

MODELO DE PREDICCIÓN DE DEMANDA PARA LA OPTIMIZACIÓN DE LA CADENA DE SUMINISTROS

DEMAND PREDICTION MODEL FOR SUPPLY CHAIN OPTIMIZATION

Recibido: 28/03/2025 – Aceptado: 25/04/2025

Eduardo Daniel Revelo Chacón

Investigador Independiente
Ecuador

Ingeniero en Logística y Transporte
Universidad Politécnica Estatal del Carchi

eduardo.revelo@upec.edu.ec

ORCID: <https://orcid.org/0000-0003-4728-4357>

Iván Gabriel Mafla Bolaños

Docente en la Universidad Politécnica Estatal del Carchi
Ecuador

Magister en Gerencia de Sistemas
Universidad de las Fuerzas Armadas

gabriel.mafla@upec.edu.ec

ORCID: <https://orcid.org/0000-0003-1841-2831>

Cómo citar este artículo:

Revelo Chacón, E. D., & Mafla Bolaños, I. G. (Enero – junio de 2025). Modelo de predicción de demanda para la optimización de la cadena de suministros. *Visión Empresarial*, Vol. 15, Núm. 2, 112 – 135. <https://doi.org/10.32645/13906852.1380>



Resumen

Este estudio propone un modelo de predicción de demanda basado en inteligencia artificial para optimizar la cadena de suministros de la distribuidora farmacéutica Grupo Montalvo. El objetivo principal es mejorar la precisión en la predicción de la demanda de medicamentos mediante el uso de modelos estadísticos y de aprendizaje automático, incluyendo el Suavizado Exponencial Simple (SES), ARIMA, SARIMA, Holt-Winters, Random Forest, redes neuronales (NN) y LSTM. La evaluación de los modelos se realizó utilizando métricas como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). Los resultados mostraron que el modelo de red neuronal (NN) fue el más preciso, alcanzando un MSE de 8.10×10^{-6} , un RMSE de 0.0028 y un MAE de 0.0016. En comparación, el modelo Random Forest presentó un MSE de 2.04×10^9 y un RMSE de 45232.60, lo que refleja un rendimiento mucho más bajo. Por otro lado, el modelo LSTM mostró un MSE extremadamente alto (1.07×10^{21}), indicando que requiere ajustes adicionales. Estos resultados destacan la superioridad de las redes neuronales para realizar predicciones precisas de la demanda, lo que contribuye a optimizar la toma de decisiones logísticas en la cadena de suministros.

Palabras clave: Predicción de demanda, inteligencia artificial, optimización de cadena de suministros, redes neuronales;

Abstract

This study proposes a demand prediction model based on artificial intelligence to optimize the supply chain of the pharmaceutical distributor Grupo Montalvo. The main objective is to improve the accuracy of medication demand forecasting using both statistical and machine learning models, including Simple Exponential Smoothing (SES), ARIMA, SARIMA, Holt-Winters, Random Forest, neural networks (NN), and LSTM. The models were evaluated using performance metrics such as Mean Squared Error (MSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). Results showed that the neural network model (NN) performed the best, achieving an MSE of 8.10×10^{-6} , an RMSE of 0.0028, and an MAE of 0.0016. In comparison, the Random Forest model had an MSE of 2.04×10^9 and an RMSE of 45232.60, indicating significantly lower performance. The LSTM model, on the other hand, displayed an extremely high MSE of 1.07×10^{21} , suggesting the need for further adjustments. These findings highlight the superiority of neural networks in providing accurate demand predictions, contributing to more efficient supply chain decision-making and optimization.

Keywords: Demand prediction; artificial intelligence; supply chain optimization; neural networks;

Código JEL: O3–O30

Introducción

La industria farmacéutica enfrenta numerosos problemas de cadena de suministro debido a la variabilidad de la demanda, la necesidad de controlar los niveles óptimos de inventario y a cumplir con las regulaciones de seguridad sanitaria estrictas. Tales situaciones generan costos, pérdidas rotas y posibles rupturas de suministro, perjudicando tanto a las empresas de la industria como a los pacientes que dependen de suministros de medicamentos constantes. En vista de este contexto, improvisar la precisión del pronóstico de demanda se vuelve indispensable para transformar la operativa y reducir los costos logísticos de manera significativa.

Estudios anteriores han investigado el uso de modelos de IA para la predicción de la demanda en el sector farmacéutico. Por ejemplo, Zhang (2019) Aplicaron métodos de aprendizaje automático para mejorar la precisión en el pronóstico de la demanda de medicamentos en los hospitales. Por otro lado, los autores Chauhan & Soni (2020) examinaron el suministro optimización de la cadena en la industria farmacéutica basándose en Random Forest. No obstante, es posible que la mayoría de los estudios anteriores centralizaran la aplicación de modelos estadísticos estándar y no exploraran en profundidad cómo funciones como redes neuronales corta larga plazo pueden mejorar los pronósticos en situaciones altamente variabilidad.

Esta investigación se basa en dos enfoques clave: el modelado estadístico de series temporales y el uso de técnicas de inteligencia artificial. Según Hyndman y Athanasopoulos (2018), se utilizan modelos como ARIMA y el Suavizado Exponencial, que se fundamentan en la idea de que los patrones históricos en los datos pueden ayudarnos a predecir tendencias futuras. Por otro lado, los modelos de inteligencia artificial, como Random Forest y las redes neuronales profundas (NN), se apoyan en teorías del aprendizaje automático. Liaw y Wiener (2019) describen el algoritmo Random Forest como un método que utiliza múltiples árboles de decisión, lo que permite generar pronósticos más robustos y precisos en comparación con modelos de regresión más simples. Además, las redes neuronales y LSTM se basan en el concepto de aprendizaje supervisado y se utilizan para modelar relaciones no lineales y dinámicas complejas. Esto es algo que Chollet (2018) y Goodfellow (2016) han destacado, siendo pioneros en el desarrollo de redes neuronales profundas y su aplicación en diversas áreas, incluyendo el análisis de series temporales.

En la distribuidora farmacéutica Grupo Montalvo, ubicada en Ibarra, Ecuador, no existía un modelo eficiente de predicción de demanda basado en inteligencia artificial, lo que limitaba la optimización de su cadena de suministro. La planificación de inventarios y compras se realizaba con métodos tradicionales que no consideraban el análisis avanzado de datos ni la capacidad de aprendizaje de patrones históricos. Esta carencia dificultaba la toma de decisiones estratégicas, aumentando la incertidumbre en la gestión de recursos y afectando la disponibilidad de medicamentos en el mercado.

