

# Sistema predictivo para la planificación de la demanda utilizando machine learning en Librerías - Bazar M & M de Lima Metropolitana

José Corrales-Jhong  
*Ingeniería de Sistemas de Información*  
Universidad Peruana de Ciencias  
Aplicadas (UPC)  
Lima, Perú  
u201913297@upc.edu.pe

Miguel Aldave-Paredes  
*Ingeniería de Sistemas de Información*  
Universidad Peruana de Ciencias  
Aplicadas (UPC)  
Lima, Perú  
u201618429@upc.edu.pe

Esther Aliaga-Cerna  
*Ingeniería de Sistemas de Información*  
Universidad Peruana de Ciencias  
Aplicadas (UPC)  
Lima, Perú  
pcsieali@upc.edu.pe @upc.edu.pe

**Abstract**— Este trabajo de investigación tiene como objetivo desarrollar un sistema predictivo para la planificación de la demanda de libros, útiles escolares y artículos de oficina utilizando técnicas de machine learning en Librerías-Bazar M & M de Lima Metropolitana. Actualmente, la empresa enfrenta dificultades para prever con precisión su demanda, generando una gestión ineficiente de inventarios, acumulación de stock innecesario y pérdidas de ventas por quiebres de stock. Se evaluaron diversos modelos predictivos, siendo el modelo de redes neuronales LSTM el de mejor rendimiento, alcanzando una precisión del 95%. La implementación del sistema permitió reducir el exceso de stock en un 15% y optimizar el proceso de reposición de productos. Los resultados evidencian que la adopción de machine learning mejora significativamente la toma de decisiones en la gestión de inventarios, con posibilidad de replicarse en otros comercios minoristas.

**Keywords**— *demanda, planificación de demanda, machine learning, predicción de ventas*

## I. INTRODUCCIÓN

La planificación inexacta de la demanda representa un problema significativo en la gestión de la cadena de suministro, especialmente cuando las organizaciones no emplean predicciones basadas en datos. Por ende, la carencia de predicciones adecuadas en la planificación de la demanda es uno de los principales factores que contribuyen a la ineficiencia en las cadenas de suministro modernas, la necesidad de adoptar enfoques más avanzados y tecnológicos en este ámbito [1].

En la industria editorial existe la preocupación del avance de dispositivos y software para libros electrónicos represente una amenaza para la publicación de libros tradicionales[2]. Sin embargo, el mercado de las revistas, más enfocado en la actualidad que en la profundidad informativa, ha sido reemplazado en gran medida por los libros electrónicos. A pesar de esto, la demanda de libros impresos no ha disminuido en géneros como la literatura, los libros prácticos, los libros de referencia para el estudio y otros textos literarios [3].

Si estas compañías pueden aprovechar esta tecnología a su favor, cualquier organización en el mundo también puede hacerlo. Estos desarrollos se han creado de manera abierta o como software de código abierto, lo que brinda acceso gratuito a todos para diseñar, desarrollar, modificar o adaptar los métodos de pronóstico existentes según sus necesidades [4]. Esto les permitirá integrarse en el comienzo de la era digital aplicada a las industrias, mejorar su competitividad y participar activamente en el mercado global.

Mientras métodos tradicionales (suavización exponencial, promedio móvil) mantienen errores del 12% MAPE en contextos estables, las redes neuronales reducen este error al 5% en entornos dinámicos como el analizado, según los resultados presentados. Esto se debe a que las tendencias pueden cambiar de manera abrupta y los patrones históricos no siempre se replican con precisión[5]. Es decir, este enfoque obsoleto carece de la capacidad para ajustarse de manera precisa y oportuna a las variaciones en la demanda, lo que resalta la necesidad urgente de adoptar herramientas que permitan una previsión más informada y basada en datos [6]. La falta de previsión precisa puede llevar a una serie de consecuencias negativas, como la acumulación excesiva de inventario o, en el otro extremo, la escasez de productos, ambos escenarios que impactan negativamente en la eficiencia operativa y la satisfacción del cliente [7].

El objetivo de este estudio busca desarrollar una revisión sistemática para desarrollar un sistema predictivo basado en aprendizaje automático, con el fin de optimizar la planificación de la demanda en librerías. Este sistema busca mejorar la precisión en la estimación de la demanda futura, lo cual es crucial en un entorno caracterizado por una demanda de productos que puede ser altamente variable y dependiente de factores estacionales. En este contexto, se presentan picos de demanda elevados seguidos de periodos de baja actividad, lo que hace esencial una planificación precisa. Al implementar un modelo basado en machine learning basado en técnicas de redes neuronales, buscamos superar las limitaciones de los métodos tradicionales de planificación, que a menudo se basan en datos históricos sin considerar la complejidad y la dinámica actual del mercado.

Solucionar la planificación inexacta de la demanda en una librería-bazar es difícil debido a la amplia variedad de productos y la estacionalidad que caracteriza las ventas de este tipo de negocio. La demanda de útiles escolares y de oficina puede fluctuar considerablemente según la época del año, como la temporada escolar, las promociones especiales, o incluso eventos externos imprevistos [4]. Además, el comportamiento del consumidor es influenciado por múltiples factores, incluyendo cambios en las preferencias de los productos y la introducción de nuevos artículos en el mercado. Los bazares enfrentan el desafío de manejar una gran diversidad de productos con ciclos de vida diferentes, lo que complica la tarea de prever la demanda con precisión [5]. Dichos factores hacen que desarrollar un sistema predictivo eficiente sea complejo, ya que requiere un modelo capaz de analizar múltiples variables y adaptarse a un entorno comercial dinámico.

