento del modelo. Este subconjunto permitió evaluar la capacidad predictiva del modelo frente a datos nuevos, simulando su desempeño en un entorno real.

```
# Se define fecha de corte
train_end = dt.datetime(2025, 7, 31)

# Datos de entrenamiento
train_data = monthly[:train_end]

# Datos de prueba
test_data = monthly[train_end + dt.timedelta(days=1):]
```

Figura 15. Establecimiento del conjunto de entrenamiento y prueba del dataset

3.3.3. Selección de variables para el modelo

La selección de variables constituyó un paso fundamental en la construcción del modelo predictivo, ya que permitió definir los elementos que influirían directamente en la estimación de la demanda de medicamentos. Para el caso de esta investigación, se priorizó el uso de variables que capturaran la dependencia temporal de la serie, simplificando el modelo sin perder capacidad explicativa.

3.3.3.1. Variables explicativas utilizadas en el modelo

En el presente estudio, las variables explicativas estuvieron conformadas por los valores rezagados de la variable objetivo, es decir, la demanda de medicamentos en periodos anteriores. Específicamente, se utilizó el valor correspondiente al periodo inmediatamente anterior como principal variable explicativa, lo cual permitió modelar la relación directa entre la demanda actual y la pasada.

4.3.3.2. Variable objetivo: demanda de medicamentos

La variable objetivo del modelo fue la demanda total de medicamentos, representada por la variable *total_sales*. Esta variable fue construida mediante la agregación de las distintas categorías terapéuticas clasificadas según el sistema ATC. La utilización de una variable agregada permitió simplificar el análisis y centrarse en el

comportamiento global de la demanda, lo cual resulta relevante.

3.4. Implementación del modelo de Machine Learning para predicción de demanda

En esta etapa se implementó un modelo de series temporales con el objetivo de predecir la demanda futura de medicamentos a partir de la variable agregada *total_sales*. El enfoque adoptado fue de tipo autorregresivo, considerando que los valores históricos de la demanda contienen información relevante para explicar su comportamiento futuro. Previo al entrenamiento de los modelos, fue necesario verificar la calidad de los datos utilizados en el dataset, y con ello se identificó la presencia de valores faltantes (NaN) en la serie. Estos fueron tratados mediante imputación utilizando el método de propagación hacia adelante (forward fill).

```
print("NaN:", train_data['total_sales'].isna().sum())
print("Inf:", (train_data['total_sales'] == float("inf")).sum())
print("-Inf:", (train_data['total_sales'] == float("-inf")).sum())

NaN: 1943
Inf: 0
-Inf: 0
```

Figura 16. Verificación de valores inválidos en la serie *total_sales*

```
# Si existieran valores NaN, se imputan
train_data['total_sales'] = train_data['total_sales'].ffill()

/tmp/ipython-input-792/4158387412.py:1: SettingWithCopyWarning:
A value is trying to be set on a copy of a slice from a DataFrame.
Try using .loc[row_indexer,col_indexer] = value instead

See the caveats in the documentation: https://pandas.pydata.org/pandas-docs/stable/user_guide/indexing.html#returning-a-view-versus-a-copy
train_data['total_sales'] = train_data['total_sales'].ffill()
```

Figura 17. Proceso de imputación de valores faltantes mediante *forward fill*

3.4.1. Modelo autorregresivo (AR)

Este modelo fue seleccionado como una técnica adecuada para modelar la dinámica temporal de la demanda de medicamentos, debido a la dependencia observada entre los valores actuales y los valores pasados de la serie.

A partir del análisis previo de autocorrelación, se determinó que este tipo de modelos eran suficientes para capturar la estructura temporal de los datos, descartando la inclusión de componentes de media móvil debido a su falta de significancia estadística.

3.4.1.1. Configuración del modelo AR

El modelo se configuró utilizando la función *AutoReg*, considerando como variable de entrada la serie temporal"



total_sales". Se estableció un rezago de orden 1 ($lags = 1$), lo que implica que el valor actual de la demanda depende únicamente del valor inmediatamente anterior.

Matemáticamente, el modelo se expresó de la siguiente forma:

$$Y_t = c + \phi_1 Y_{t-1} + \varepsilon_t$$

Donde:

- Y_t : demanda de medicamentos en el periodo actual
- Y_{t-1} : demanda en el periodo anterior
- c : constante del modelo
- ϕ_1 : coeficiente autorregresivo
- ε_t : término de error

Esta configuración permitió capturar la inercia de la serie temporal, es decir, la influencia directa del comportamiento pasado sobre la demanda futura.

```
model = sm.tsa.ar_model.AutoReg(
    train_data['total_sales'],
    lags=1
)
results = model.fit()
```

Figura 18. Configuración del modelo autorregresivo AR

3.4.1.2. Resultados del entrenamiento del modelo

El entrenamiento del modelo AR (1) generó resultados estadísticamente significativos, evidenciando que la demanda de medicamentos presenta una dependencia temporal importante.

```
***
AutoReg Model Results
=====
Dep. Variable:    total_sales  No. Observations:    67
Model:            AutoReg(1)  Log Likelihood       -494.001
Method:           Conditional MLE  S.D. of innovations  430.924
Date:            Thu, 26 Dec 2024  AIC                    994.003
Time:            06:02:35       BIC                    1000.572
Sample:          02-28-2014      HQIC                   996.599
                - 07-31-2019

=====
                coef  std err  z  P>|z|  [0.025  0.975]
-----
const          1170.2422  218.386   5.359  0.000  742.213  1598.272
total_sales.L1  0.3607  0.115   3.129  0.002  0.135  0.587

=====
                    Roots
-----
                Real      Imaginary  Modulus  Frequency
-----
AR.1            2.7724      +0.0000j   2.7724   0.0000
```

Figura 19. Resultados del modelo AutoReg

A partir de la figura anterior, los principales resultados obtenidos fueron:

- Coeficiente autoregresivo (ϕ_1) = 0.3607: Este valor indica que aproximadamente el 36.07% de la demanda

actual puede explicarse por la demanda del periodo anterior.

- Constante (c)=1170.24: Representa el nivel base de la demanda cuando no se considera el efecto del rezago:
- p - value del coeficiente AR = 0.002: Al ser menor a 0.05, se concluyó que el coeficiente es estadísticamente significativo, validando de esta manera a la relevancia del modelo.
- Criterios de información (AIC=994.003): Indicaron un ajuste adecuado del modelo a los datos.

