



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado

Facultad de Ingeniería de Sistemas e Informática

Unidad de Posgrado

**Comparación de métodos estadísticos y redes neuronales para
la toma de decisiones en la asignación de ubicación del
almacenamiento**

TESIS

Para optar el Grado Académico de Magíster en Ingeniería de
Sistemas e Informática con mención en Gestión de Tecnología de
Información y Comunicaciones

AUTOR

Agusto Guillermo SÁNCHEZ FERRER

ASESOR

Dr. José Alfredo HERRERA QUISPE

Lima, Perú

2025



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.


Referencia bibliográfica

Sánchez, A. (2025). *Comparación de métodos estadísticos y redes neuronales para la toma de decisiones en la asignación de ubicación del almacenamiento*. [Tesis de maestría, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Agusto Guillermo Sánchez Ferrer
Tipo de documento de identidad	DNI
Número de documento de identidad	72492135
URL de ORCID	https://orcid.org/0000-0003-3643-3046
Datos de asesor	
Nombres y apellidos	Dr. José Alfredo Herrera Quispe
Tipo de documento de identidad	DNI
Número de documento de identidad	40362859
URL de ORCID	https://orcid.org/0000-0002-8207-9714
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Mg. José César Piedra Isusqui
Tipo de documento	DNI
Número de documento de identidad	25628915
Miembro del jurado 1	
Nombres y apellidos	Mg. Pablo Edwin López Villanueva
Tipo de documento	DNI
Número de documento de identidad	32920084
Miembro del jurado 2	
Nombres y apellidos	Mg. William Martín Enriquez Maguiña
Tipo de documento	DNI
Número de documento de identidad	06179457
Datos de investigación	

Línea de investigación	C.0.5.8
Grupo de investigación	No aplica.
Agencia de financiamiento	No aplica.
Ubicación geográfica de la investigación	Edificio: Universidad Nacional Mayor de San Marcos País: Perú Departamento: Lima Provincia: Lima Distrito: Lima Latitud: - 12.053424 Longitud: -77.085161
Año o rango de años en que se realizó la investigación	2022 - 2025
URL de disciplinas OCDE	Informática y Ciencias de la Información https://purl.org/pe-repo/ocde/ford#1.02.00 Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
Facultad de Ingeniería de Sistemas e Informática
Vicedecanato de Investigación y Posgrado
Unidad de Posgrado

**ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR EL GRADO ACADÉMICO DE
MAGÍSTER EN INGENIERÍA DE SISTEMAS E INFORMÁTICA CON MENCIÓN EN
GESTIÓN DE TECNOLOGÍA DE INFORMACIÓN Y COMUNICACIONES**

A los dieciocho (18) días del mes de diciembre de 2025, siendo las 10:00 am., se reunieron en el Auditorio Alfredo Celso Alva Bravo, el Jurado de Tesis conformado por los siguientes docentes:

Mg. Jose César Piedra Isusqui (Presidente)
Mg. Pablo Edwin López Villanueva (Miembro)
Mg. William Martín Enriquez Maguiña (Miembro)
Dr. José Alfredo Herrera Quispe (Miembro Asesor)

Se inició la Sustentación invitando al candidato a Magíster **Agusto Guillermo Sánchez Ferrer**, para que realice la exposición oral de la tesis para optar el Grado Académico de Magister en Ingeniería de Sistemas e Informática con mención en Gestión de Tecnología de Información y Comunicaciones, siendo la Tesis intitulada:

**“COMPARACIÓN DE MÉTODOS ESTADÍSTICOS Y REDES NEURONALES PARA LA TOMA
DE DECISIONES EN LA ASIGNACIÓN DE UBICACIÓN DEL ALMACENAMIENTO”**

Concluida la exposición, los miembros del Jurado de Tesis procedieron a formular sus preguntas que fueron absueltas por el graduando; acto seguido se procedió a la evaluación correspondiente, habiendo obtenido la siguiente calificación:

Diecisiete (17) MUY BUENO

Por tanto, el presidente del Jurado, de acuerdo con el Reglamento General de Estudios de Posgrado, otorga al Bachiller **AGUSTO GUILLERMO SÁNCHEZ FERRER** el Grado Académico de Magister en Ingeniería de Sistemas e Informática con mención en Gestión de Tecnología de Información y Comunicaciones.