El propósito de esta investigación fue desarrollar un modelo de predicción de demanda para Grupo Montalvo, integrando modelos estadísticos y técnicas de inteligencia artificial con el fin de mejorar la precisión de los pronósticos y optimizar la gestión de la cadena de suministro. Para ello, se evaluaron modelos como Suavizado Exponencial Simple (SES), ARIMA, SARIMA, Holt-Winters, Random Forest, redes neuronales artificiales (NN) y LSTM, comparando su desempeño mediante métricas como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE).

La principal contribución de esta investigación radica en la aplicación de enfoques avanzados de inteligencia artificial para mejorar la planificación logística y la distribución de medicamentos, reduciendo costos de inventario y aumentando la eficiencia en la cadena de suministro. Los resultados

obtenidos permitieron no solo optimizar los procesos internos de Grupo Montalvo, sino que también pueden servir de referencia para otras empresas farmacéuticas que enfrentan desafíos similares en mercados con alta incertidumbre y estrictas regulaciones.

Marco teórico

Planificación en la cadena de suministros

El concepto de planificación está asociado con la anticipación de eventos futuros y la organización de las actividades necesarias para abordar estos eventos de manera eficiente y eficaz. La planificación busca establecer una dirección clara, establecer prioridades, asignar recursos de manera adecuada e identificar y anticipar posibles obstáculos que puedan surgir en el camino (Affonso, 2023).

La planificación es fundamental para la anticipación y organización eficiente de eventos futuros. Al establecer dirección, prioridades, asignar recursos y prevenir obstáculos, se asegura una gestión efectiva y preparación para enfrentar desafíos, garantizando el logro de objetivos de manera óptima.

La SCM es el ciclo de vida de un producto o servicio, desde que se concibe hasta que se consume. Un subsistema dentro de la organización que engloba la planificación de las actividades de suministro, fabricación y distribución de los productos. La cadena de suministro engloba la oferta y la demanda, dentro y fuera de la empresa y es una filosofía de trabajo integradora para gestionar todos los flujos en los distintos canales de distribución: proveedores, clientes y consumidores finales (Estaún, 2023).

La cadena de suministros abarca el ciclo completo de vida de un producto o servicio, desde su concepción hasta su consumo. Es un subsistema organizacional que coordina la planificación de actividades de suministro, fabricación y distribución, integrando oferta y demanda tanto interna como externamente.

Características de la inteligencia artificial

La Inteligencia Artificial combina inteligencia con ingeniería para desarrollar herramientas que apoyen la inteligencia humana y crear máquinas que ejecuten tareas humanas que exigen inteligencia. Estos sistemas almacenan, manipulan datos, adquieren y aplican conocimiento, deducen información nueva y resuelven problemas complejos mediante representaciones y métodos específicos (Lopes et al., 2021).

La Inteligencia Artificial permite potenciar capacidades humanas y crear sistemas capaces de realizar tareas complejas, estos procesan datos, aplican conocimiento, generan nueva información y resuelven desafíos mediante métodos especializados, destacando su versatilidad y capacidad para abordar problemas diversos de manera eficiente.

Aplicaciones de la inteligencia artificial

Abarcan desde la automatización de tareas administrativas y transporte hasta la gestión de almacenes para mejorar la eficiencia y seguridad. Además, la IA permite análisis predictivos más precisos para anticipar la demanda y tendencias del mercado, mejorando la gestión de inventario y reduciendo costos. Asimismo, la IA contribuye a una gestión más eficiente de las relaciones con proveedores al facilitar la selección, evaluación del desempeño y automatización de comunicaciones. La visión artificial impulsada por IA transforma la calidad y gestión del inventario, mientras que la sostenibilidad se ve favorecida mediante la optimización de rutas y la reducción de emisiones en la cadena de suministro (Ortiz, 2023).

La Inteligencia Artificial (IA) impulsa la automatización, análisis predictivo, gestión de proveedores, visión artificial y sostenibilidad en la cadena de suministro, mejorando la eficiencia, seguridad, gestión de inventario y relaciones comerciales, y optimizando la calidad, gestión del inventario y sostenibilidad.

Importancia de la inteligencia artificial

La IA permite una mayor visibilidad y trazabilidad de los productos a lo largo de la cadena de suministros, lo que facilita la detección y resolución de problemas de manera más rápida y eficiente. Además, puede identificar patrones y tendencias en los datos, lo que ayuda a tomar decisiones más informadas y a anticipar posibles interrupciones o riesgos en la cadena de suministros (Gutiérrez y Polo, 2023).

La Inteligencia Artificial (IA) optimiza la supervisión y seguimiento de productos en la cadena de suministro, agilizando la identificación y solución de inconvenientes. Al analizar datos para detectar patrones y tendencias, facilitar la toma de decisiones fundamentadas, prevenir interrupciones y gestionar riesgos, mejorando la eficacia operativa y la capacidad de respuesta logística.

Inteligencia artificial y redes neuronales

Tanto la inteligencia artificial como las redes neuronales son tecnologías que han revolucionado la forma en que vivimos y trabajamos. Aunque es difícil determinar cuál es la mejor opción, es importante entender que depende del problema a resolver. La inteligencia artificial es una herramienta versátil que se puede aplicar en diferentes categorías, mientras que las redes neuronales son idóneas para solucionar problemas específicos (Pérez, 2023).

Modelos de predicción de demanda

Demanda

“La demanda es la suma de bienes y servicios requeridos por los consumidores considerando diferentes precios durante un determinado período de tiempo” (Pereda, 2021).

Esta definición resalta la relación entre precios y la cantidad demandada, subrayando la influencia de factores económicos y temporales en el comportamiento del consumidor y en la planificación estratégica de las empresas. Entender y anticipar la demanda es fundamental para la toma de decisiones efectivas en la gestión de inventarios, precios y estrategias de mercado.

Pronóstico

“Es una estimación cuantitativa o cualitativa de uno o varios factores (variables) que conforman un evento futuro, con base en información actual o del pasado” (Villarreal, 2016).

El pronóstico permite utilizar información previa para prevenir posibles escenarios y tomar decisiones informadas en diversos ámbitos, desde la planificación empresarial hasta la gestión de riesgos, realizar proyecciones precisas es fundamental para la toma de decisiones estratégicas y la preparación para eventos futuros.

Métodos tradicionales estadísticos

Regresión lineal

La regresión lineal es una técnica de análisis de datos que predice el valor de datos desconocidos mediante el uso de otro valor de datos relacionado y conocido. Modela matemáticamente la variable desconocida o dependiente y la variable conocida o independiente como una ecuación lineal (Avilés, 2024).