A partir de estos resultados, el modelo estimado se expresó como:

$$\hat{Y}_t = 1170.24 + 0.3607Y_{t-1}$$

Este resultado evidenció que la serie de demanda no es aleatoria, sino que presenta una estructura temporal que puede ser aprovechada para realizar predicciones.

Finalmente, se generó el pronóstico de la demanda para los periodos futuros, el cual fue comparado con los valores reales del conjunto de prueba.

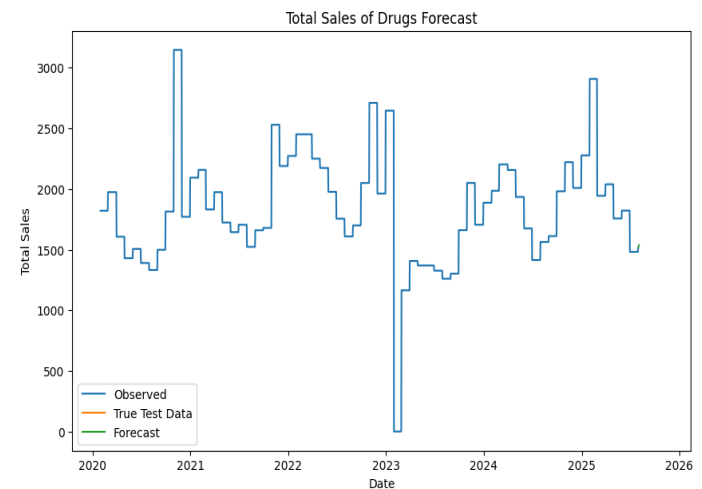


Figura 20. Pronóstico de demanda de medicamentos usando modelo AR

El gráfico mostró que el modelo logra capturar la tendencia general de la serie, aunque presenta limitaciones para reproducir variaciones abruptas, lo cual es característico de modelos autorregresivos simples.

Sin embargo, su desempeño fue adecuado como aproximación inicial para la predicción de la demanda en el contexto hospitalario.

3.4.2. Modelo ARIMA

Con el objetivo de mejorar la capacidad predictiva del modelo autorregresivo simple, se implementó un modelo ARIMA (AutoRegressive Integrated Moving Average), el



cual permite capturar no solo la dependencia temporal, sino también la tendencia y los componentes de error presentes en la serie.

Este modelo resulta adecuado para series no estacionarias, como la demanda de medicamentos observada, ya que incorpora un proceso de diferenciación que elimina la tendencia y estabiliza la media de la serie.

3.4.2.1. Ajuste del modelo ARIMA

El modelo ARIMA fue configurado con parámetros $(p, d, q) = (1, 1, 1)$, definidos a partir del análisis previo de autocorrelación (ACF) y autocorrelación parcial (PACF), así como de la necesidad de aplicar una diferenciación de primer orden para lograr la estacionariedad.

Matemáticamente, el modelo se expresa como:

$$\Delta Y_t = c + \phi_1 \Delta Y_{t-1} + \theta_1 \epsilon_{t-1} + \epsilon_t$$

Donde cada uno de sus componentes se interpreta de la siguiente manera:

- Y_t : representa la demanda de medicamentos en el periodo actual t , medida a través de la variable agregada `total_sales`.
- ΔY_t : corresponde a la serie diferenciada, definida como:

$$\Delta Y_t = Y_t - Y_{t-1}$$

Este término permite eliminar la tendencia de la serie y garantizar la estacionariedad, condición necesaria para la correcta aplicación del modelo ARIMA.

- c : es la constante del modelo, la cual representa el nivel promedio de la serie diferenciada cuando los demás términos son nulos.
- ϕ_1 : es el coeficiente autorregresivo de primer orden (AR), que mide la influencia del cambio en la demanda del periodo anterior (ΔY_{t-1}) sobre el cambio actual. Este parámetro captura la persistencia temporal de la serie.
- θ_1 : es el coeficiente de media móvil (MA), el cual modela el impacto del error del periodo anterior (ϵ_{t-1}) sobre el valor actual. Este componente permite corregir errores pasados y mejorar la precisión del modelo.
- ϵ_t : representa el término de error aleatorio en el periodo actual, el cual se asume como ruido blanco con media cero y varianza constante.
- $p=1$: indica que el modelo utiliza un rezago autorregresivo de primer orden.
- $d=1$: señala que se aplicó una diferenciación de primer orden para estabilizar la serie.

- $q=1$: indica la inclusión de un término de media móvil de primer orden.

El ajuste del modelo se realizó utilizando el conjunto de entrenamiento, comprendido hasta diciembre de 2024, lo que permitió estimar los parámetros del modelo sin comprometer la validez de la evaluación posterior.

4.4.2.2. Predicción de la demanda futura de medicamentos

Una vez ajustado el modelo, se generaron predicciones para el conjunto de prueba correspondiente al año 2025, utilizando la función `forecast()`.




Figura 21. Pronóstico de demanda mediante modelo ARIMA

En la figura se observan tres componentes principales:

- Datos de entrenamiento (Train Data)
- Datos reales del conjunto de prueba (True Test Data)
- Predicción generada por el modelo (ARIMA Forecast)

El modelo ARIMA mostró una tendencia general de la serie, generando predicciones relativamente estables.

Sin embargo, se evidenció una limitación importante en la capacidad del modelo para reproducir variaciones abruptas o cambios bruscos en la demanda.

En particular, se observó que el modelo tiende a suavizar la serie, generando predicciones menos volátiles en comparación con los valores reales.

3.4.3. Comparación entre valores observados y predichos

Con el fin de evaluar el desempeño del modelo, se realizó una comparación directa entre lo observado y lo predicho.

La evaluación gráfica permitió comparar la capacidad predictiva de los modelos ARIMA y SARIMA frente a los datos reales de demanda de medicamentos. Se presentan tres gráficas principales:




Figura 22. Pronóstico de demanda mensual de medicamentos mediante el modelo ARIMA

De la figura anterior se muestra que la línea azul representa los datos de entrenamiento, la línea naranja los valores reales de prueba, y la línea verde el pronóstico generado por ARIMA. Los picos de demanda elevados en ciertos meses no se reflejan completamente en el pronóstico, lo que indica que el modelo ARIMA, sin componentes estacionales explícitos, predice bien la tendencia central, pero tiene limitaciones en periodos con variaciones extremas.