Siendo las 11:10 horas, el presidente del Jurado de Tesis, da por concluido el acto académico de Sustentación de Tesis.

Mg. Jose César Piedra Isusqui
(Presidente)

Mg. Pablo Edwin López Villanueva
(Miembro)

Mg. William Martín Enriquez Maguiña
(Miembro)

Dr. José Alfredo Herrera Quispe
(Miembro Asesor)



UNIVERSIDAD NACIONAL MAYOR DE
SAN MARCOS
Universidad del Perú, Decana de América

CERTIFICADO DE SIMILITUD

Yo, José Alfredo Herrera Quispe en mi condición de asesor acreditado con Dictamen N° 000007-2022-UPG-VDIP-FISI/UNMSM de la tesis, cuyo título es **COMPARACIÓN DE MÉTODOS ESTADÍSTICOS Y REDES NEURONALES PARA LA TOMA DE DECISIONES EN LA ASIGNACIÓN DE UBICACIÓN DEL ALMACENAMIENTO**, presentado por el egresado **AGUSTO GUILLERMO SÁNCHEZ FERRER** para optar el grado de Maestría en Ingeniería de Sistemas e Informática con mención en Gestión de Tecnología de Información y Comunicaciones.

CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el 5% de similitud, nivel **PERMITIDO** para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del grado correspondiente.

Lima, 28 de abril de 2025

Firma del Asesor

Nombres y Apellidos del asesor: José Alfredo Herrera Quispe

DNI 40362859

DEDICATORIA

A mi familia, por su apoyo incondicional y por siempre estar a mi lado, brindándome fortaleza y motivación en cada paso de este camino.

A mis amigas Sofía y Yelka, por ser un apoyo constante, brindándome su amistad, comprensión y aliento incondicional a lo largo de todo este proceso.

A Fernanda, por su apoyo y motivación al inicio de este proyecto de tesis, incluso cuando nuestra comunicación llegó a su fin. Su impulso en los primeros pasos fue significativo y siempre será valorado.

Agradezco profundamente al Dr. José Herrera por su constante apoyo, guía y valiosas asesorías durante el desarrollo de mi tesis.

Sobre todo, a Evelyn, quien fue la persona más importante durante el transcurso de la elaboración de mi tesis. Gracias a su apoyo incansable, su paciencia, sabiduría y dedicación, no solo pude culminar este proyecto, sino que también crecí como persona. Su constante motivación, consejos y presencia fueron clave para superar los desafíos, y su amistad y generosidad siempre serán un pilar fundamental en mi vida. Sin ella, este logro no habría sido posible.

Índice General

DEDICATORIA	II
LISTA DE TABLAS	V
LISTA DE FIGURAS	VI
RESUMEN	VII
ABSTRACT	VIII
I INTRODUCCIÓN	1
1.1 Situación problemática	1
1.1.1 Ámbito Internacional	1
1.1.2 Ámbito Nacional	1
1.2 Formulación del problema	2
1.2.1 Problema general	2
1.2.2 Problemas específicos	2
1.3 Justificación teórica de la investigación	2
1.3.1 Valor Teórico	2
1.3.2 Conveniencia	3
1.3.3 Relevancia Social	3
1.3.4 Implicaciones y Aplicaciones Prácticas	3
1.4 Objetivos de la investigación	3
1.4.1 Objetivo general	3
1.4.2 Objetivos específicos	3
1.5 Hipótesis de la investigación	4
1.5.1 Hipótesis general	4
1.5.2 Hipótesis específicas	4
II MARCO TEÓRICO	5
2.1 Antecedentes de Investigación	5
2.1.1 Nacional	5
2.1.2 Internacional	7
2.2 Bases Teóricas	10
2.2.1 Almacén	10
2.2.2 Slotting	12