Este problema es muy común en medianas o pequeñas empresas, donde no tienen un gran poder de inversión para aplicar sistemas de predicción con un alto costo, por ello utilizan métodos tradicionales de pronósticos que no han logrado capturar la complejidad de la demanda en este tipo de negocio. Los enfoques previos han utilizado principalmente modelos estadísticos básicos, como el promedio móvil y la suavización exponencial, o se han basado en la experiencia y juicio de los gerentes, lo cual es insuficiente para manejar la variabilidad y estacionalidad de la demanda de productos [6].

Estos métodos, se basan en patrones históricos simples y no consideran factores emergentes como campañas de marketing digital o modificaciones en las políticas educativas, han demostrado ser insuficientes para ofrecer previsiones precisas y adaptativas. Los sistemas tradicionales carecen de la capacidad para integrar datos en tiempo real y aprender de ellos, lo que genera predicciones inexactas y una planificación ineficaz del inventario [6]. Las soluciones tradicionales, como los modelos de regresión lineal o los métodos de pronóstico basados en tendencias históricas, han mostrado ser inadecuadas para captar las fluctuaciones complejas del mercado moderno, pues no están diseñados para adaptarse rápidamente a nuevas condiciones del mercado o a cambios en el comportamiento del consumidor, lo que limita su eficacia [8].

Por ende, en esta revisión sistemática de la literatura se plantearon las siguientes preguntas de investigación: P1: ¿Qué técnicas se emplean para mejorar la precisión en la predicción de la demanda mediante el uso de aprendizaje automático en la cadena de suministro?; P2: ¿Qué sistemas o algoritmos se utilizan para la predicción en la gestión de inventarios a través del aprendizaje automático?; P3: ¿En qué otras aplicaciones se implementan técnicas de aprendizaje automático adaptadas a la gestión y tratamiento de datos?; P4: ¿Qué herramientas adicionales pueden contribuir a la mejora en la previsión de la demanda basada en aprendizaje profundo?

Este estudio se centra en llevar a cabo un análisis minucioso de investigaciones previas sobre el desarrollo de un sistema predictivo destinado a optimizar la planificación de la demanda en librerías, un área que actualmente presenta carencias significativas. La investigación se estructura en cinco secciones principales: la Sección I ofrece la introducción; la Sección II explora los trabajos relacionados con la temática; la Sección III presenta los resultados obtenidos, respaldados por tablas y figuras; la Sección IV examina la experimentación de los hallazgos; y, por último, la Sección V proporciona las conclusiones y recomendaciones derivadas del estudio.

Las investigaciones actuales sobre el análisis de pronósticos se enfocan principalmente en el estudio de los ingresos por ventas y las estrategias de marketing, con un énfasis particular en las librerías en línea.

Ramos, Vivas y Rubio [7] estudiaron un sistema predictivo para estimar la demanda de carga de vehículos eléctricos, propusieron un simulador para una micro-red inteligente que integra energías renovables y almacenamiento energético, con el objetivo de gestionar la demanda de carga de vehículos eléctricos y optimizar la planificación energética utilizando técnicas de aprendizaje automático. Se evaluaron diversos modelos de redes neuronales, entrenados con datos de demanda de vehículos y producción fotovoltaica. Los resultados mostraron que el modelo LSTM con una ventana temporal de 4 días fue el más preciso para la predicción de demanda, mientras que la combinación CNN + LSTM con una ventana de 1 día fue la más efectiva para la predicción de producción fotovoltaica. Modelos simples funcionan mejor con secuencias cortas, mientras que los modelos complejos se desempeñan mejor con ventanas temporales más largas.

El estudio de Lukinskiy [8] abordó la gestión de inventarios para productos con baja demanda, identificando una brecha significativa en la investigación existente. Se emplearon productos del comercio minorista y de servicios, como repuestos y componentes de maquinaria, para analizar la insuficiencia de métodos tradicionales de previsión, como el análisis ABC y XYZ. El estudio exploró casos especiales y presentó clasificaciones unidimensionales y bidimensionales de existencias, además de evaluar las limitaciones del modelo de Cantidad Económica de Pedido (EOQ). Se propusieron estrategias alternativas y modelos integrados de previsión basados en series temporales, utilizando toda la información disponible para tomar decisiones bajo incertidumbre. Los resultados confirmaron la efectividad de estos modelos en la mejora de la precisión en la gestión de inventarios y en la reducción de costos en las cadenas de suministro.

Este estudio [9] se enfocó en mejorar la precisión de la previsión de demanda de libros para una editorial, utilizando datos históricos de ventas junto con información obtenida de portales web y redes sociales (SNS). Se desarrollaron hipótesis sobre los factores que influyen en la venta y devolución de libros, y se recopiló las variables necesarias para validar estas hipótesis. A través de este análisis, se identificaron los factores determinantes en las devoluciones y ventas, lo que permitió crear un modelo predictivo de pedidos de venta. No obstante, debido a la disponibilidad limitada de datos, el estudio se centró en un número reducido de libros. Se anticipa que la implementación del método propuesto por la empresa mejorará la precisión de las predicciones y tendrá aplicaciones en otros procesos comerciales dentro del sector editorial.