Figura 23. Pronóstico de demanda mensual de medicamentos mediante el modelo SARIMA

A partir de la figura anterior se evidencia que la línea verde representa el pronóstico SARIMA.

A diferencia del modelo ARIMA, el modelo SARIMA logra reproducir de manera más precisa los picos y valles estacionales de la curva de la demanda mensual y esto refleja la capacidad del modelo para incorporar patrones periódicos de 12 meses.

En estas figuras, la comparación visual permite observar que SARIMA ajusta mejor la amplitud de las oscilaciones

estacionales, mostrando menor desviación respecto a los valores reales.

Aunque en el modelo ARIAM se subestima la demanda en meses con picos pronunciados, evidenciando la ventaja de incluir estacionalidad en contextos de demanda hospitalaria variable.

3.5. Evaluación del desempeño del modelo

La evaluación cuantitativa del desempeño de los modelos se realizó mediante métricas de error estándar: RMSE y MAE.

Estas métricas permiten cuantificar la discrepancia entre los valores pronosticados y los observados, y son esenciales para validar la utilidad del modelo en la planificación de inventarios y gestión de medicamentos.

3.5.1. Métricas de evaluación

Para cuantificar el error de predicción se calcularon las métricas más representativas:

3.5.1.1. RMSE (Root Mean Squared Error)

El RMSE indica la desviación promedio entre los valores reales y los predichos, penalizando errores grandes.

Valores menores reflejan un mejor ajuste del modelo.

- ARIMA: 5.82 %
- SARIMA: 3.76 %

3.5.1.2. MAE (Mean Absolute Error)

El MAE muestra el error promedio absoluto, representando la magnitud de los errores sin considerar su dirección. Valores más bajos indican mayor precisión.

- ARIMA: 5.14 %
- SARIMA: 3.42 %

3.5.1.3. Interpretación de las métricas de error

Los resultados indican que SARIMA presenta menores errores tanto en RMSE como en MAE respecto a ARIMA, lo que confirma que la incorporación de estacionalidad permite capturar mejor los patrones periódicos de la demanda de medicamentos.

Esto es consistente con la observación gráfica de los pronósticos, donde SARIMA se ajusta con mayor precisión a los picos y valles estacionales.

3.5.2. Análisis de residuos del modelo

La evaluación gráfica del comportamiento de los modelos permitió analizar de manera cualitativa.

Al observar los gráficos previamente referenciados en la sección 4.4.3, se constató que ambos modelos lograron capturar la tendencia general de la demanda de medicamentos, reflejando incrementos y descensos a lo largo del tiempo.

Sin embargo, se evidenció que SARIMA replicaba con mayor precisión los patrones estacionales, adaptándose mejor a los picos de alta demanda y a las variaciones periódicas presentes en la serie temporal.

3.6. Impacto del modelo en la gestión de medicamentos

Los resultados generados por estos modelos mostraron tendencias y patrones estacionales, lo que posibilitó la planificación anticipada de compras.

3.7. Integración de modelos predictivos y LLM en la toma de decisiones

3.7.1. Entrada de datos y preparación de información

La preparación incluye:

- Formateo de las series temporales y predicciones.
- Estandarización de métricas de error.
- Conversión de datos en tablas comprensibles para el LLM.

3.7.2. Generación de recomendaciones estratégicas

El LLM utiliza los datos estructurados para producir recomendaciones concretas:

- Corto plazo: Ajustes inmediatos de inventario crítico y revisión de puntos de reorden (ROP).
- Mediano plazo: Planificación de compras, consolidación de pedidos y acuerdos con proveedores.
- Largo plazo: Estrategias de seguridad del suministro y rotación de stock para reducir pérdidas por vencimiento.

El modelo LLM complementa los resultados de los modelos predictivos, proporcionando una interpretación lógica de los datos y sugerencias que facilitan la toma de decisiones.

```
*** Recomendaciones basadas en la evaluación de las métricas y las predicciones ***
En base a las métricas obtenidas del modelo SARIMA y las predicciones de ventas para los años 2020 a 2025, se pueden generar las siguientes recomendaciones:
**Evaluación de las métricas**
- El RMSE (Error cuadrático medio) es de 25648.33, lo que indica un error significativo en la predicción del modelo. Esto sugiere que el modelo puede estar sobrecapado o que la demanda es demasiado volátil.
- El MAE (Error absoluto medio) es de 48378, lo que indica que el error en la predicción es considerable. Esto sugiere que el modelo puede estar subajustado.
- El MAPE (Error porcentual absoluto medio) es del 22.34%, lo que indica que el error en la predicción es moderado. Esto sugiere que el modelo puede ser útil para propósitos de planificación a largo plazo.
**Evaluación de las predicciones**
- Las predicciones de ventas para los años 2020 a 2025 muestran una tendencia decreciente, con una reducción del 58% en las ventas totales entre 2020 y 2025.
- Las predicciones sugieren que la farmacia hospitalaria debe reducir su inventario de medicamentos y ajustar sus compras para reflejar la disminución de la demanda.
**Recomendaciones**
1. **Revisar y ajustar el modelo SARIMA**: Debido a los errores significativos en la predicción, se recomienda revisar y ajustar el modelo SARIMA para mejorar su precisión.
2. **Reducir el inventario de medicamentos**: Debido a la tendencia decreciente en las ventas, se recomienda reducir el inventario de medicamentos para optimizar el flujo de caja y reducir costos de almacenamiento.
3. **Ajustar las compras**: Se recomienda ajustar las compras de medicamentos para reflejar la disminución en la demanda. Esto puede incluir la negociación de mejores precios con los proveedores y la implementación de programas de gestión de inventario.
4. **Monitorear y evaluar la demanda**: Se recomienda monitorear y evaluar la demanda de medicamentos de manera regular para asegurarse de que las predicciones sigan siendo precisas.
5. **Considerar estrategias de mitigación**: Debido a la incertidumbre en la predicción, se recomienda considerar estrategias de mitigación para reducir el riesgo de quedarse sin stock o de tener exceso de inventario.
En resumen, las recomendaciones sugieren que la farmacia hospitalaria debe ajustar su inventario y compras para reflejar la disminución en la demanda y mejorar su eficiencia operativa.
```