La regresión lineal es una herramienta fundamental en el análisis de datos, esta técnica proporciona una forma estructurada y matemática de entender y prever comportamientos en diversos contextos. La regresión lineal es ampliamente utilizada en la estadística y el aprendizaje automático para realizar predicciones y tomar decisiones fundamentadas en base a datos.

Media móvil

“Este método consiste en el suavizado de la serie dada, promediando sus observaciones con valores con valores contiguos, anteriores y posteriores” (Martínez, 2024, pág. 31).

Es una herramienta común en el análisis de datos para mejorar la interpretación y la precisión en la identificación de tendencias significativas, implica promediar observaciones con valores adyacentes, tanto anteriores como posteriores.

ARIMA

“Los Modelos de Promedio Móvil Autorregresivo Integrado, (ARIMA), por sus siglas en inglés, son una clase de modelos que tienen la capacidad de operar sobre series de tiempo estacionarias o no estacionarias” (Ruelas y Laguna, 2014).

Permite analizar y la predecir datos temporales, adaptándose a diferentes tipos de comportamientos en las series, permitiendo modelar y predecir con precisión cualquier tipo de fenómeno.

Métodos de inteligencia artificial

Redes neuronales artificiales

“En inteligencia artificial, las redes neuronales artificiales son modelos muy precisos en tareas como la clasificación y la regresión en el estudio de fenómenos naturales, pero se consideran “cajas negras” porque no permiten explicación directa de aquello que abordan.” (Rodríguez, 2024).

Esta técnica de regresión no sigue un modelo específico ni una relación lineal entre variables, lo que le permite predecir series temporales de forma efectiva. Siendo flexible, adaptándose a diferentes patrones de datos, aprendiendo de la información disponible y representa relaciones complejas y no lineales entre variables.

Redes neuronales para el pronóstico de series de tiempo

“Modelo de red neuronal para series de tiempo En la literatura se proponen diferentes estructuras de redes neuronales para analizar y obtener pronósticos de las series de tiempo. El modelo de red neuronal multicapa (RNM) es el más utilizado, comprende un conjunto de nodos (unidades de procesamiento) los cuales están organizados y distribuidos en tres capas: una capa de entrada, al menos una capa oculta y una capa de salida” (Zhang et al., 1998).

El modelo de red neuronal para series de tiempo emplea estructuras como la red neuronal multicapa (RNM) para pronósticos. Consta de nodos en tres capas: entrada, oculta y salida, siendo la RNM la más comúnmente utilizada en análisis y predicciones.

Materiales y métodos

La investigación realizada corresponde a un estudio cuantitativo y predictivo, cuyo propósito fue desarrollar un modelo de predicción de demanda aplicando técnicas estadísticas y de inteligencia artificial. Se centró específicamente en el análisis del Clonazepam 2 mg, un medicamento que representa el 9.21% de las ventas de la distribuidora farmacéutica Grupo Montalvo. La elección de este producto responde a su relevancia dentro de la cadena de suministro de la empresa y su impacto en la planificación y gestión de inventarios.

El estudio se llevó a cabo bajo un diseño no experimental y de tipo transversal, dado que se analizaron datos históricos sin intervención en el proceso de distribución del medicamento. Se empleó el análisis de series temporales como base metodológica, examinando patrones de demanda del Clonazepam 2 mg entre los años 2020 y 2024 con el fin de desarrollar modelos predictivos que permitan anticipar necesidades futuras. La muestra estuvo conformada por 118 registros mensuales de ventas

correspondientes a este período, los cuales fueron obtenidos de los sistemas internos de la empresa. Para garantizar la fiabilidad de los datos, se aplicaron criterios de inclusión que consideraron únicamente los registros completos de ventas e inventarios, excluyendo datos incompletos o referentes a otros productos farmacéuticos.

El estudio se realizó en la distribuidora farmacéutica Grupo Montalvo, ubicada en Ibarra, Ecuador. La empresa proporcionó los datos históricos de demanda, los cuales fueron recolectados a través de registros administrativos del departamento de logística y ventas. Para el procesamiento de los datos, se emplearon herramientas de análisis en Google Colab con Python, utilizando bibliotecas especializadas en modelado predictivo. Se implementaron modelos de predicción mediante los algoritmos de Random Forest, redes neuronales y redes de memoria a largo corto plazo (LSTM), desarrollados con TensorFlow y Keras. Los modelos fueron evaluados con métricas de error como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE), con el fin de determinar su capacidad de predicción en comparación con métodos tradicionales.

La investigación se realizó bajo estrictas consideraciones éticas, garantizando la confidencialidad de los datos utilizados. Toda la información procesada fue de carácter agregado y anónimo, sin involucrar datos personales de pacientes. La empresa otorgó la autorización para el uso de estos registros con fines académicos, asegurando que su aplicación se limitara exclusivamente al ámbito de este estudio.

Entre las limitaciones del estudio se encuentra el hecho de que el análisis se restringió a un solo medicamento, lo que dificulta la generalización de los resultados a otros productos dentro de la empresa. Asimismo, factores externos como fluctuaciones estacionales o cambios imprevistos en la demanda podrían afectar la precisión de los modelos predictivos, limitando su aplicabilidad en escenarios de alta variabilidad. Sin embargo, la metodología desarrollada sienta las bases para su implementación en otros productos, permitiendo optimizar la planificación de la cadena de suministro en la industria farmacéutica.

Resultados y discusión


En esta sección se exponen los resultados obtenidos de la implementación de los modelos de predicción de demanda para el Clonazepam 2 mg durante el periodo comprendido entre 2020 y 2024. En la figura 1 se presentan un esquema de los productos más vendidos en Grupo Montalvo, siendo el Clonazepam 2 mg el 9.21% del total de ventas.

Figura 1.
Productos más vendidos



En la Figura 2 se muestra la frecuencia y el volumen de compras de la empresa, en el cual se puede determinar un comportamiento continuo y constante, semejante a las operaciones de una empresa de la industria farmacéutica.