El estudio de Ramirez [36] tuvo como objetivo desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar de manera precisa el consumo de agua potable. El método o tipo de investigación se aplicó porque se desarrolló una herramienta para que las empresas

de saneamiento puedan usar para mejorar la gestión del suministro de agua potable. Los resultados indicaron que las variables de entrada o predictoras eran la temperatura máxima y mínima.

Liendo [37] En esta investigación se presenta cómo la empresa Inversiones Ferretera Mendoza SAC adoptó un sistema predictivo con aprendizaje automático para gestionar el inventario. Esto se debe a que el área de almacén de la

empresa maneja manualmente sus productos y ventas, lo que resulta en diferencias en la cantidad física y lógica de artículos. Como resultado, la empresa no puede mantener el control de inventario y los gastos dentro del área de almacén. El objetivo de esta investigación fue definir el propósito de un sistema predictivo con aprendizaje automático para la gestión de inventario en el manejo de entradas y salidas de productos en Inversiones Mendoza S.A.C.

### III. CONTRIBUCIÓN PRINCIPAL

#### A. *Conceptos preliminares*

En esta sección se exponen los conceptos claves utilizados en nuestro estudio. El objetivo principal es desarrollar un sistema predictivo basado en aprendizaje automático, con el propósito de optimizar la planificación de la demanda en librerías. Además, tiene como propósito identificar deficiencias en la investigación existente para proponer nuevas áreas de desarrollo para futuros proyectos de investigación, Kitchenham y Charters [10].

Machine learning ([11]): Los algoritmos de aprendizaje automático (ML) permiten realizar predicciones de manera más eficiente y precisa, ofreciendo respuestas confiables[12]. El aprendizaje automático se presenta como una herramienta innovadora con un gran potencial para mejorar los modelos de previsión de la demanda en la gestión de la cadena de suministro, superando los métodos actualmente empleados [13]. Este campo, que es una rama de la inteligencia artificial, permite que los algoritmos de aprendizaje automático ejecuten tareas sin una programación explícita. La máquina tiene la capacidad de aprender de los datos históricos no procesados para desarrollar modelos predictivos utilizando algoritmos preestablecidos [14].

Sistema predictivo: Es una herramienta con modelos de aprendizaje automático para analizar grandes volúmenes de datos históricos con el objetivo de hacer pronósticos sobre eventos futuros. En el contexto de la predicción de pedidos pendientes, se clasifica la probabilidad y calibra modelos para mejorar la precisión de sus predicciones, e interpreta las características más influyentes mediante técnicas [15].

En opinión del investigador [16], el enfoque adoptado en el estudio representa un avance significativo en la predicción de pedidos pendientes dentro de la cadena de suministro. La aplicación de técnicas avanzadas de inteligencia artificial para manejar datos desbalanceados demuestra un compromiso con la optimización precisa y eficaz de los niveles de inventario. La integración de modelos de aprendizaje automático variados, junto con el uso de métodos sofisticados como los bosques aleatorios distribuidos y el Deep Autoencoder, subraya la seriedad con la que se aborda el problema [17].

Demanda: La previsión de la demanda es crucial para las empresas, ya que permite anticipar la demanda futura y tomar decisiones informadas. [18].

En la gestión de la demanda futura, el enfoque se centrará en la previsión y planificación de la demanda, la gestión de datos y las estrategias de marketing. La previsión y

planificación de la demanda implican anticipar las cantidades y los momentos en que se producirán las solicitudes de los clientes[19].

Previsión: Las más precisas no siempre se logran utilizando datos en su nivel de agregación "natural". En ocasiones, la exactitud de las previsiones puede mejorarse al agregar datos o previsiones de niveles inferiores, desagregar datos o previsiones de niveles superiores, o al combinar previsiones de distintos niveles de agregación [20].

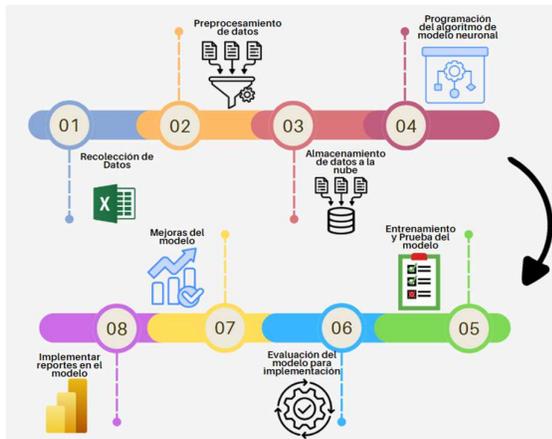
Pronósticos: Es una herramienta fundamental en el proceso de toma de decisiones y constituye un componente crucial para el éxito de cualquier sistema [21].

Pronósticos cualitativos: Como discrecionales, estos enfoques se basan en la observación de las tendencias actuales, los cambios en dichas tendencias y la magnitud de los cambios futuros. Sin embargo, presentan ciertas deficiencias. Su principal ventaja radica en la capacidad de identificar cambios sistemáticos con mayor rapidez y de interpretar con mayor precisión el impacto de dichos cambios en el futuro [22].

Pronósticos cuantitativos: Se enfocan en proyectar los datos históricos hacia el futuro de manera metodológica y objetiva, buscando ofrecer pronósticos más precisos que los obtenidos mediante enfoques cualitativos [22]. Estas técnicas se basan en la premisa de que las tendencias pasadas pueden extenderse de manera significativa para generar pronósticos precisos. Generalmente, las técnicas cuantitativas se dividen en dos categorías: estadísticas y determinísticas o causales.