Figura 24. Recomendaciones estratégicas generadas por el LLM de la plataforma de Meta

```
*** 1. Interpretación rápida de los resultados ***
|Métrica| Valor | Qué indica | Comentario para la farmacia |
|---|---|---|---|
|RMSE**| 25648.33 | Error cuadrático medio (en unidades de venta). Un valor elevado sugiere que, en promedio, el modelo está "desviándose" varios cientos de unidades de la demanda real. |
|MAE**| 48378.00 | Error absoluto medio (en unidades de venta). Un MAE alto indica que el modelo tiende a subestimar o sobrestimar los valores. |
|MAPE**| 22.34 % | Error porcentual absoluto medio (%). En promedio, el pronóstico se desvía 22 % del valor real. |
|**Nota**| | Mis aceptable que el RMSE, pero sigue siendo un margen de error considerable. |
***Conclusión breve** El modelo SARIMA captura la tendencia decreciente, pero la precisión es limitada. Se pueden usar sus resultados como "orientación" (no como pronóstico exacto).

*** 2. Análisis del pronóstico de ventas (2020-2025) ***
|Año| Ventas pronosticadas (unidades) | % Cambio respecto al año anterior |
|---|---|---|
|2020| 2 000 | - |
|2021| 1 500 | -25.0 % |
|2022| 1 000 | -33.3 % |
|2023| 750 | -25.0 % |
|2024| 500 | -33.3 % |
|2025| 250 | -50.0 % |
- **Tendencia clara:** caída sostenida y acelerada de la demanda.
- **Implica:** menor necesidad de inventario, pero también mayor riesgo de "obsolescencia" y "pérdida de capacidad de respuesta" si la tendencia se invierte (p.ej., un resurgimiento repentino).

*** 3. Recomendaciones operativas ***
*** 3.1 Gestión de inventario (corto-plazo: 0-12 meses) ***
|Acción| Por qué | Cómo implementarla |
|---|---|---|
|**Reducir el stock de productos de alta demanda** (A, B, C) y ajustar los puntos de reorden (ROP) según la disminución pronosticada. | Evita exceso de stock y costos de mantenimiento. |
|**Aumentar el safety stock (stock de seguridad)** en un 10-20 % para los productos críticos (ej., antibióticos de primera línea) y reducirlo en un 30-40 % en los productos de menor demanda. |
|**Implementar "re-order point dinámico" basado en un "rolling window" de 3-6 meses para captar cambios estacionales o emergencias. | Permite reaccionar rápido a cambios de demanda. |
|**Negociar acuerdos de suministro "just-in-time" con cláusulas de flexibilidad (p.ej., entregas parciales, plazos más cortos). | Reduce la necesidad de grandes inventarios. |
```

Figura 25. Recomendaciones estratégicas generadas por el LLM de la compañía de OpenAI

3.7.3. Aplicación práctica y retroalimentación

Este subpunto aborda cómo las recomendaciones del LLM se implementan en la operación diaria de la farmacia hospitalaria y cómo se retroalimenta el sistema:

- Monitoreo de los ajustes sugeridos y su efectividad.
- Validación de predicciones y ajustes mediante comparación con datos reales.
- Retroalimentación para mejorar continuamente la precisión del modelo.

Esta estructura permite reflejar de manera clara el flujo de integración entre modelos cuantitativos (ARIMA/SARIMA) y cualitativos (LLM), mostrando un enfoque proactivo y sustentado en datos para la gestión farmacéutica.

3.8. Prueba de hipótesis

Prueba de hipótesis HE1:

HE1: - El machine learning incrementa significativamente la precisión en la predicción de la demanda de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

H_0 = El machine learning no incrementa significativamente la precisión en la predicción de la demanda de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

H_1 = El machine learning incrementa significativamente la precisión en la predicción de la demanda de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

Procedimiento de la prueba de hipótesis

Para evaluar la hipótesis planteada, se requiere:



- Una métrica adecuada para medir la precisión del modelo, tales como: RMSE (Root Mean Squared Error) y MAE (Mean Absolute Error).
- Un dataset comparativo:
 1. Predicción sin modelo (método tradicional o baseline)

2. Predicción con modelo de Machine Learning (ARIMA/SARIMA)

Previo a la aplicación de las pruebas de hipótesis, se evaluó el supuesto de normalidad. Esta evaluación permite determinar el tipo de prueba estadística a utilizar (paramétrica o no paramétrica).

Tabla 1

Prueba de normalidad de las pruebas de pretest y postest para el primer objetivo

	Pruebas de normalidad					
	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
I1 - PRETEST	,232	80	,000	,787	80	,000
I1 - POSTEST	,340	80	,000	,636	80	,000

Los resultados de la figura anterior muestran que:

- En la prueba de Shapiro-Wilk, tanto para el pretest como para el postest, se obtienen valores de significancia de $p = 0.000$, siendo menores a 0.05.
- En la prueba de Kolmogorov-Smirnov, tanto para el pretest como para el postest, se obtienen valores de significancia de $p = 0.000$, siendo menores a 0.05.

Interpretación:

Dado que la prueba de Shapiro-Wilk es más adecuada para muestras pequeñas y medianas ($n < 100$), se toma como referencia principal. En este caso:

Tabla 2

Prueba de Wilcoxon respecto a HE1

Estadísticos de prueba	
Z	I1 - POSTEST - I1 - PRETEST
	-7,843 ^b
Sig. asintótica	,000

Conclusión de HE1:

El machine learning incrementa significativamente la precisión en la predicción de la demanda de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

Prueba de hipótesis HE2:

HE2: El machine learning aumenta significativamente la exactitud en el control de los niveles de inventario de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

$p < 0.05$: los datos no siguen una distribución normal

Por lo tanto, se concluye que los datos no presentan normalidad, lo que implica el uso de pruebas no paramétricas en el contraste de hipótesis.

Regla de decisión:

Si: $p < 0.05$: se rechaza H_0

Si: $p \geq 0.05$: no se rechaza H_0

H_0 = El machine learning no aumenta significativamente la exactitud en el control de los niveles de inventario de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

H_1 = El machine learning aumenta significativamente la exactitud en el control de los niveles de inventario de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.