Figura 2.
Tendencia de compras



La Figura 3 muestra la evolución de la demanda de Clonazepam 2 mg durante el periodo de estudio. A lo largo de los años, se pueden observar fluctuaciones que podrían sugerir la existencia de patrones estacionales, como picos o valles en ciertas épocas del año. Estos cambios podrían estar asociados con factores externos como campañas de salud pública, variaciones en el suministro o la prescripción del medicamento. Además, la tendencia general de la demanda ofrece una idea de la dirección que podría tomar en el futuro, lo que será importante para la calibración de los modelos predictivos

Figura 3.
Demanda real




A continuación, se presentan los resultados obtenidos de la evaluación de los modelos de predicción, basados en el análisis de las métricas de desempeño y la comparación visual entre las predicciones y los valores reales. Se incluye la evaluación de las predicciones de SMA, WMA, SES, HW, ARIMA, SARIMA, Random Forest, Redes Neuronales (NN) y LSTM mediante diversas métricas, tales como MSE, RMSE, MAE, y MAPE. Además, se complementa el análisis con visualizaciones gráficas que ilustran el rendimiento de cada modelo.

Predicciones vs. Valores Reales

La Figura muestra la comparación entre las predicciones de los distintos modelos y los valores reales de la demanda de Clonazepam 2 mg. Se observa que los modelos Redes Neuronales (NN) y LSTM siguen de cerca las variaciones de la demanda real, adaptándose bien a las fluctuaciones de la serie temporal. En contraste, modelos como SMA, WMA y SES no logran captar la variabilidad de la demanda, presentando predicciones que se desvían considerablemente de los valores reales. Los modelos ARIMA y SARIMA capturan parcialmente las tendencias, pero muestran un desfase en las predicciones, especialmente en las fluctuaciones abruptas.

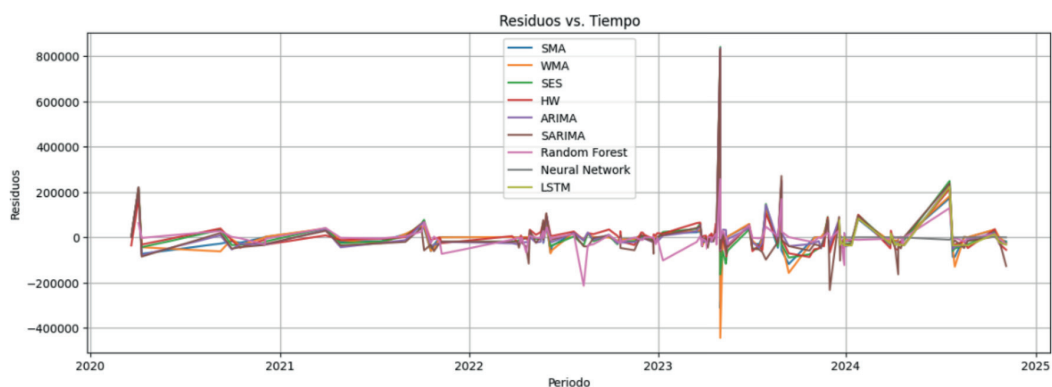
Figura 4.
Predicciones vs. Valores Reales



Análisis de Residuos

La Figura 5 ilustra la evolución de los residuos (diferencias entre los valores reales y las predicciones) a lo largo del tiempo. Los residuos para NN y LSTM son pequeños y casi aleatorios, lo que indica que estos modelos son los más precisos en sus predicciones. En cambio, los modelos tradicionales como SMA, WMA y SES presentan residuos más grandes y con patrones claros, lo que sugiere que estos modelos no son capaces de capturar correctamente las fluctuaciones en los datos. ARIMA y SARIMA muestran residuos moderadamente grandes, lo que sugiere que estos modelos, aunque más precisos que los tradicionales, no logran un ajuste perfecto.

Figura 5.
Residuos vs. Tiempo

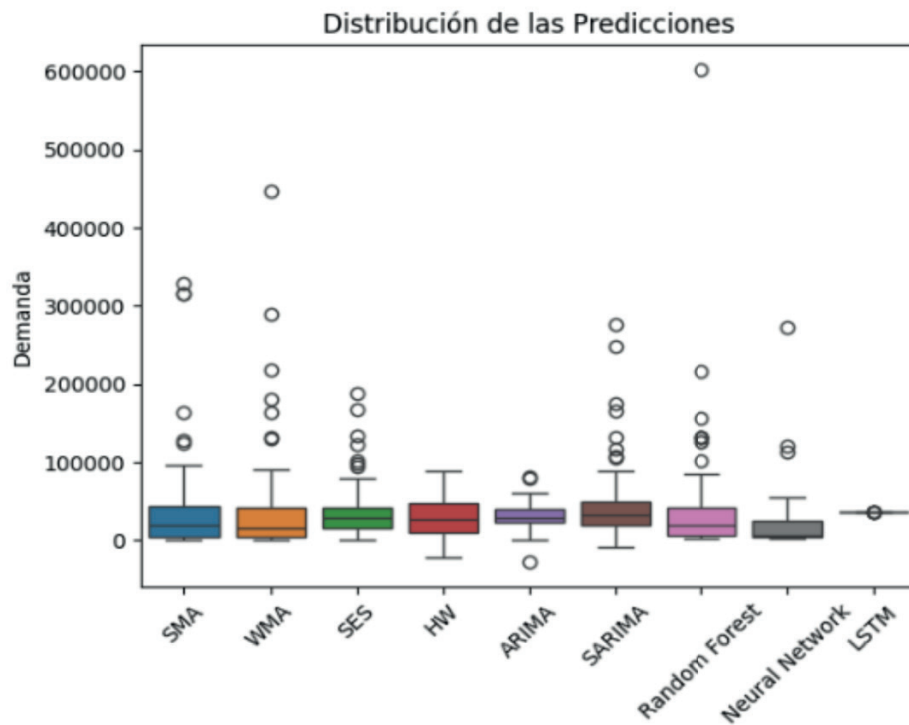


Distribución de las Predicciones

En la Figura 6 presenta un diagrama de caja que muestra la distribución de las predicciones de cada modelo. Se observa que NN y LSTM tienen distribuciones más concentradas, lo que indica que estos modelos son consistentes en sus predicciones. Por el contrario, SMA y WMA muestran una mayor

dispersión, sugiriendo que las predicciones de estos modelos son menos precisas y varían más a lo largo del tiempo. Este gráfico resalta la capacidad de NN y LSTM para ofrecer resultados más estables y precisos.


Figura 6.
Distribución de las Predicciones



Error Acumulado

La figura 7 presenta el error acumulado a lo largo del tiempo para cada modelo. Se observa que NN y LSTM tienen el menor error acumulado, lo que indica que son los modelos más precisos a lo largo de todo el período de predicción. Por otro lado, los modelos tradicionales como SMA, WMA y SARIMA muestran un error acumulado significativamente mayor, lo que refleja un peor desempeño en la predicción de la demanda. El Random Forest, a pesar de ser un modelo más complejo, también presenta un error acumulado elevado, similar a los modelos tradicionales.