2.2.3	Series temporales	13
2.3	Marco Conceptual	19
2.3.1	Errores de Predicción	19
2.3.2	Gráficos de Residuales	20
2.3.3	Pruebas de Estacionariedad	21
2.3.4	Intervalos de Confianza	22
2.4	Glosario	23
III	METODOLOGÍA	25
3.1	Tipo de la Investigación	25
3.2	Diseño de la Investigación	25
3.3	Nivel de la Investigación	25
3.4	Dataset y Partición	26
3.4.1	Dataset	26
3.4.2	Partición	26
3.5	Operacionalización de Variables	26
3.5.1	Identificación de Variables	26
3.5.2	Descripción de Dimensiones e Indicadores de Variables	29
3.6	Criterios de Evaluación del Desempeño de los Modelos de Pronóstico	29
IV	FASE IMPLEMENTACIÓN	31
4.1	Análisis del Dataset <i>ProductForecastData</i>	31
4.1.1	Ventajas del Uso del Dataset de Productos	31
4.1.2	Desventajas del Uso del Dataset de Productos	32
4.2	Presentación de Modelo Propuesto	32
4.2.1	Entrada	33
4.2.2	Procesamiento	34
4.2.3	Salida	37
4.2.4	Infraestructura tecnológica	38
4.3	Implementación de los modelos de Suavización Exponencial	39
4.4	Implementación del modelo Autorregresivo Integrado de Promedio Móvil (Estacionalidad)	42
4.5	Implementación del modelo de Memoria a Largo y Corto Plazo	48
4.6	Implementación del modelo de Unidad Recurrente con Puertas	53
V	RESULTADOS	57
5.1	Objetivo Específico 1: Suavizaciones Exponenciales	57
5.2	Objetivo Específico 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad	62
5.3	Objetivo Específico 3: Memoria a Largo y Corto Plazo	66

5.4	Objetivo Específico 4: Unidad Recurrente con Puertas	70
5.5	Resultados de los modelos de pronósticos por MAPE	73
5.5.1	Resumen de los modelos de MAPE	73
5.5.2	Resumen de los modelos de pronósticos MAPE	74
5.5.3	Resumen de los modelos de MAPE agrupados	75
VI	DISCUSIÓN	77
6.1	Hipótesis Específica 1: Suavizaciones Exponenciales	77
6.2	Hipótesis Específica 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad	78
6.3	Hipótesis Específica 3: Memoria a Largo y Corto Plazo	79
6.4	Hipótesis Específica 4: Unidad Recurrente con Puertas	79
VII	CONCLUSIONES	81
7.1	Conclusión General	81
7.2	Objetivo Específica 1: Suavizaciones Exponenciales	81
7.3	Objetivo Específica 1: Suavizaciones Exponenciales	81
7.4	Objetivo Específica 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad	82
7.5	Objetivo Específica 3: Memoria a Largo y Corto Plazo	82
7.6	Objetivo Específica 4: Unidad Recurrente con Puertas	83
VIII	RECOMENDACIONES	84
8.1	Monitoreo y Reevaluación de Modelos	84
8.2	Capacitación del Personal	84
8.3	Exploración de Nuevas Técnicas	85
8.4	Mejora en la Calidad de los Datos	85
8.5	Propuesta de nuevo rango de MAPE	85
	Referencias bibliográficas	87

Lista de Tablas

Tabla 1.	Descripción de variables y métodos utilizados	28
Tabla 2.	Criterio de evaluación de MAPE	30
Tabla 3.	Descripción de los procesos	39
Tabla 4.	Resultados de Pronósticos: Suavizaciones Exponenciales Dobles y Triples	59
Tabla 5.	Resultados de MAPE: Suavizaciones Exponenciales Dobles y Triples	60
Tabla 6.	Resultados de Pronósticos: (S)ARIMA	63
Tabla 7.	Resultados de MAPE: (S)ARIMA	64
Tabla 8.	Resultados de Pronósticos: LSTM	67
Tabla 9.	Resultados de MAPE: LSTM	68
Tabla 10.	Resultados de Pronósticos: GRU	71
Tabla 11.	Resultados de MAPE: GRU	72
Tabla 12.	Resultados de MAPE de los modelos de pronósticos	74
Tabla 13.	Análisis de los Valores Mínimos, Máximos y Promedios del MAPE en los Modelos de Pronóstico	75
Tabla 14.	Resultados de MAPE de los modelos Agrupados	76
Tabla 15.	<i>Nueva propuesta de intervalo MAPE</i>	86