Procedimiento de la prueba de hipótesis:

Para evaluar la hipótesis planteada, se requiere:

- Exactitud de inventario (%).

- Diferencia entre stock real vs proyectado.

Previo a la aplicación de las pruebas de hipótesis, se evaluó el supuesto de normalidad. Esta evaluación permite determinar el tipo de prueba estadística.

Tabla 2

Prueba de normalidad de las pruebas de pretest y postest para el segundo objetivo

	Pruebas de normalidad					
	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
I2 - PRETEST	,113	80	,013	,938	80	,001
I2 - POSTEST	,130	80	,002	,925	80	,000

Los resultados de la figura anterior muestran que:

- En la prueba de Shapiro-Wilk, el pretest presenta $p = 0.001$ y el postest $p = 0.000$.
- En la prueba de Kolmogorov-Smirnov, el pretest presenta $p = 0.013$ y el postest $p = 0.002$.

valor umbral y en estos resultados del valor de p evidencian ser inferiores al valor de umbral: 0.05.

Es decir, los datos o siguen una distribución normal.

Por lo tanto, implica el uso de pruebas no paramétricas en el contraste de hipótesis.

Interpretación

Dado que la prueba de Shapiro-Wilk es más adecuada para muestras pequeñas y medianas, se la consideró como prueba de referencia para comparar el valor de p con el

Regla de decisión:

Si: $p < 0.05$: se rechaza H_0

Si: $p \geq 0.05$: no se rechaza H_0

Tabla4

Prueba de Wilcoxon respecto a HE2

Estadísticos de prueba	
	I2 - POSTEST - I2 - PRETEST
Z	-7,772
Sig. asintótica	,000

Conclusión de HE2:

El machine learning aumenta significativamente la exactitud en el control de los niveles de inventario de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

H_1 = El machine learning reduce significativamente los desabastecimientos y el sobre stock de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

Prueba de hipótesis HE3:

HE3: El machine learning reduce significativamente los desabastecimientos y el sobre stock de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

Procedimiento de la prueba de hipótesis

Para evaluar la hipótesis planteada, se requiere:

- Número de quiebres de stock
- Nivel de sobreinventario.

Previo a la aplicación de las pruebas de hipótesis, se evaluó el supuesto de normalidad.

Esta evaluación permite determinar el tipo de prueba estadística.

Tabla 3

Prueba de normalidad de las pruebas de pretest y postest para el tercer objetivo

	Pruebas de normalidad					
	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
I3 - PRETEST	,094	80	,080	,944	80	,002
I3 - POSTEST	,136	80	,001	,936	80	,001

Los resultados de la figura anterior muestran que:

- En la prueba de Shapiro-Wilk, el pretest presenta $p = 0.002$ y el postest $p = 0.001$.
- En la prueba de Kolmogorov-Smirnov, el pretest presenta $p = 0.080$ y el postest $p = 0.001$.

Interpretación

Dado que la prueba de Shapiro-Wilk es más adecuada para estas muestras, se la consideró como prueba de referencia

para comparar el valor de p con el valor umbral y a partir de estos resultados se muestra que el valor de p evidencia ser inferior al valor de umbral: 0.05. Es decir, los datos o siguen una distribución normal. Por lo tanto, implica el uso de pruebas no paramétricas en el contraste de hipótesis.

Regla de decisión:

Si: $p < 0.05$: se rechaza H_0

Si: $p \geq 0.05$: no se rechaza H_0

Tabla 6

Prueba de Wilcoxon respecto a HE3

Estadísticos de prueba	
	I3 - POSTEST - I3 - PRETEST
Z	-7,772 ^b
Sig. asintótica	,000

Conclusión de HE3:

El machine learning reduce significativamente los desabastecimientos y el sobre stock de medicamentos en una farmacia hospitalaria de Lima durante el año 2025.

Prueba de hipótesis HE4:

HE4: El machine learning eleva significativamente la oportunidad y calidad de la información utilizada para la toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025.

H_0 = El machine learning no eleva en elevar la oportunidad y calidad de la información utilizada para la toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025.

H_1 = El machine learning eleva significativamente la oportunidad y calidad de la información utilizada para la toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025.

Procedimiento de la prueba de hipótesis

Para evaluar la hipótesis planteada, se requiere:

- Tiempo de generación de reportes
- Precisión de reportes
- Nivel de actualización de datos

Previo a la aplicación de las pruebas de hipótesis, se evaluó el supuesto de normalidad. Esta evaluación permite determinar el tipo de prueba estadística.

Tabla 7

Prueba de normalidad de las pruebas de pretest y postest para el cuarto objetivo

Pruebas de normalidad	
Kolmogorov-Smirnov	Shapiro-Wilk

	Estadístico	gl	Sig.	Estadístico	gl	Sig.
I4 - PRETEST	,126	80	,003	,938	80	,001
I4 - POSTEST	,148	80	,000	,906	80	,000

Los resultados de la figura anterior muestran que:

- En la prueba de Shapiro-Wilk, el pretest presenta $p = 0.001$ y el postest $p = 0.000$.
- En la prueba de Kolmogorov-Smirnov, el pretest presenta $p = 0.003$ y el postest $p = 0.000$.

Interpretación

Dado que la prueba de Shapiro-Wilk es más adecuada para estas muestras, se la consideró como prueba de referencia para comparar el valor de p con el valor umbral y a partir

de estos resultados se muestra que el valor de p evidencia ser inferior al valor de umbral: 0.05. Es decir, los datos o siguen una distribución normal. Por lo tanto, implica el uso de pruebas no paramétricas en el contraste de hipótesis.

Regla de decisión

Si: $p < 0.05$: se rechaza H_0

Si: $p \geq 0.05$: no se rechaza H_0

Tabla 8

Prueba de Wilcoxon respecto a HE4

Estadísticos de prueba	
Z	I4 - POSTEST - I4 - PRETEST
Sig. asintótica	-7,771 ^b
	,000

Conclusión de HE4:

El machine learning eleva significativamente la oportunidad y calidad de la información utilizada para la toma de decisiones en una farmacia hospitalaria de Lima durante el año 2025.