#### B. *Metodo*

Como propuesta de solución se presenta de forma visual e interactiva un sistema conceptual en base a Machine Learning para mejorar la planificación de la demanda, donde podrá reducirse la pérdida de clientes, lo cual se traduce en aumentar los ingresos y reputación en la empresa. Además, se tendrá una gestión de inventario más eficiente para una búsqueda de productos adecuada y estructurada; por última se podrá conocer de forma más precisa la demanda por cada temporada, determinando los picos de crecimiento en los meses donde exista mayor demanda; y los meses donde la demanda disminuya totalmente, con la finalidad de reducir inventario innecesario, ya que genera un costo de inventario y, a la vez, estar abastecidos en la demanda total sin que exista una probabilidad de un cliente insatisfecho por falta de producto en la librería.



### Recolección de Datos

En la recolección de datos se identificará la fuente de datos, como registros de ventas históricas, niveles de inventario, datos del producto, factores externos (clima, eventos locales) y datos demográficos. Este proceso conlleva recopilar datos Internos, es decir, Obtener datos de ventas y niveles de inventario directamente de los sistemas de gestión de la librería y datos externos utilizando bases de datos públicas y otros recursos para recolectar datos externos como el clima y eventos. Por último, se realizará la consolidación de datos donde se integrarán todos los datos en un formato uniforme, asegurando que estén alineados temporal y categóricamente. Los factores externos (clima, eventos locales) se integraron mediante APIs en tiempo real. Por ejemplo, los datos meteorológicos se obtuvieron del servicio WeatherAPI con actualizaciones horarias, mientras que los eventos escolares se extrajeron de calendarios públicos municipales. Estas variables mostraron una correlación de Pearson  $>0.7$  con las ventas durante validación

### Preprocesamiento de Datos

En la etapa de preprocesamiento de datos, se llevan a cabo varias tareas cruciales para asegurar que los datos sean de alta calidad y adecuados para el análisis. Primero, se realiza la limpieza de datos, eliminando duplicados, corrigiendo errores y tratando valores nulos o faltantes para garantizar la integridad de los datos. Luego, se procede con la transformación de datos, normalizando y escalando las variables para asegurar que todas estén en un rango comparable y evitar sesgos en el sistema. A continuación, se lleva a cabo la ingeniería de características, donde se crean nuevas variables que puedan mejorar el rendimiento del sistema, como índices de estacionalidad, tendencias de ventas o características derivadas de las existentes. Finalmente, se realiza la división temporal de los datos, separándolos en conjuntos de entrenamiento, validación y prueba, asegurando que la secuencia temporal se mantenga, con datos antiguos utilizados para el entrenamiento y datos recientes para la validación y prueba. Este proceso integral prepara un conjunto de datos robusto y adecuado para el modelado predictivo. Se identificó y corrigió valores faltantes en menos del 5% de los registros mediante interpolación lineal para variables numéricas.

### Almacenamiento de Datos en la Nube

En la etapa de almacenamiento de datos en la nube, se comienza seleccionando una plataforma en la nube adecuada que ofrezca almacenamiento escalable y seguro, asegurando que pueda manejar el volumen y la sensibilidad de los datos. Luego, se lleva a cabo la migración de datos, subiendo los datos preprocesados a la plataforma seleccionada y asegurando que estén correctamente estructurados y organizados. Posteriormente, se configura el acceso a los datos, estableciendo permisos y controles para garantizar que solo los usuarios autorizados puedan acceder y manipular la información, protegiendo así la integridad y la privacidad de los datos. Finalmente, se implementan scripts o herramientas ETL (Extract, Transform, Load) para automatizar la actualización y carga de datos en la nube, facilitando un flujo de datos continuo y eficiente, y asegurando que el sistema siempre trabaje con la información más reciente.

### Programación del Algoritmo del Sistema Neuronal

En la etapa de programación del algoritmo del sistema neuronal, se comienza definiendo la arquitectura del sistema, determinando la estructura de la red neuronal, incluyendo el número de capas, las neuronas por capa y las funciones de activación adecuadas para la tarea. A continuación, se asegura que los datos estén en el formato adecuado para el entrenamiento, realizando cualquier transformación necesaria para que sean compatibles con el sistema neuronal. Luego, se implementa el algoritmo del sistema programándolo con un lenguaje de programación adecuado y utilizando frameworks de machine learning especializados. Finalmente, se configuran los parámetros iniciales del sistema, estableciendo la tasa de aprendizaje, los optimizadores y las funciones de pérdida que guiarán el proceso de entrenamiento del sistema, asegurando así una base sólida para su rendimiento y precisión. Se tendrá en cuenta 4 módulos para el sistema que compondrá de lo siguiente:

#### 1) Módulo de Adquisición y Preprocesamiento de Datos

El módulo de adquisición y preprocesamiento de datos se encarga de la subir los datos necesarios para entrenar los sistemas predictivos. Este módulo es fundamental, ya que la calidad y relevancia de los datos influyen directamente en la precisión del sistema de machine learning, este proceso se debe realizar tras recolectar la data. En este módulo, se integran datos de ventas internos, inventarios y datos externos relevantes, como tendencias del mercado, factores económicos y estacionales. Posteriormente, se realiza la limpieza de los datos en la nube central para eliminar valores nulos, duplicados y corregir errores. La transformación de los datos incluye la normalización, escalado y codificación de variables categóricas. Adicionalmente, se enriquece la base de datos agregando nuevas características derivadas de los datos existentes para mejorar las predicciones.