Lista de Figuras

Figura 1.	Gráfico residual	21
Figura 2.	Gráfico de prueba de Dickey-Fuller	22
Figura 3.	Gráfico de intervalo de confianza	23
Figura 4.	Modelo de Slotting utilizando métodos estadísticos y redes neuronales	33
Figura 5.	Características del procesamiento de datos de muestra	34
Figura 6.	Características del procesamiento de Procesamiento Estadístico y Aprendizaje Automático	36
Figura 7.	Características de Procesamiento de Resultado	37
Figura 8.	Características del proceso de toma de decisiones	38
Figura 9.	Gráficos de UND_ORDEN y Pronósticos usando Suavización Exponencial	62
Figura 10.	Gráficos de UND_ORDEN y Pronósticos usando (S)ARIMA	65
Figura 11.	Gráficos de UND_ORDEN y Pronósticos usando LSTM	69
Figura 12.	Gráficos de UND_ORDEN y Pronósticos usando GRU	73

RESUMEN

En la actualidad los almacenes enfrentan diversos desafíos logísticos en todas sus áreas, siendo uno de los más relevantes el proceso de preparación de pedidos, donde los tiempos de espera en la recolección suelen aumentar considerablemente debido a la congestión generada por la falta de productos en las ubicaciones asignadas. Se han desarrollado diversos métodos de solución, destacando el 'Slotting', que optimiza la preparación de pedidos mediante técnicas analíticas para asignar productos de manera eficiente. Sin embargo, los cambios estacionales y las variaciones en la demanda de productos representan un desafío constante en la asignación de productos, ya que requieren reubicar los productos en diferentes zonas según sus necesidades. En la presente investigación se aplicaron métodos estadísticos y redes neuronales para pronosticar la demanda de los productos, los cuales podrían ser utilizados para la toma de decisiones en la asignación de ubicación de almacenamiento. La investigación consta de dos fases. La primera tiene como objetivo integrar un modelo novedoso para mejorar la asignación de ubicaciones de almacenamiento de productos, basado en un análisis riguroso de estudios previos. La segunda fase se enfoca en la comparación de diversos métodos, como el modelo autorregresivo integrado de medias móviles estacional; la suavización exponencial doble y triple; redes neuronales como las unidades recurrentes con puertas y memoria de largo y corto plazo. Para comparar estos métodos, se realizó el siguiente estudio utilizando un conjunto de datos históricos de 50 productos, abarcando un período de 7 años, desde enero de 2016 hasta julio de 2023. Esta investigación propone un enfoque híbrido, donde los métodos aplicados representan una estrategia efectiva para alcanzar una mayor precisión en los pronósticos y optimizar la asignación de ubicaciones en el almacenamiento.

Palabras clave: Suavización Exponencial, Pronóstico, Redes Neuronales Recurrentes, Asignación de Productos, SARIMA, Slotting.

ABSTRACT

Currently, warehouses face various logistical challenges across all areas, with one of the most significant being the order preparation process. In this process, collection times often increase considerably due to congestion caused by the lack of products in their assigned locations. Several solution methods have been developed, with 'Slotting' standing out as a technique that optimizes order preparation through analytical methods to efficiently allocate products. However, seasonal changes and variations in product demand present a constant challenge in product allocation, as they require the relocation of products to different areas based on their needs. In the present research, statistical methods and neural networks were applied to forecast product demand, which could be used for decision-making in the allocation of storage locations. The research consists of two phases. The first aims to integrate an innovative model to improve the allocation of storage locations for products, based on a rigorous analysis of previous studies. The second phase focuses on the comparison of various methods, including the seasonal autoregressive integrated moving average model, double and triple exponential smoothing and neural networks such as Gated Recurrent Units and Long Short-Term Memory. To compare these methods, a study was conducted using a historical dataset of 50 products, spanning a period of 7 years, from January 2016 to July 2023. This research proposes a hybrid approach, where the applied methods represent an effective strategy to achieve greater forecasting accuracy and optimize storage location allocation.

Keywords: Exponential Smoothing, Forecasting, Recurrent Neural Networks, Product Allocation, SARIMA, Slotting.