Discusión

La aplicación del modelo predictivo basado en ML evidenció un impacto positivo en la gestión de medicamentos, reflejado principalmente en la mejora significativa de la precisión en la predicción de la demanda, con reducciones en métricas de error como RMSE y MAE, y un mejor ajuste a los patrones reales de las series temporales. Estos resultados confirman la capacidad de los modelos predictivos para capturar comportamientos complejos en datos farmacéuticos, en concordancia con lo planteado por Tri (2024), quien reporta un MAPE de 9.8% mediante modelos híbridos CNN-LSTM, destacando su eficacia en el análisis de dependencias temporales. Asimismo, los hallazgos coinciden con Fourkiotis (2024), quien sostiene que los modelos de machine learning superan a los enfoques estadísticos tradicionales al incorporar patrones estacionales y no lineales, lo cual refuerza la validez de los resultados obtenidos. En el contexto nacional, la mejora observada supera lo reportado

por Quispe (2021), evidenciando que el modelo implementado no solo incrementa la precisión, sino que también fortalece la capacidad predictiva en escenarios reales de farmacias hospitalarias. En este sentido, los modelos basados en series temporales pueden constituirse en herramientas efectivas para reducir la incertidumbre y optimizar la planificación del abastecimiento.

En relación con el control de inventarios, los resultados evidencian que la implementación del modelo contribuye significativamente a mejorar la exactitud en la gestión de los niveles de stock, permitiendo una mayor sincronización entre la demanda proyectada y las decisiones de reposición. Este hallazgo es consistente con lo reportado por Ramos (2022), quien identificó un incremento del 35% en la exactitud del control de inventarios tras la aplicación de modelos predictivos, así como con Shen (2024), quien destaca mejoras en la eficiencia operativa y reducción de errores mediante el uso de inteligencia artificial en la cadena de suministro farmacéutica. En comparación con estos estudios, la presente investigación aporta evidencia de que modelos como ARIMA pueden ser altamente efectivos incluso en contextos con limitaciones tecnológicas, destacando su aplicabilidad práctica y su capacidad de generar valor inmediato sin requerir infraestructuras complejas.



Por otro lado, la reducción significativa de los niveles de desabastecimiento y sobre stock. Este resultado guarda relación con lo planteado por Pall (2023), quien demuestra la capacidad de los modelos predictivos para anticipar eventos críticos de desabastecimiento, así como con Mbonyinshuti (2021), quien reporta mejoras en la planificación de la demanda mediante técnicas de machine learning. A nivel nacional, los resultados son comparables e incluso superiores a los reportados por Ramos (2022) y Vargas (2024), quienes evidencian reducciones importantes en eventos de desabastecimiento. En este contexto, la investigación refuerza la idea de que el uso de modelos predictivos permite transitar de una gestión reactiva a una gestión proactiva, basada en evidencia cuantitativa y orientada a la reducción de riesgos operativos.

Finalmente, los resultados demuestran una mejora significativa en la oportunidad y calidad de la información utilizada para la toma de decisiones, al proporcionar datos oportunos, consistentes y basados en evidencia analítica. Este hallazgo es coherente con lo señalado por Salazar (2023), quien reporta mejoras en la oportunidad de la información y reducción de compras de emergencia tras la implementación de sistemas inteligentes, así como con Shen (2024), quien destaca la importancia de la información estandarizada para la optimización de procesos logísticos. En comparación con estos antecedentes, el presente estudio evidencia que la incorporación de modelos de machine learning no solo mejora indicadores operativos, sino que transforma la dinámica de la toma de decisiones.

Conclusiones

La implementación del modelo de ML para la predicción de la demanda de medicamentos demostró un impacto significativo en la mejora de la precisión de los pronósticos, evidenciado en la reducción de métricas de error como el RMSE y el MAE. Este resultado valida la eficacia del modelo para anticipar patrones de consumo en entornos hospitalarios, confirmando la relevancia de variables como el historial de consumo, la estacionalidad y la frecuencia de prescripción en la predicción de la demanda. No obstante, los resultados también evidencian que la calidad, consistencia y actualización de los datos son factores determinantes para optimizar el rendimiento del modelo.

El modelo predictivo aplicado al control de inventarios evidenció una mejora sustancial en la exactitud de los niveles de stock, permitiendo una adecuada sincronización entre la demanda proyectada y las decisiones de reposición. Este hallazgo confirma la capacidad del machine learning para optimizar la gestión de inventarios en farmacias hospitalarias, reduciendo errores y mejorando la eficiencia

operativa. Sin embargo, se identifican desafíos relacionados con la disponibilidad de datos estructurados, la integración de sistemas y la variabilidad de la demanda, los cuales pueden influir en la generalización de los resultados. Por ello, se recomienda integrar fuentes de datos complementarias, fortalecer la interoperabilidad de los sistemas de información y aplicar enfoques híbridos que permitan mejorar la robustez del modelo en distintos contextos hospitalarios.

En relación con la gestión del abastecimiento, los resultados evidenciaron una reducción significativa en los niveles de desabastecimiento y sobre stock, lo cual optimiza las decisiones de compra y almacenamiento. Este hallazgo respalda la pertinencia de incorporar analítica predictiva en la gestión farmacéutica, al permitir anticipar escenarios de riesgo y minimizar pérdidas económicas asociadas a vencimientos o faltantes. No obstante, la evidencia también señala la necesidad de considerar factores externos como cambios epidemiológicos, políticas de salud y variaciones en la demanda clínica, los cuales pueden influir en el comportamiento del consumo. Por ende, se sugiere complementar el modelo con variables contextuales y técnicas de análisis más avanzadas que permitan una mayor adaptabilidad y precisión.

Finalmente, la implementación del modelo de -ML evidenció una mejora significativa en la oportunidad y calidad de la información utilizada para la toma de decisiones, al proporcionar datos consistentes, oportunos y basados en evidencia empírica. Este resultado confirma que la analítica predictiva contribuye a transformar la gestión farmacéutica desde un enfoque reactivo hacia uno proactivo y basado en datos. Sin embargo, se identifican retos asociados a la adopción tecnológica, la capacitación del personal y la gobernanza de datos, aspectos clave para garantizar la sostenibilidad del modelo en el tiempo. En ese sentido, se recomienda promover una cultura organizacional orientada al uso de datos, fortalecer las competencias digitales del personal y establecer políticas de gestión de datos que aseguren la calidad, seguridad y trazabilidad de la información, consolidando así el uso del machine learning como una herramienta estratégica en la mejora continua del servicio farmacéutico hospitalario.