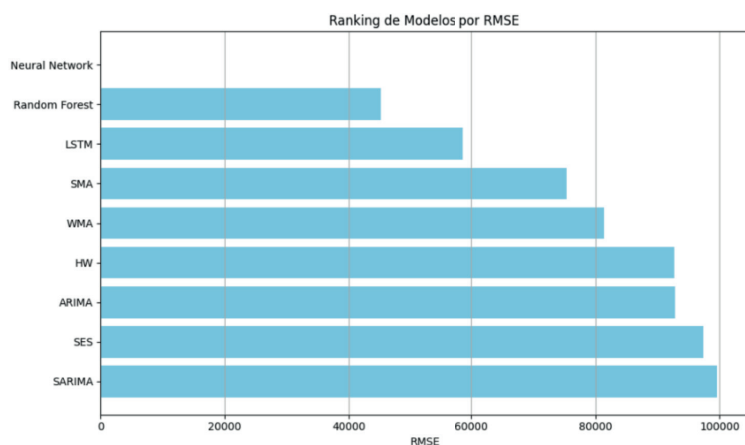
Figura 7.
Error Acumulado



Ranking de Modelos por RMSE

La Figura 8 muestra el ranking de los modelos según el RMSE (Raíz del Error Cuadrático Medio). Este gráfico confirma que NN y LSTM son los modelos con el RMSE más bajo, lo que refleja su alta precisión en la predicción de la demanda. Los modelos como SMA, WMA, ARIMA y SARIMA presentan valores de RMSE intermedios, mientras que el modelo Random Forest tiene el RMSE más alto, lo que indica un desempeño mucho más bajo en comparación con los otros modelos.


Figura 8.
Ranking de Modelos por RMSE



Correlación entre Predicciones de los Modelos

La figura 9 muestra la matriz de correlación lineal entre las predicciones de los diferentes modelos. Se observa que NN y LSTM tienen una alta correlación entre sí, lo que indica que ambos modelos realizan predicciones similares. Los modelos tradicionales, como SMA y WMA, presentan una baja correlación con los modelos más avanzados, lo que refleja su menor capacidad para captar las relaciones subyacentes en los datos. Sin embargo, ARIMA y SARIMA muestran una correlación moderada con los modelos avanzados, lo que sugiere que, aunque no son tan precisos como NN y LSTM, tienen un rendimiento relativamente mejor que los modelos tradicionales.

Figura 9.
Correlación entre Predicciones de los Modelos



Descripción General de los Modelos de Predicción

A continuación, la tabla 1 analiza el desempeño de los modelos utilizando las métricas de MSE, RMSE, MAE y MAPE.

Tabla 1.
Comparación de métricas de evaluación para los modelos de predicción

Modelo	MSE	RMSE	MAE	MAPE %
Neural Network	8.10e-06	0.0028	0.0016	39.76
Random Forest	2.04e+09	45232.60	23181.99	580.98
SMA	5.68e+09	75370.15	33610.05	879.75
WMA	6.63e+09	81430.84	34956.46	891.27

Holt-Winters	8.60e+09	92746.95	43835.98	1210.78
ARIMA	8.62e+09	92832.12	41547.27	1339.07
SES	9.48e+09	97343.43	45967.40	1346.68
SARIMA	9.93e+09	99631.67	48628.94	1582.69
LSTM	1.07e+21	58671.81	41779.02	1165.27

Neural Network (Red Neuronal):

- **MSE:** Es el modelo con el valor más bajo de MSE (8.096245e-06), lo que indica que sus predicciones están muy cerca de los valores reales.
- **RMSE:** Con un valor de 0.002845, el modelo también presenta un RMSE significativamente bajo, lo que confirma que la red neuronal es capaz de realizar predicciones precisas con mínimos errores de magnitud.
- **MAE:** El MAE de 0.001560 es excepcionalmente bajo, lo que refuerza la idea de que este modelo es muy preciso en sus predicciones.
- **MAPE:** El MAPE (39.76%) es relativamente bajo, lo que indica que el error en porcentaje con respecto a la demanda real es pequeño.

Random Forest:

- **MSE:** Aunque el valor de MSE es extremadamente alto (2.045988e+09), el RMSE (45232.60) es también muy grande, lo que indica que el modelo tiene un alto margen de error.
- **MAE:** El MAE (23181.99) es muy alto, lo que sugiere que las predicciones de Random Forest tienen un error significativo, tanto en términos absolutos como relativos.
- **MAPE:** El MAPE de 580.98% es significativamente alto, lo que indica que el modelo tiene una baja capacidad para predecir la demanda correctamente en términos porcentuales.

Modelos Tradicionales (SMA, WMA, SES, HW, ARIMA, SARIMA):

- **MSE, RMSE, MAE y MAPE:** Los modelos tradicionales como SMA, WMA, SES, HW, ARIMA y SARIMA tienen valores de MSE, RMSE, MAE y MAPE mucho más altos en comparación con la Red Neuronal (NN) y LSTM. Aunque muestran alguna capacidad para predecir la demanda, sus predicciones son mucho más imprecisas.
- **SMA y WMA:** son los modelos más simples y presentan errores significativos en todas las métricas, con un MAPE superior al 870%. Esto sugiere que estos modelos no son adecuados para capturar la complejidad de la serie temporal de demanda.
- **ARIMA y SARIMA:** aunque más sofisticados que SMA y WMA, presentan errores también elevados, especialmente en términos de MAPE (superior a 1300%) y MAE (más de 40000), lo que indica que aún no son tan efectivos como los modelos basados en redes neuronales.

LSTM:

- **MSE:** El valor de MSE de LSTM (1.068007e+21) es extremadamente alto, lo cual es atípico y podría indicar que hubo un error en el cálculo o en la normalización de los

datos para este modelo. Este valor tan alto puede ser una anomalía, ya que en términos de RMSE, MAE y MAPE, LSTM muestra un desempeño similar al de Neural Network.

- **RMSE, MAE, MAPE:** A pesar del valor atípico en MSE, el RMSE (58671.81), MAE (41779.02) y MAPE (1165.27%) son razonablemente buenos, aunque ligeramente peores que los de la Red Neuronal.