Capítulo I

INTRODUCCIÓN

1.1. Situación problemática

1.1.1. Ámbito Internacional

Los centros de distribución (CD) y almacenes gestionan diversas actividades logísticas, desde la recepción y almacenamiento de productos hasta el envío de órdenes al usuario final. En la actualidad, están enfrentando nuevos desafíos en la mejora de la calidad del servicio al cliente debido a la alta competitividad entre las empresas. Como respuesta, están adoptando tecnologías avanzadas como la inteligencia artificial (IA). La IA permite a las empresas modernizar sus centros de distribución y almacenes mediante la implementación de sistemas inteligentes que optimizan el uso del espacio, mejoran la gestión de inventarios y reducen los tiempos de procesamiento. A pesar de los desafíos y la inversión que supone la adopción de IA, los resultados a largo plazo traen múltiples beneficios, como la reducción de costos, la mejora en la satisfacción del cliente y una mayor capacidad para competir en el mercado.

1.1.2. Ámbito Nacional

En el Perú las empresas de logística se han enfocado en planificar y desarrollar mejoras operacionales con la finalidad de optimizar los procesos internos de los almacenes, reduciendo costos, tiempos y accidentes. El Slotting es un factor clave para los procesos de preparación de pedidos y distribución de inventario, mejorando la productividad en el almacén. En la actualidad, las empresas logísticas empiezan a crecer su infraestructura y su alcance al público, muchas de ellos convirtiéndose Centros de Distribución siendo una infraestructura con mayor demanda al almacén. Por ello, los modelos y técnicas analíticas de Slotting, deben asegurar el eficiente y seguimiento de la asignación de productos. Sin embargo, la mayoría de empresas solo optan por aplicar el Slotting únicamente 1 o 2 veces, como consecuencia, no se realiza el monitoreo

de la variación de las demandas de los productos.

1.2. Formulación del problema

1.2.1. Problema general

¿Cómo el diseño de un modelo que integra métodos estadísticos y redes neuronales recurrentes permite obtener pronósticos significativamente más precisos para la toma de decisiones en la asignación de ubicaciones de almacenamiento?

1.2.2. Problemas específicos

- ¿Cómo los métodos de suavización exponencial doble y triple obtienen pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento?
- ¿Cómo el método de Autorregresivo Integrado de Promedio Móvil, con o sin estacionalidad obtienen pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento?
- ¿Cómo el método de Memoria a Largo y Corto Plazo obtienen pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento?
- ¿Cómo el método de Unidad Recurrente con Puertas obtienen pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento?

1.3. Justificación teórica de la investigación

1.3.1. Valor Teórico

Esta investigación tiene como objetivo contribuir con nuevos conocimientos que refuercen la importancia y la necesidad del Slotting en los almacenes. Este estudio busca profundizar en su aplicación y beneficios, apoyando teorías relacionadas con el proceso de preparación de pedidos y proporcionando una base empírica y teórica. Los resultados obtenidos no solo añadirán valor a la práctica logística actual, sino que también servirán como referencia en futuros estudios de caso y en investigaciones académicas. Al identificar y analizar las mejores prácticas y metodologías en Slotting, se espera promover la adopción de técnicas avanzadas en la gestión de almacenes, contribuyendo al desarrollo de modelos más eficientes que mejoren la competitividad de las empresas de logística en diversos sectores.

1.3.2. Conveniencia

El desarrollo de esta investigación permitirá a las empresas de logística mantener un monitoreo continuo y efectivo de sus productos mediante la implementación de diversas metodologías y técnicas avanzadas de análisis de Slotting. Esto se traducirá en mejoras significativas, tales como la reducción del tiempo necesario para la preparación de pedidos, la optimización de los costos asociados al abastecimiento durante las horas de preparación, un control más preciso del inventario y un notable incremento en el nivel de servicio ofrecido a los clientes.

1.3.3. Relevancia Social

La asignación eficiente de espacios en el almacén mediante métodos precisos de pronóstico contribuye significativamente a la optimización de recursos, reduciendo el desperdicio y fomentando prácticas empresariales más sostenibles. Al minimizar la sobreproducción y gestionar de manera eficaz los inventarios, la empresa se alinea con principios de responsabilidad social y ambiental, fortaleciendo su compromiso con la eficiencia operativa y la gestión responsable de recursos.