Recomendaciones

Las entidades bancarias deberían centrarse en la implementación de programas de capacitación técnica especializada mientras se hace seguimiento a la idoneidad continuada de sus arquitecturas de IA; a diferencia de los enfoques puramente teóricos que se han analizado en la literatura, este trabajo demuestra que la incorporación empírica de las amenazas reales junto a los modelos predictivos constituye la clave para perfeccionar la



defensa; por ello, la inversión en tecnología ha de ir acompañada de un camino de desarrollo de competencias en el capital humano para garantizar la viabilidad frente a los retos actuales.

Con todo ello, también se recomienda desarrollar protocolos específicos basados en IA que ayuden a mejorar la detección adelantada. Para verificar que estos sistemas son eficaces, es necesario programar y realizar simulacros periódicos dirigidos a los equipos de ciberseguridad que permitan auditar la eficacia de la capacidad de respuesta real del sistema ante amenazas complejas, asegurando de este modo que las herramientas predictivas están correctamente afinadas para contrarrestar ataques de alta persistencia.

Se aconseja a las áreas de infraestructura tecnológica de las entidades financieras reforzar la resiliencia del sistema frente a las APT, garantizando la implementación de herramientas que permitan el monitoreo y la mitigación continua de los riesgos.

Resulta apropiado establecer calendarios de actualización de los modelos predictivos de IA contra amenazas con carácter más sofisticado, la actualización de las mejoras se guarda alineada a las tendencias globales de innovación tecnológica y futuras APT.

Referencias Bibliográficas

- Abouelmehdi, K., Beni-Hessane, A., & Khaloufi, H. (2021). Big data security and privacy in healthcare: A review. *Procedia Computer Science*, 113, 73–80. <https://doi.org/10.1016/j.procs.2017.08.292>
- Abrar, M., ur Rehman, M., Khalid, S., et al. (2026). The intersection of artificial intelligence and assistive technologies in the diagnosis and intervention of mental health conditions. *Artificial Intelligence Review*, 59, 40. <https://doi.org/10.1007/s10462-025-11447-9>
- Ali, A. J., Verma, M., & Hamdan, R. (2025). Impact of outsourcing on government service quality. In A. Hamdan (Ed.), *Achieving Sustainable Business through AI, Technology Education and Computer Science (Studies in Big Data, vol. 158, pp. 541-553)*. Springer, Cham. https://doi.org/10.1007/978-3-031-70855-8_50
- Babic, B., Cohen, I. G., Stern, A. D., Li, Y., & Ouellet, M. (2025). A general framework for governing marketed AI/ML medical devices. *npj Digital Medicine*, 8(328). <https://doi.org/10.1038/s41746-025-01717-9>
- Bader, A., Shtayat, A., & Al-Mistarehi, B. (2025). Enhancing structural health monitoring with AI-ML algorithms: a focus on crack detection and prediction. *Asian Journal of Civil Engineering*, 26, 1907–1918. <https://doi.org/10.1007/s42107-024-01261-z>
- Batini, C., Cappiello, C., Francalanci, C., & Maurino, A. (2022). Methodologies for data quality assessment and improvement. *ACM Computing Surveys*, 54(6), 1–41. <https://doi.org/10.1145/3487890>
- Bharech, S., Yang, Y., Selzer, M., et al. (2025). ML-extendable framework for multiphysics-multiscale simulation workflow and data management using Kadi4Mat. *Scientific Data*, 12, 962. <https://doi.org/10.1038/s41597-025-05027-3>
- Bocean, C. G., & Vărzaru, A. A. (2025). Health status in the era of digital transformation and sustainable economic development. *BMC Health Services Research*, 25, 343. <https://doi.org/10.1186/s12913-025-12498-y>
- Dash, S., Shakyawar, S. K., Sharma, M., & Kaushik, S. (2021). Big data in healthcare: Management, analysis and future prospects. *Journal of Big Data*, 8(1), 1–25. <https://doi.org/10.1186/s40537-021-00417-7>
- Floridi, L., Cows, J., Beltrametti, M., et al. (2021). AI4PeopleAn ethical framework for a good AI society: Opportunities, risks, principles, and recommendations. *Minds and Machines*, 28(4), 689–707. <https://doi.org/10.1007/s11023-018-9482-5>
- Fourkiotis, K. P., & Tsadiras, A. (2024). Applying Machine Learning and Statistical Forecasting Methods for Enhancing Pharmaceutical Sales Predictions. *Forecasting*, 6(1), 170–186. <https://doi.org/10.3390/forecast6010010>
- González-Pérez, Y., Delgado, A. M., & Sesmero, J. M. M. (2024). Acercando la inteligencia artificial a los servicios de farmacia hospitalaria. *Farmacia Hospitalaria*, 48, S35–S44.
- Holden, R. J., & Karsh, B. T. (2021). The Technology Acceptance Model: Its past and its future in health care. *Journal of Biomedical Informatics*, 43(1), 159–172. <https://doi.org/10.1016/j.jbi.2009.07.002>
- Huamán, J. L. (2020). Aplicación de técnicas de machine learning para la predicción de demanda de medicamentos en un hospital público del Perú [Tesis de maestría, Universidad Nacional Mayor de San Marcos]. Repositorio Institucional UNMSM.