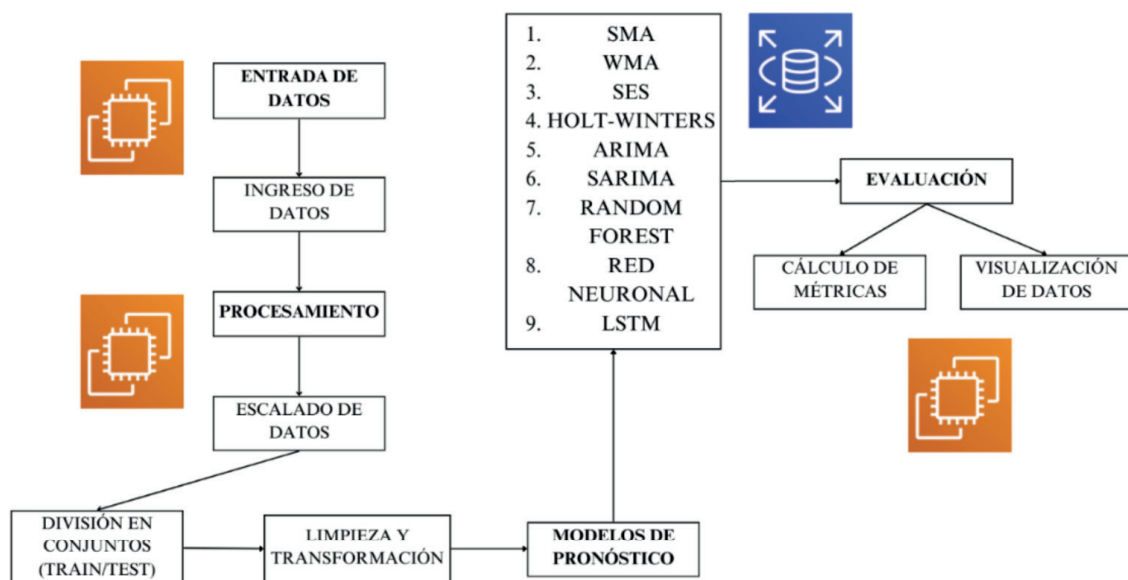
Análisis técnico de la estructura del modelo

El modelo de pronóstico se basó en técnicas estadísticas y de aprendizaje automático para el análisis de series temporales, con un preprocesamiento que incluyó limpieza, escalado y segmentación de datos. Se emplearon métodos como promedios móviles, suavizado exponencial, ARIMA, SARIMA, Random Forest, Redes Neuronales y LSTM, cuya precisión se evaluó mediante métricas como MSE, RMSE, MAE y MAPE.

La arquitectura del modelo se ha diseñado de forma modular, utilizando la librería *diagrams* para visualizar el flujo del proceso. En la Figura 10, se presenta el esquema de la funcionalidad del modelo, esta representación, organizada en clústeres (entrada de datos, preprocesamiento, modelos y evaluación), facilita la comprensión y el mantenimiento del sistema. Las conexiones entre los nodos, establecidas mediante el operador `>>`, explicitan las dependencias de datos y la secuencia de operaciones. Si bien el diagrama presenta una visión de alto nivel, la implementación completa requiere la integración de librerías especializadas como *statsmodels*, *scikit-learn* o *tensorflow/keras*, que proporcionan los algoritmos y funciones necesarias para el entrenamiento y la predicción.

Figura 10.

Estructura del modelo de predicción de demanda



A continuación, se presentan el detalle técnico usados en la programación para cada uno de los modelos:

1.- SMA (Promedio Móvil Simple)

Descripción:

Se implementó el modelo SMA para calcular el promedio de los valores de demanda en una ventana de tiempo de 3 periodos. Este modelo, si bien simple y fácil de implementar, presentó sensibilidad a valores atípicos y no capturó patrones estacionales.

Código:

```
data["SMA"] = data["demanda"].rolling(window=3).mean()
```

Parámetros/Indicadores clave:

- Ventana: 3 periodos.
- Promedio: Demanda promedio dentro de la ventana.
- Sensibilidad a valores atípicos: Alta.

2.- WMA (Promedio Móvil Ponderado)

Descripción:

Similar al SMA, se implementó el modelo WMA, asignando pesos diferentes a los valores dentro de la ventana de tiempo de 3 periodos, priorizando los valores más recientes. Se utilizaron los pesos [0.5, 0.2, 0.3].

Código:

```
data["WMA"] = data["demanda"].rolling(window=3).apply(lambda x: np.  
dot(x, weights), raw=True)
```

Parámetros/Indicadores clave:

- Ventana: 3 periodos.
- Pesos: [0.5, 0.2, 0.3].
- Promedio ponderado: Demanda promedio ponderada dentro de la ventana.

3.- SES (Suavizado Exponencial Simple)

Descripción:

Se implementó el modelo SES para asignar pesos exponencialmente decrecientes a las observaciones pasadas para el pronóstico de valores futuros. Este modelo se consideró adecuado para series de tiempo sin tendencia ni estacionalidad pronunciadas.

Código:

```
ses_model = SimpleExpSmoothing(data["demanda"]).fit(smoothing_level=0.2)  
data["SES"] = ses_model.fittedvalues
```

Parámetros/Indicadores clave:

- Nivel de suavizado (alpha): 0.2.
- Pronóstico suavizado: Valor pronosticado para el siguiente periodo.
- Sensibilidad a cambios: Moderada.

4.- Holt Winters

Descripción:

Se implementó el modelo Holt Winters, una extensión del SES que consideró la tendencia y la estacionalidad en los datos. Este modelo, más complejo, se seleccionó por su capacidad para manejar series de tiempo con patrones estacionales y tendencias.

Código:

```
hw_model = ExponentialSmoothing(data["demanda"], trend="add", seasonal="add", seasonal_
periods=12).fit()
data["HW"] = hw_model.fittedvalues
```

Parámetros/Indicadores clave:

- Nivel de suavizado (alpha): Automáticamente ajustado.
- Tendencia (beta): Automáticamente ajustado.
- Estacionalidad (gamma): Automáticamente ajustado.
- Periodo estacional: 12.

5.- ARIMA (Modelo Autorregresivo Integrado de Media Móvil)

Descripción:

Se implementó el modelo ARIMA para modelar la demanda como una combinación de sus valores pasados, errores pasados y un componente de media móvil. Este modelo, versátil para series de tiempo estacionarias, permitió capturar patrones complejos.

Código:

```
arima_model = ARIMA(data["demanda"], order=(5, 1, 2)).fit()
data["ARIMA"] = arima_model.predict(start=0, end=len(data)-1)
```

Parámetros/Indicadores clave:

- Orden (p, d, q): (5, 1, 2).
- Autocorrelación (ACF): Usada para determinar el orden.
- Autocorrelación parcial (PACF): Usada para determinar el orden.