1.3.4. Implicaciones y Aplicaciones Prácticas

La aplicación de métodos de pronóstico avanzados facilita una planificación estratégica más efectiva para la asignación de espacios en el almacén. Esto permite a las empresas anticipar de manera precisa las demandas futuras, facilitando decisiones informadas sobre la expansión, reorganización y uso óptimo del espacio disponible.

1.4. Objetivos de la investigación

1.4.1. Objetivo general

Diseñar un modelo que integre métodos estadísticos y redes neuronales recurrentes, que permita generar pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.

1.4.2. Objetivos específicos

- Evaluar los métodos de suavización exponencial doble y triple, que permitan generar pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.

- Evaluar el método de Autorregresivo Integrado de Promedio Móvil, con o sin estacionalidad, que permita generar pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.
- Evaluar el método de Memoria a Largo y Corto Plazo, que permita generar pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.
- Evaluar el método de Unidad Recurrente con Puertas, que permita generar pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.

1.5. Hipótesis de la investigación

1.5.1. Hipótesis general

El diseño de un modelo que integre métodos estadísticos y redes neuronales recurrentes permitirá obtener pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.

1.5.2. Hipótesis específicas

- La aplicación de los métodos de suavización exponencial doble y triple permitirán obtener pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.
- La aplicación del método Autorregresivo Integrado de Promedio Móvil, con o sin estacionalidad permitirá obtener pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.
- La aplicación del método de Memoria a Largo y Corto Plazo permitirá obtener pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.
- La aplicación del método de Unidad Recurrente con Puertas permitirá obtener pronósticos para la toma de decisiones en la asignación de ubicaciones de almacenamiento.

Capítulo II

MARCO TEÓRICO

2.1. Antecedentes de Investigación

2.1.1. Nacional

Según Robles Rakov y Valverde Campos (2021), en su tesis publicada "Sistema de predicción para incrementar las ventas de accesorios y repuestos automotrices en la empresa GGP Automotriz", Los autores identificaron desafíos significativos en los cálculos de inventario y ventas exclusivamente mediante métodos tradicionales que han demostrado ser ineficiente y propenso a errores. Por esta razón, su investigación se centró en desarrollar un sistema de predicción de ventas basado en las capacidades de Machine Learning, utilizando específicamente las Redes Neuronales Recurrentes (LSTM). El objetivo principal fue optimizar el inventario para garantizar el stock necesario, lo que permitiría incrementar las ventas y satisfacer la demanda del cliente. Los autores desarrollaron un sistema web predictivo que proporciona robustas funcionalidades logísticas, asegurando la cobertura eficiente tanto de la predicción de la demanda como de las operaciones logísticas de la empresa.

Según Bernaola Velarde y Varillas Trujillo (2022), en su tesis publicada "Sistema predictivo con Machine Learning para la gestión de inventario para la Empresa Inversiones Ferreteras Mendoza S.A.C". La presente tesis aborda la problemática del manejo manual de inventarios, donde la falta de control sobre entradas, salidas y stock de productos genera discrepancias entre la cantidad física y la registrada, afectando el control de gastos y la eficiencia del almacén. Como solución, se desarrolló un sistema predictivo basado en Machine Learning para la gestión de inventario, aplicando la metodología CRISP-DM. La implementación del sistema demuestra que es posible reducir tiempos y costos, optimizar la rotación de inventarios y mejorar significativamente la gestión de los productos, proporcionando un procedimiento más eficiente y confiable para la empresa.

Según Sedano Rosales (2022) en sus tesis publicada "Desarrollo de un sistema de predicción con machine learning para la gestión logística en Megaelectric Perú SAC". La presente investigación aborda la problemática de la gestión logística manual en el proceso de despachos y satisfacción del cliente. Como solución, se desarrolló un sistema de predicción basado en Machine Learning y un sistema experto, utilizando la metodología SCRUM y tecnologías como PHP, JQuery, Python y MySQL. La implementación del sistema, evaluada mediante indicadores de nivel de cumplimiento de despachos y porcentaje de clientes satisfechos, mostró mejoras significativas: un aumento del 21.82 % en los despachos cumplidos y un incremento del 17.29 % en la satisfacción de clientes, evidenciando que la automatización y predicción logística optimizan los procesos y generan resultados positivos para la empresa.