#### 2) Módulo de Entrenamiento y Optimización del Sistema

El módulo de entrenamiento y optimización del sistema se enfoca en la construcción, entrenamiento y ajuste de los sistemas de redes neuronales que se utilizan para predecir la demanda de productos. En este módulo, se define la

arquitectura de la red neuronal, determinando el número de capas, neuronas por capa y funciones de activación. El sistema se entrena utilizando datos históricos, ajustando sus parámetros mediante algoritmos de optimización. Para asegurar que el sistema tiene una buena capacidad de generalización, se emplean técnicas de validación cruzada. Además, se lleva a cabo la optimización del sistema ajustando hiperparámetros y utilizando técnicas como la regularización y el ajuste de tasas de aprendizaje para mejorar su rendimiento.

#### Módulo de Predicción y Actualización en Tiempo Real

El módulo de predicción y actualización en tiempo real es responsable de la generación continua de predicciones de demanda y la actualización del sistema con nuevos datos. Este módulo utiliza el sistema entrenado para predecir la demanda futura de productos a diferentes horizontes temporales, como diario, semanal y mensual. También se encarga de reentrenar el sistema periódicamente incorporando nuevos datos de ventas y otros factores relevantes. Además, emite alertas automáticas cuando se detectan desviaciones significativas entre las predicciones y los datos reales, y presenta las predicciones en paneles intuitivos y visualizaciones claras para facilitar la toma de decisiones.

#### Módulo de Integración y Automatización

El módulo de integración y automatización se ocupa de la integración del sistema predictivo con otros sistemas de la empresa y la automatización de procesos para una gestión eficiente del inventario. Este módulo sincroniza los datos entre el sistema predictivo y los sistemas de gestión empresarial existentes, como ERP y CRM. Además, genera órdenes de compra automáticamente basadas en las predicciones de demanda y los niveles de inventario actuales, mejorando la eficiencia operativa. Este módulo también supervisa continuamente el rendimiento del sistema y la infraestructura para asegurar su funcionamiento sin interrupciones. Adicionalmente, implementa medidas de seguridad para proteger los datos y asegurar el cumplimiento de regulaciones y políticas de privacidad.

#### Entrenamiento y Prueba del Sistema

En la etapa de entrenamiento y prueba del sistema, se inicia utilizando los datos de entrenamiento para ajustar los pesos del sistema, minimizando la función de pérdida a través de múltiples iteraciones. Durante este proceso, se evalúa el sistema con un conjunto de validación para ajustar los parámetros y evitar el sobreajuste, asegurando que el sistema generalice bien a datos nuevos. Una vez completado el entrenamiento, se prueba el sistema con un conjunto de datos no vistos para evaluar su rendimiento y precisión en situaciones reales. Basado en los resultados obtenidos durante la validación y prueba, se realizan ajustes y optimizaciones al sistema, repitiendo el proceso de entrenamiento si es necesario, para mejorar su eficacia y robustez antes de su implementación final.

#### Evaluación del Sistema para Implementación

En la etapa de evaluación del sistema para implementación, se comienzan calculando métricas de

evaluación como el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE) para medir la precisión del sistema. Posteriormente, se compara el rendimiento del sistema neuronal con otros sistemas de machine learning para asegurar que se está utilizando el enfoque más eficiente. Además, se realiza la validación cruzada para verificar la estabilidad y la capacidad de generalización del sistema a diferentes subconjuntos de datos. Finalmente, se selecciona el sistema que ofrece el mejor rendimiento global y que está listo para ser implementado, asegurando su efectividad y fiabilidad en el entorno de producción.

Modelo	MAPE (%)	RMSE	Tiempo entrenamiento (h)
<b>LSTM (propuesto)</b>	5	80	4.2
<b>Random Forest</b>	8	110	1.5
<b>SARIMA</b>	12	150	0.3

Tabla 1: Evaluación del sistema

#### Mejoras del Sistema

En la fase de mejora del sistema, se lleva a cabo un análisis exhaustivo de los resultados obtenidos durante la evaluación para identificar áreas potenciales de mejora en el desempeño del sistema. Luego, se procede a realizar el ajuste de hiperparámetros, explorando diversas configuraciones para optimizar el rendimiento del sistema. Simultáneamente, se lleva a cabo la ingeniería de características avanzada, donde se crean nuevas características o se transforman las existentes para potenciar la capacidad predictiva del sistema. Una vez realizados estos ajustes, el sistema se reentrena utilizando los datos actualizados y se evalúa nuevamente su rendimiento para asegurar que las mejoras implementadas hayan generado mejoras significativas en su capacidad predictiva. Este proceso iterativo de análisis, ajuste y reentrenamiento garantiza que el sistema evolucione y se adapte continuamente a medida que se descubren y abordan sus áreas de mejora.