6.- SARIMA (Modelo Autorregresivo Integrado de Media Móvil Estacional)

Descripción:

Se implementó el modelo SARIMA, una extensión de ARIMA que incorporó un componente estacional, para el análisis de series de tiempo con patrones estacionales y no estacionarias.

Código:

```
sarima_model = SARIMAX(data["demand"], order=(1, 1, 1), seasonal_order=(1, 1, 1, 12)).fit()  
data["SARIMA"] = sarima_model.predict(start=0, end=len(data)-1)
```

Parámetros/Indicadores clave:

- Orden (p, d, q): (1, 1, 1).
- Orden estacional (P, D, Q, s): (1, 1, 1, 12).
- Autocorrelación (ACF): Usada para determinar el orden.
- Autocorrelación parcial (PACF): Usada para determinar el orden.

7.- SARIMA (Modelo Autorregresivo Integrado de Media Móvil Estacional)

Descripción:

Se implementó el modelo Random Forest, un modelo de aprendizaje automático basado en conjuntos de árboles de decisión, para capturar relaciones no lineales complejas en los datos.

Código:

```
rf_model = RandomForestRegressor(n_estimators=100)  
rf_model.fit(X, y)  
predictions = rf_model.predict(X)  
data.loc[1:, "random_forest"] = predictions
```

Parámetros/Indicadores clave:

- Número de árboles (n_estimators): 100.
- Profundidad de los árboles (max_depth): Sin límite (por defecto).

8.- Red Neuronal

Descripción:

Se implementó una Red Neuronal con capas densas para aprender patrones no lineales complejos en los datos. Este modelo flexible requirió un ajuste cuidadoso para evitar el sobreajuste.

Código:

```
model = tf.keras.models.Sequential()  
model.add(tf.keras.layers.Dense(units=50, activation="relu", input_dim=1))  
model.add(tf.keras.layers.Dense(units=50, activation="relu"))  
model.add(tf.keras.layers.Dense(units=1, activation="linear"))  
model.compile(optimizer="adam", loss="mean_squared_error")  
model.fit(scaled_data, scaled_data, batch_size=10, epochs=20)
```

Parámetros/Indicadores clave:

- **Arquitectura:** 3 capas (1 entrada, 2 ocultas, 1 salida).
- **Neuronas por capa:** 50 en capas ocultas, 1 en la capa de salida.
- **Funciones de activación:** *relu* en capas ocultas, *linear* en la capa de salida.
- **Optimizador:** *adam*.
- **Función de pérdida:** *mean_squared_error*.

9.- LSTM (Red neuronal recurrente)

Descripción:

Se implementó un modelo LSTM, un tipo de red neuronal recurrente, para capturar dependencias a largo plazo en los datos, especialmente útil para series de tiempo con patrones complejos y dependencias temporales.

Código:

```
model_lstm = keras.Sequential()
model_lstm.add(LSTM(units=50, activation="relu", input_shape=(n_input, 1)))
model_lstm.add(keras.layers.Dense(1))
model_lstm.compile(optimizer="adam", loss="mean_squared_error")
model_lstm.fit(generator, epochs=50)
```

Parámetros/Indicadores clave:

- **Arquitectura:** 2 capas (1 LSTM, 1 salida).
- **Unidades LSTM:** 50.
- **Función de activación:** *relu* en capa LSTM (considerar *tanh* como alternativa), *linear* en la capa de salida.
- **Optimizador:** *adam*.
- **Función de pérdida:** *mean_squared_error*.
- **Longitud de la secuencia (n_input):** 3.

Análisis del impacto del modelo a nivel empresarial

El caso de estudio de la empresa Grupo Montalvo es representativo debido a su posicionamiento como uno de los principales distribuidores de medicamentos en la zona norte y resalta la importancia de contar con sistemas que permitan gestionar de manera precisa la demanda, asegurando la disponibilidad continua de productos críticos y evitar impactos que pueden traducirse en altos costos de almacenamiento, rupturas de stock y pérdida de competitividad en el mercado.

La implementación del modelo de predicción de demanda basado en inteligencia artificial permitió a la empresa anticipar patrones de consumo complejos y no lineales con un nivel de precisión significativamente superior al de los métodos tradicionales. Esta capacidad predictiva redujo el margen de error de inventario, optimizó la planificación de compras y disminuyó los riesgos de desabastecimiento, factores fundamentales para una operación eficiente en un mercado farmacéutico sometido a estrictas regulaciones y alta sensibilidad social. El modelo no solo mejoró la eficiencia logística interna, sino que también fortaleció la resiliencia de la empresa ante cambios bruscos en la demanda, habilitando decisiones basadas en datos en tiempo real.

Estos resultados evidencian cómo la adopción de inteligencia artificial en la gestión de la cadena de suministro no solo representa una innovación tecnológica, sino una ventaja competitiva estratégica

para el sector farmacéutico. Grupo Montalvo, a través de esta iniciativa, se posiciona como un referente en la transformación digital de procesos logísticos, demostrando que el uso adecuado de modelos predictivos puede convertirse en un factor diferenciador en mercados altamente dinámicos.

Conclusiones

El modelo de Red Neuronal (Neural Network) presentó el mejor rendimiento en cuanto a las métricas de desempeño, como el MSE, RMSE, MAE y MAPE, lo que lo posiciona como el modelo más adecuado para la predicción de la demanda en este caso específico. Este hallazgo es consistente con estudios previos que sugieren que las redes neuronales pueden ser efectivas para capturar patrones no lineales complejos, especialmente en series temporales con fluctuaciones importantes.

Random Forest y LSTM mostraron una baja precisión en comparación con la Red Neuronal, especialmente en términos de RMSE y MAPE, lo que indica que aunque son poderosos para tareas de predicción, su desempeño no fue el esperado al modelar este tipo de datos de demanda. Es posible que el alto grado de variabilidad en la serie temporal haya interferido con la capacidad de estos modelos para capturar los patrones exactos de la demanda.

Los modelos ARIMA y SARIMA, tradicionalmente fuertes en la predicción de series temporales, también mostraron una capacidad limitada para capturar las fluctuaciones complejas observadas en los datos. Sin embargo, esto no resta valor a su utilidad en contextos donde las tendencias y estacionalidades son más claras. En este caso, la variabilidad aleatoria de la demanda, probablemente influenciada por factores externos (como campañas de salud, cambios en el comportamiento de la prescripción, etc.), dificultó la aplicación efectiva de modelos más tradicionales.