Según Montero Lopez (2025), en su tesis titulada "Sistema web inteligente basado en Machine Learning para apoyar la gestión de inventarios en la empresa E.B. Pareja Lecaros S.A.". La investigación abordó la problemática de la gestión manual de inventarios, la cual dificultaba predecir la demanda futura de productos y optimizar los niveles de stock. Como solución, se desarrolló un sistema web inteligente basado en Machine Learning, empleando algoritmos como XGBoost, LSTM, regresión lineal y Random Forest, y siguiendo las metodologías SCRUM y CRISP-DM para organizar el desarrollo y entrenamiento del modelo. Entre los algoritmos evaluados, XGBoost se identificó como el más preciso para las predicciones, obteniendo un MAE 0.5136148. Los resultados evidencian que el sistema mejora la eficiencia en la gestión de inventarios, reduce costos y genera beneficios financieros, satisfaciendo las necesidades de la empresa.

Según Castañeda Mauricio (2020) en su tesis publicada "Slotting en la gestión de inventarios de la empresa Costeño Alimentos S.A.C, Callao 2020", como objetivo es aplicar Slotting para mejorar la gestión de inventario de productos. Para ello, define dos variables: la dependiente e independiente. Siendo el Slotting como variable independiente y la gestión de inventarios como variable dependiente. El estudio se enfoca en una metodología cuantitativo y es experimental. Se concluye que la aplicación de Slotting: incremento la exactitud en el registro de inventarios en un 12.85 %; incremento la preparación de pedidos en un 19.21 % e incremento el índice de rotura de stock en un 82.09 %. Así mismo, el autor concluye que al aplicar Slotting los indicadores se ven afectados positivamente. Finalmente, se recomienda considerar el indicador exactitud en el registro de inventarios y aplicar Slotting de manera cíclica debido a que ciertos productos son estacionales.

Según Peña Valdiviezo (2021) en su tesis publicada “Mejora del proceso de preparación de pedidos del operador logístico Dinat S. A. con la aplicación de la metodología de Slotting y clasificación ABC con enfoque multicriterio para reducir los costos logísticos”, tiene como objetivo reducir costos logísticos en la preparación de pedidos, ya que los indicadores no se alinean a los objetivos de la empresa. Para ello, el autor decide implementar Slotting de tipo de clasificación usando 3 variables: frecuencia, volumen de pedido y valor de productos. Como resultados: incremento la productividad del 45 % en cajas y 38 % en unidades; incremento el nivel de servicio del 6.42 % y reducción del 59 % en costos por penalidades al operador. Finalmente, se concluye que la metodología de Slotting de clasificación ABC tiene un impacto en la reducción de costos logísticos para la empresa.

2.1.2. Internacional

Según Riatma et al. (2025), el estudio tuvo como objetivo comparar el rendimiento de los algoritmos Long Short-Term Memory (LSTM) y Gated Recurrent Unit (GRU) en la predicción de ventas. Los resultados muestran que LSTM supera a GRU en métricas como RMSE, MAE y MAPE, evidenciando una mayor precisión en el conjunto de datos analizado. En particular, para 100 epochs, el modelo GRU obtuvo un MAPE del 20 %, mientras que LSTM registró un MAPE del 60 %, confirmando su superioridad en términos de exactitud.

Según Pasupuleti et al. (2024), en su artículo “Enhancing Supply Chain Agility and Sustainability through Machine Learning: Optimization Techniques for Logistics and Inventory Management”. La gestión logística y de inventarios enfrenta una problemática crucial en las cadenas de suministro modernas, ya que los métodos tradicionales de optimización y predicción, como ARIMA y la suavización exponencial (ETS), son insuficientes para manejar la complejidad generada por las fluctuaciones de demanda y la heterogeneidad de datos (ERP, IoT). Como solución, el artículo propone y valida el uso de Machine Learning, específicamente modelos LSTM y CNN, como herramientas clave para optimizar procesos mediante la predicción de demanda y el análisis de patrones; esto se demostró con resultados concretos, donde el modelo LSTM logró un error de pronóstico del 2.3 %, superando significativamente el 3.7 % obtenido por ARIMA, lo cual evidencia mejoras directas en la eficiencia operativa, la reducción de costos y la precisión en los niveles de inventario.