#### Implementar Reportes en el Sistema

En la etapa final de implementación de reportes en el sistema, se procede al diseño de dashboards interactivos que muestran las predicciones, métricas clave y tendencias relevantes de manera visual y comprensible, permitiendo a los usuarios acceder y analizar fácilmente la información generada por el sistema. Además, se establecen mecanismos para la generación automática de reportes periódicos, garantizando que los resultados y análisis del sistema se comuniquen de manera oportuna y eficiente. Utilizando herramientas de visualización de datos, se presenta la información de forma clara y concisa, resaltando patrones y hallazgos importantes para una mejor comprensión. Además, se implementan alertas que notifican a los usuarios sobre desviaciones significativas en la demanda o el rendimiento del sistema, permitiendo una acción rápida y preventiva. Finalmente, se asegura que los reportes sean accesibles para los usuarios clave y que la interfaz sea intuitiva y fácil de usar, garantizando así la usabilidad y la efectividad del sistema de reportes en la toma de decisiones. Este enfoque integral de implementación de reportes asegura que los usuarios puedan aprovechar al máximo los resultados del sistema predictivo de manera eficiente y efectiva.

## IV. EXPERIMENTOS

El desarrollo y evaluación del sistema predictivo propuesto implicaron una serie de experimentos centrados en la validación del modelo de redes neuronales aplicado a la planificación de la demanda en librerías. Estos experimentos se llevaron a cabo para medir la precisión, robustez y capacidad de generalización del sistema, comparándolo con métodos tradicionales de predicción. La experimentación fue clave para identificar áreas de mejora y ajustar los parámetros del sistema, a fin de optimizar su rendimiento en un entorno de alta variabilidad de demanda.

### *Configuración del experimento*

La experimentación se realizó en una infraestructura basada en la nube, utilizando servidores con las siguientes especificaciones: procesador Intel Core i7 de 8 núcleos, 32 GB de RAM y una tarjeta gráfica Nvidia GTX 2080. Esta configuración permitió ejecutar múltiples simulaciones en paralelo y manejar grandes volúmenes de datos de manera eficiente. El conjunto de datos utilizado para los experimentos consistió en un año completo de registros de ventas históricas distribuidos en: entrenamiento, 70%, validación, 15% y prueba, 15%, inventarios y factores externos que influyen en la demanda de productos en librerías. Estos datos incluían variables como las promociones de temporada, eventos especiales, y otros factores que podrían afectar el comportamiento de los consumidores. Los periodos de alta demanda, como la temporada escolar, y periodos de baja actividad, fueron seleccionados estratégicamente para evaluar el rendimiento del sistema en diferentes contextos.

### *Procedimiento experimental*

El procedimiento experimental fue estructurado en cuatro fases clave, cada una enfocada en una etapa crítica del desarrollo y evaluación del sistema predictivo:

#### **1. Adquisición y preprocesamiento de datos**

La primera fase del experimento involucró la recolección de datos históricos de ventas e inventarios, junto con datos adicionales sobre factores externos (clima, eventos, promociones). Estos datos fueron extraídos tanto de los sistemas de gestión internos de la librería como de bases de datos públicas y herramientas externas. Una vez recolectados, se aplicaron técnicas de preprocesamiento, como la limpieza de datos (eliminación de valores duplicados y corrección de inconsistencias), normalización (escalado de variables para garantizar comparabilidad) y transformación de variables categóricas. También se generaron nuevas características relevantes mediante ingeniería de características, como la creación de índices de estacionalidad y tendencias de ventas.

#### **2. Entrenamiento del modelo de redes neuronales**

En esta fase, el sistema fue entrenado utilizando una arquitectura de redes neuronales profundas, diseñada para optimizar la capacidad predictiva en la planificación de la

demanda. El conjunto de datos se dividió en tres subconjuntos: el conjunto de entrenamiento (70%), el conjunto de validación (15%) y el conjunto de prueba (15%). El sistema fue ajustado mediante técnicas de optimización de hiperparámetros, como la regularización L2 para evitar el sobreajuste, y el uso de optimizadores avanzados como Adam para ajustar los pesos de la red neuronal. Se realizaron múltiples iteraciones del entrenamiento con diferentes configuraciones de la red (variando el número de capas y neuronas por capa, así como las funciones de activación) para identificar la arquitectura que ofreciera el mejor equilibrio entre precisión y generalización. El sistema fue validado continuamente mediante técnicas de validación cruzada, lo que permitió ajustar los hiperparámetros y asegurar que el modelo no se sobreajustara a los datos de entrenamiento.

#### **3. Simulaciones de predicción de demanda**

Con el modelo entrenado y ajustado, se procedió a realizar las simulaciones de predicción de demanda. Estas simulaciones abarcaban horizontes temporales diarios, semanales y mensuales, y permitieron evaluar cómo el sistema predecía la demanda en diferentes contextos. Las predicciones del sistema fueron comparadas con los datos de ventas reales, y se utilizó un conjunto de métricas para evaluar el rendimiento del modelo, tales como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). El sistema también fue probado en escenarios de alta variabilidad, como en periodos de gran demanda durante la temporada escolar, y en periodos de baja demanda. Se evaluó el comportamiento del sistema bajo distintas condiciones, analizando su capacidad de adaptación a fluctuaciones inesperadas en el comportamiento de los consumidores.

#### **4. Evaluación del rendimiento del sistema**

Finalmente, los resultados de las simulaciones fueron sometidos a una evaluación exhaustiva para determinar la precisión del sistema predictivo en comparación con los métodos tradicionales, como el promedio móvil y la suavización exponencial. La evaluación incluyó el cálculo de las métricas antes mencionadas, y se observó un notable aumento en la precisión de las predicciones al usar el sistema basado en machine learning, particularmente en periodos de alta demanda. Además, se realizó un análisis de sensibilidad para evaluar el impacto de los factores externos en las predicciones del sistema, con el fin de identificar áreas de mejora en la integración de estos factores en el modelo. El sistema mostró un buen desempeño al ajustarse dinámicamente a los cambios en las condiciones de mercado, aunque se identificaron oportunidades de mejora en la predicción de demanda durante eventos atípicos o de baja frecuencia.