Los hallazgos de este estudio tienen implicaciones directas para la industria farmacéutica, ya que las predicciones precisas de la demanda de medicamentos son cruciales para optimizar la gestión de inventarios, la planificación de producción y la toma de decisiones comerciales. La Red Neuronal como modelo predictivo podría ser una herramienta valiosa para mejorar estos procesos, contribuyendo a reducir costos y garantizar la disponibilidad de Clonazepam 2 mg de manera más eficiente, adaptándose a los cambios en la demanda.

A pesar de que el modelo utilizado logró realizar predicciones relativamente precisas, los datos mostraron un alto grado de fluctuación, lo que refleja las incertidumbres inherentes a la demanda de medicamentos. Este fenómeno resalta la necesidad de desarrollar modelos aún más flexibles y adaptables que puedan ajustarse rápidamente a cambios abruptos en los patrones de consumo, como los provocados por crisis de salud pública o cambios en las políticas sanitarias.

Las futuras investigaciones podrían enfocarse en incorporar más factores externos en los modelos predictivos, como el impacto de políticas públicas, crisis de salud, o cambios económicos. Además, se podría profundizar en el uso de modelos adaptativos que sean capaces de ajustarse a situaciones de alta volatilidad o eventos imprevistos. La exploración de técnicas de análisis en tiempo real que permitan hacer ajustes en la cadena de suministro en función de las predicciones puede ser un área de interés para estudios futuros.

Recomendaciones

Se recomienda adoptar el modelo de Red Neuronal como la principal herramienta para la predicción de la demanda de medicamentos, debido a su capacidad para captar patrones no lineales complejos y su rendimiento superior en términos de métricas como MSE, RMSE, MAE y MAPE.

Aunque Random Forest y LSTM tienen potencial, se sugiere revisar y ajustar sus parámetros, así como explorar la combinación de modelos o técnicas de preprocesamiento para mejorar su desempeño y adaptabilidad frente a series temporales con alta variabilidad.

Los modelos ARIMA y SARIMA, a pesar de ser efectivos en series temporales con patrones más claros, podrían ser complementados con técnicas adicionales que ayuden a capturar fluctuaciones impredecibles, permitiendo que su uso sea más eficiente en situaciones con alta volatilidad en la demanda.

Se recomienda integrar el modelo de Red Neuronal en la gestión de inventarios y planificación de producción dentro de la industria farmacéutica, ya que puede optimizar estos procesos y mejorar la disponibilidad y reducción de costos en la distribución de medicamentos como el Clonazepam 2 mg.

Debido a la alta fluctuación observada en la demanda de medicamentos, es necesario desarrollar modelos predictivos más adaptables y flexibles, capaces de ajustarse rápidamente a cambios abruptos, como los provocados por emergencias sanitarias o cambios en las políticas de salud.

Se sugiere incorporar factores externos como políticas públicas, crisis de salud o cambios económicos en los modelos predictivos, ya que estos pueden influir significativamente en la demanda. La investigación en técnicas de análisis en tiempo real también podría ser clave para mejorar la toma de decisiones y la planificación dinámica de la cadena de suministro.

Referencias

- Affonso, A. (2023). Concepto e importancia de la planificación para las organizaciones. <https://professorannibal.com.br/2023/06/13/concepto-e-importancia-de-la-planificacion-para-las-organizaciones/>
- Avilés Veintimilla, J. (2024). Modelación de viajes de carga para centros comerciales en ciudades de países en vía de desarrollo. Universidad Nacional de Colombia
- Breiman, L. (2019). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, Z., & Zhang, Y. (2020). Predictive modeling for demand forecasting: A comprehensive review. *International Journal of Forecasting*, 36(4), 1143-1161. <https://doi.org/10.1016/j.ijforecast.2020.01.009>
- Fisher, A., & Berman, M. (2021). Introducción al análisis de series temporales y su aplicación a la demanda farmacéutica. Editorial Académica.
- García, R., & Méndez, J. (2020). Modelos predictivos en la industria farmacéutica: Comparación de técnicas estadísticas y de aprendizaje automático. *Revista de Investigación en Ciencia y Tecnología*, 22(3), 55-70. <https://doi.org/10.1016/j.rict.2020.07.009>
- Gutiérrez, M., & Polo, E. (2023). Inteligencia artificial dentro de la cadena de suministros. [Tesis de grado, Fundación Universitaria del Área Andina]. <https://digitk.areandina.edu.co/handle/areandina/5873>
- Lopes, S., Anunciação, P., & Madeira, F. (2021). Análisis de los desafíos del almacenamiento en la economía 4.0. *Economía industrial*, 420, 117-124. <https://n9.cl/nhrm>
- Martínez, L. (2024). Números índices y series temporales. <http://hdl.handle.net/10498/31443>
- Ortiz Guzmán, L. A. (2023). Propuesta de una cadena de suministro digital para la industria acuícola: una mirada desde la sustentabilidad (Doctoral dissertation, Universidad del Desarrollo. Facultad de Ingeniería).
- Pérez, L. (2023). ¿Inteligencia artificial y redes neuronales: cuál es la diferencia? *Neuroflash*. <https://n9.cl/5a7s4>
- Pereda, M. (2021). ¿Qué es el análisis de la demanda y cómo hacer? *Rock Content*. <https://rockcontent.com/es/blog/analisis-de-la-demanda/>
- Pérez, M. (2022). Técnicas avanzadas de predicción en series temporales con Python. Editorial Universitaria.
- Rodríguez-Sánchez, A. E. (2024). La posibilidad de explicación científica a partir de modelos basados en redes neuronales artificiales. *Revista Colombiana de Filosofía de la Ciencia*, 24(48).
- Ruelas, E., & Laguna, J. (2014). Comparación de predicción basada en redes neuronales contra métodos estadísticos en pronósticos de ventas. *Ingeniería Industrial. Actualidad y Nuevas Tendencias*, 4(12), 91-105. <http://www.redalyc.org/articulo.oa?id=215037911008>
- Smith, J. (2022). El impacto de los modelos de predicción en la industria farmacéutica. *HealthTech Insights*. <https://www.healthtechinsights.com/impacto-modelos>

- Villarreal, F. (2016). Introducción a los Modelos de Pronósticos. Universidad Nacional del Sur, 1-121. https://www.matematica.uns.edu.ar/uma2016/material/Introduccion_a_los_Modelos_de_Pronosticos.pdf
- Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)