- Inga Llacza, F. G., Miranda Manrique, K. M. A., Quispe Zuñiga, D., Reyna Torres, J. M., & Turriate Naveda, S. (2023). Implementación de técnicas de Machine Learning para la segmentación de clientes en una empresa del sector farmacéutico.
- Kane, G. C., Phillips, A. N., Copulsky, J., & Andrus, G. (2021). The technology fallacy: How people are the real key to digital transformation. MIT Press.
- Kenyon, G. N. (2026). Service systems dimensions of quality. In *The Perception of Quality*. Springer, London. https://doi.org/10.1007/978-1-4471-7606-0_11
- Kwon, H. Y., Kim, S. J., Jung, S. Y., & Park, R. W. (2021). Predictive analytics for drug inventory management in hospitals using machine learning techniques. *BMC Medical Informatics and Decision Making*, 21(1), 1–12. <https://doi.org/10.1186/s12911-021-01455-6>
- Lazo Pilatuña, J. R., & Moreano Moncayo, A. V. (2021). Desarrollo de un sistema inteligente para predecir los consumos de medicamentos genéricos de mayor demanda en el distrito de salud 06d05 guano-penipe, aplicando técnicas de regresión de machine learning.
- Leixiao, Z., Xiaonan, S., Lutong, P., et al. (2024). Development and reliability and validity testing of a medication literacy scale for medical college students. *BMC Medical Education*, 24, 1238. <https://doi.org/10.1186/s12909-024-06222-3>
- León, F. E. (2020). Modelo de big data y machine learning para mejorar el proceso de toma de decisiones en la administración de la salud de la población (Doctoral dissertation, Universidad de Oviedo).
- Loaiza Saldivar, A. R., & Montano Vega, S. (2026). Desarrollo de un sistema web de planificación de abastecimiento médico gestionado por un modelo predictivo para anticipar la demanda de medicamentos. *Científica*.
- Madariaga Torres, S. M. (2021). Machine Learning para predecir volúmenes operacionales de las líneas de negocio de Cenabast.
- Manrique Rodriguez, D. S. (2025). Machine learning para la gestión de inventarios de medicamentos en el Hospital José Agurto Tello de Chosica.
- Mbonyinshuti, F., Nkurunziza, J., Niyobuhungiro, J., & Kayitare, E. (2021). The Prediction of Essential Medicines Demand: A Machine Learning Approach Using Consumption Data in Rwanda. *Processes*, 10(1), 26. <https://doi.org/10.3390/pr10010026>
- Mendoza Vasquez, D., & Salazar Chavez, S. S. (2022). Modelo Tecnológico utilizando herramientas de Machine Learning para apoyar la toma de decisiones en el Diagnóstico y Tratamiento de la Leucemia Pediátrica.
- Morley, J., Floridi, L., Kinsey, L., & Elhalal, A. (2020). From what to how: An overview of AI ethics tools, methods and research to translate principles into practices. *Science and Engineering Ethics*, 26(4), 2141–2168. <https://doi.org/10.1007/s11948-019-00165-1>
- Pall, R., et al. (2023). Predicting drug shortages using pharmacy data and machine learning. *PLOS ONE / (PMC free article)*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10009839/>
- Paramesha, K., Jalapur, S., Hanok, S., et al. (2025). Machine learning and deep learning approaches for guava disease detection. *SN Computer Science*, 6, 361. <https://doi.org/10.1007/s42979-025-03886-6>
- Porter, M. E., & Lee, T. H. (2021). The strategy that will fix health care. *Harvard Business Review*, 99(4), 50–70.
- Provost, F., & Fawcett, T. (2021). *Data science for business* (2nd ed.). O'Reilly Media.
- Quispe, R. A. (2021). Modelo predictivo basado en machine learning para la gestión de inventarios de medicamentos en un hospital público de Lima [Tesis de maestría, Universidad Nacional de Ingeniería]. Repositorio Institucional UNI.
- Raghupathi, W., & Raghupathi, V. (2020). Big data analytics in healthcare: Promise and potential. *Health Information Science and Systems*, 8(1), 1–10. <https://doi.org/10.1007/s13755-020-00112-7>
- Ramos, C. F. (2022). Implementación de un modelo de machine learning para optimizar la gestión de inventarios farmacéuticos en un hospital de Lima [Tesis de maestría, Universidad Tecnológica del Perú]. Repositorio UTP.
- Rodas Cortijo, C. L., & Villacrisis Guerrero, J. J. (2025). Aplicación de Machine Learning para la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024.
- Rueda Aldana, L. S. (2024). Machine Learning una solución para mejorar la percepción del dolor en



pacientes de dolor oncológico al predecir y mejorar la gestión de este síntoma en la práctica médica actual.

Salazar, M. E. (2023). Sistema inteligente para la toma de decisiones en la gestión de medicamentos en hospitales del MINSA [Tesis de maestría, Universidad César Vallejo]. Repositorio Institucional UCV.

Shen, J., Bu, F., Ye, Z., & Zhang, M. (2024). Management of drug supply chain information based on “artificial intelligence + vendor managed inventory” in China: perspective based on a case study. *Frontiers in Pharmacology (PMC free article)*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11286579/>

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2021). *Data mining for business analytics: Concepts, techniques, and applications in Python* (2nd ed.). Wiley.

Tri, L. Q., Bang, T. H., Tuyet, D. V., & Quang, N. D. (2024). Enhancing Hospital Pharmacy Management Efficiency Through Machine Learning Model for Drug Demand Prediction (PDF). Saigon International University (sitio institucional). <https://ai.siu.edu.vn/wp-content/uploads/2024/12/Enhancing-Hospital-Pharmacy-Management-Efficiency.pdf>

Vargas, P. H. (2024). Modelo de machine learning aplicado a la planificación del abastecimiento de medicamentos en un hospital nacional [Tesis de maestría, Universidad Peruana de Ciencias Aplicadas]. Repositorio UPC.

Vásquez Vera, A. F. (2025). Diseño de un modelo con uso de machine learning y big data para predecir el desabastecimiento de medicamentos.

Venkatesh, V., Thong, J. Y. L., & Xu, X. (2022). Unified theory of acceptance and use of technology: A synthesis and the road ahead. *Journal of the Association for Information Systems*, 17(5), 328–376.

Vial, G. (2021). Understanding digital transformation: A review and a research agenda. *Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/j.jsis.2019.01.003>

Wang, L., Zhang, J., He, K., & Li, X. (2023). Artificial intelligence-driven risk management in hospital pharmacy operations. *Journal of Medical Systems*,

47(3), 1–10. <https://doi.org/10.1007/s10916-023-01944-7>

Zhang, Y., Li, Z., Zhou, X., & Liu, S. (2022). Forecasting pharmaceutical demand using machine learning models: A comparative study. *Expert Systems with Applications*, 198, 116873. <https://doi.org/10.1016/j.eswa.2022.116873>

CORRESPONDENCIA:

Ronald Raul Fuentes Acuña
2023044431@unfv.edu.pe