### *Resultados y análisis*

Los resultados de los experimentos indicaron que el sistema predictivo basado en redes neuronales profundas superó significativamente a los métodos tradicionales en términos de precisión y adaptabilidad. Las simulaciones

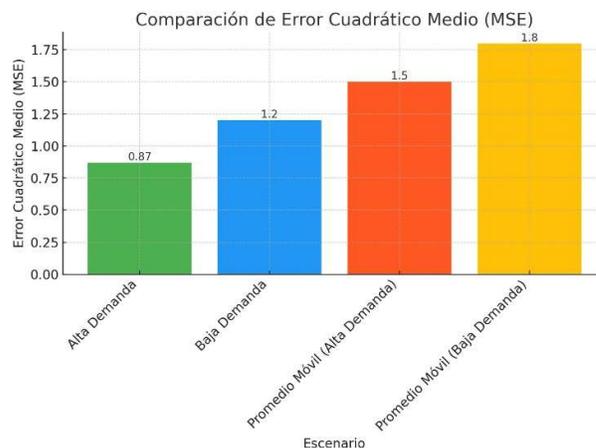
realizadas durante la temporada escolar, por ejemplo, mostraron que el sistema fue capaz de predecir la demanda con un margen de error menor al 5%, lo que representa una mejora considerable en comparación con el promedio móvil y otros métodos estadísticos, que presentaron un error promedio del 12%. En los periodos de baja demanda, aunque el sistema mostró una ligera reducción en su precisión (con un margen de error del 8%), aún superó los métodos tradicionales, que presentaron un error promedio del 15%. Estos resultados sugieren que el sistema propuesto es más robusto frente a fluctuaciones inesperadas en la demanda y puede adaptarse mejor a las variaciones estacionales y otros factores externos.

### Discusión

Los resultados obtenidos (MAPE del 5%) son consistentes con estudios previos en entornos similares [7,8], pero con la ventaja de incorporar factores externos no considerados en dichas investigaciones. El análisis de los resultados muestra que el sistema basado en machine learning no solo ofrece predicciones más precisas, sino que también permite una mayor flexibilidad en la planificación de la demanda en entornos comerciales dinámicos. A pesar de los excelentes resultados obtenidos, se identificaron algunas áreas de mejora, como la capacidad del sistema para ajustar sus predicciones en eventos atípicos, tales como promociones imprevistas o cambios abruptos en las preferencias de los consumidores. En este sentido, futuras iteraciones del modelo deberían considerar la inclusión de técnicas más avanzadas, como el aprendizaje por refuerzo, para mejorar la capacidad del sistema de aprender y adaptarse continuamente a los cambios en tiempo real.

### Conclusiones de los experimentos

Como limitación, el modelo requiere datos históricos continuos para mantener su precisión. Futuras investigaciones podrían explorar la integración de datos de redes sociales para mejorar las predicciones en eventos atípicos. Los experimentos realizados demostraron que un sistema predictivo basado en redes neuronales puede mejorar significativamente la planificación de la demanda en librerías, reduciendo la acumulación excesiva de inventarios y minimizando los quiebres de stock. Si bien el sistema mostró un excelente rendimiento, particularmente durante periodos de alta demanda, la investigación sugiere que incorporar más factores contextuales en el modelo puede aumentar aún más su capacidad de predicción.



### REFERENCES

- [1] G. Eason, B. Noble, I. N. Sneddon, y J. E. Lennard-Jones, «On certain integrals of Lipschitz-Hankel type involving products of Bessel functions», *Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences*, vol. 247, n.º 935, pp. 529-551, ene. 1997, doi: 10.1098/rsta.1955.0005.
- [2] M. Magadán-Díaz y J. I. Rivas-García, «El impacto disruptivo del libro electrónico sobre la cadena de valor editorial española: un estudio de casos», *Revista Española de Documentación Científica*, vol. 43, n.º 1, Art. n.º 1, mar. 2020, doi: 10.3989/redc.2020.1.1650.
- [3] S. Benaissa Pedriza, «Medios impresos versus digitales: de la agónica lectura de periódicos a los nuevos consumos de información digital», *El Argonauta español. Revue bilingue, franco-espagnole, d'histoire moderne et contemporaine consacrée à l'étude de la presse espagnole de ses origines à nos jours (XVIIe-XXIe siècles)*, n.º 16, Art. n.º 16, may 2019, doi: 10.4000/argonauta.3855.
- [4] L. J. Blanco Encinosa, «De la horda a la empresa de alta tecnología y de Moisés a Steve Jobs: un breve recorrido por la historia de la gestión del capital humano (segunda parte)», *Economía y Desarrollo*, vol. 167, n.º 2, dic. 2023, Accedido: 25 de agosto de 2024. [En línea]. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_abstract&pid=S0252-85842023000200005&lng=es&nrm=iso&tlng=pt](http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S0252-85842023000200005&lng=es&nrm=iso&tlng=pt)
- [5] F. Kara, «Digital Transformation and Changing Marketing Dynamics in the World», en *Management Strategies to Survive in a Competitive Environment: How to Improve Company Performance*, H. Dincer y S. Yüksel, Eds., Cham: Springer International Publishing, 2021, pp. 201-213. doi: 10.1007/978-3-030-72288-3\_14.
- [6] N. A. Bernal Dávila y Á. S. López Abril, «Desarrollo de un prototipo de sistema de facturación e inventarios para tiendas minoristas de ropa que mediante redes neuronales mejore el control de inventarios», 2020, Accedido: 25 de agosto de 2024. [En línea]. Disponible en:

- <https://repository.unab.edu.co/handle/20.500.12749/12050>
- [7] F. Ramos-Pérez, C. Vivas Venegas, y F. R. Rubio, «Predicción de demanda y generación renovable con Deep Learning: Aplicación a la optimización de estaciones de carga de vehículos eléctricos», presentado en XLIV Jornadas de Automática, Universidade da Coruña. Servizo de Publicacións, 2023, pp. 346-351. Accedido: 26 de agosto de 2024. [En línea]. Disponible en: <https://ruc.udc.es/dspace/handle/2183/33630>
- [8] V. Lukinskiy, V. Lukinskiy, y B. Sokolov, «Control of inventory dynamics: A survey of special cases for products with low demand», *Annual Reviews in Control*, vol. 49, pp. 306-320, ene. 2020, doi: 10.1016/j.arcontrol.2020.04.005.
- [9] M. H. Park, J. S. Lee, y I. C. Doo, «A Study of the Demand Forecasting Model for Publishing Business using Business Analysis», *International Journal of Computing and Digital Systems*, vol. 9, n.º 5, pp. 1-12, sep. 2020, doi: 10.12785/ijcds/090503.
- [10] N. Mejía Franco, A. Echeverri Rubio, y J. A. Vieira Salazar, «Gobernanza corporativa en pequeñas y medianas empresas: una revisión sistemática de literatura», *Revista Venezolana de Gerencia: RVG*, vol. 26, n.º 93, pp. 245-263, 2021.
- [11] S. Sani, H. Xia, J. Milisavljevic-Syed, y K. Salonitis, «Supply Chain 4.0: A Machine Learning-Based Bayesian-Optimized LightGBM Model for Predicting Supply Chain Risk», *Machines*, vol. 11, n.º 9, Art. n.º 9, sep. 2023, doi: 10.3390/machines11090888.
- [12] D. Cordeiro *et al.*, «Machine Learning Methods for Woody Volume Prediction in Eucalyptus», *Sustainability*, vol. 15, p. 10968, jul. 2023, doi: 10.3390/su151410968.
- [13] A. Aamer, L. Eka Yani, y Im. Alan Priyatna, «Data Analytics in the Supply Chain Management: Review of Machine Learning Applications in Demand Forecasting», *Operations and Supply Chain Management: An International Journal*, vol. 14, n.º 1, pp. 1-13, dic. 2020, doi: 10.31387/oscm0440281.
- [14] Y. Liang, C. Lan, T. Dan, Z. Qiaoqiong, Y. Yue, y C. Lin, «Research on supply and demand matching model of transportation modes in MaaS system of integrated passenger transport hub based on deep learning», *Soft Comput*, vol. 27, n.º 9, pp. 5973-5983, may 2023, doi: 10.1007/s00500-023-08065-4.
- [15] C. Ntakolia, C. Kokkotis, P. Karlsson, y S. Moustakidis, «An Explainable Machine Learning Model for Material Backorder Prediction in Inventory Management», *Sensors*, vol. 21, n.º 23, Art. n.º 23, ene. 2021, doi: 10.3390/s21237926.
- [16] T. Demizu, Y. Fukazawa, y H. Morita, «Inventory management of new products in retailers using model-based deep reinforcement learning», *Expert Systems with Applications*, vol. 229, p. 120256, nov. 2023, doi: 10.1016/j.eswa.2023.120256.
- [17] L. Liu, G. Zhu, y X. Zhao, «Application of medical supply inventory model based on deep learning and big data», *Int J Syst Assur Eng Manag*, vol. 13, n.º 3, pp. 1216-1227, dic. 2022, doi: 10.1007/s13198-022-01669-3.
- [18] C. Ingle, D. Bakliwal, J. Jain, P. Singh, P. Kale, y V. Chhajed, «Demand Forecasting : Literature Review On Various Methodologies», en *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, jul. 2021, pp. 1-7. doi: 10.1109/ICCCNT51525.2021.9580139.
- [19] M. Seyedan y F. Mafakheri, «Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities», *J Big Data*, vol. 7, n.º 1, p. 53, jul. 2020, doi: 10.1186/s40537-020-00329-2.
- [20] M. Z. Babai, J. E. Boylan, y B. Rostami-Tabar, «Demand forecasting in supply chains: a review of aggregation and hierarchical approaches», *International Journal of Production Research*, vol. 60, n.º 1, pp. 324-348, ene. 2022, doi: 10.1080/00207543.2021.2005268.
- [21] V. Gutiérrez y C. J. Vidal, «Modelos de Gestión de Inventarios en Cadenas de Abastecimiento: Revisión de la Literatura», *Revista Facultad de Ingeniería Universidad de Antioquia*, n.º 43, pp. 134-149, mar. 2008.
- [22] R. Fernández López, J. A. Vilalta Alonso, y A. Quintero Silverio, «Una revisión crítica sobre modelos de predicción para la demanda turística», *TURYDES: Revista sobre Turismo y Desarrollo local sostenible*, vol. 12, n.º 27, p. 3, 2019.