Según Parasian et al. (2020) El objetivo de este estudio es analizar el proceso de pronóstico de la admisión de nuevos estudiantes en un programa universitario, utili-

zando el método de suavización exponencial doble. Este enfoque busca superar las limitaciones de las predicciones basadas en la intuición, proporcionando una metodología cuantitativa y sistemática para estimar el número de nuevos estudiantes. El aporte del estudio radica en demostrar cómo el uso de un modelo matemático de pronóstico puede mejorar la precisión en la planificación de las admisiones, en comparación con métodos subjetivos.

Según Bustami et al. (2023) el objetivo de este estudio es pronosticar las exportaciones no petroleras de Indonesia utilizando métodos de suavización exponencial. Se analizaron datos de exportaciones desde enero de 2015 hasta 2021, considerando tendencias y estacionalidad. Se aplicaron los métodos de suavización exponencial doble de Holt y suavización exponencial triple de Holt-Winters, tanto multiplicativo como aditivo. El estudio concluye que el modelo de Holt-Winters aditivo es el más preciso, con un MAPE inferior al 10 %, lo que sugiere que este método es el más adecuado para prever el comportamiento futuro de las exportaciones no petroleras.

Según Koech et al. (2021) el objetivo de este estudio es desarrollar un modelo predictivo preciso para estimar los costos de los insumos industriales en Kenia, como parte de su agenda de industrialización para fomentar el desarrollo económico sostenible. Se compararon dos técnicas de suavización exponencial de Holt-Winters (HWES) utilizando datos mensuales del índice de precios de insumos industriales de Kenia entre 1980 y 2018. Los resultados mostraron que un modelo híbrido de error multiplicativo, tendencia aditiva y estacionalidad multiplicativa (MAM) fue el más preciso, con un MAPE del 2.3 % para pronósticos a 24 meses. Este modelo superó las versiones puramente aditivas y multiplicativas, proporcionando una herramienta valiosa para productores, consumidores y responsables de políticas al prever una tendencia a la baja en los costos de insumos industriales.

Según Ozdemir et al. (2022) en esta investigación se analiza el uso de redes neuronales recurrentes, específicamente las redes de memoria a largo y corto plazo (LSTM) y las unidades recurrentes con compuerta (GRU), para predecir el precio del níquel. Los resultados muestran que las redes GRU y LSTM son eficaces en la predicción de las variaciones de precio del níquel, con valores de MAPE de 7.060 % y 6.986 %, respectivamente.

Según Hamayel y Owda (2021) en esta investigación analiza el uso de tres algoritmos de redes neuronales recurrentes (RNN) para predecir los precios de tres criptomonedas: Bitcoin (BTC), Litecoin (LTC) y Ethereum (ETH). Debido a la volatilidad y dinamismo de los precios de las criptomonedas, su predicción es un desafío. Los

resultados indican que la unidad recurrente con compuerta (GRU) obtuvo el mejor rendimiento en la predicción para las tres criptomonedas, superando a los modelos de memoria a largo y corto plazo (LSTM) y LSTM bidireccional (bi-LSTM). En particular, GRU mostró una mayor precisión en la predicción del precio de LTC, con un MAPE de 0.2454 % para BTC, 0.8267 % para ETH y 0.2116 % para LTC. Por el contrario, el modelo bi-LSTM presentó los peores resultados de predicción, con un MAPE de 5.990 % para BTC, 6.85 % para ETH y 2.332 % para LTC.

Según Karim et al. (2022) se enfoca en desarrollar un modelo híbrido de aprendizaje profundo que combine redes bidireccionales de memoria a largo y corto plazo (Bi-LSTM) y unidades recurrentes con compuerta (GRU) para predecir el movimiento de precios en el mercado de valores, utilizando datos del índice NIFTY-50. Los resultados experimentales muestran que el modelo híbrido Bi-LSTM-GRU supera significativamente a los modelos individuales (LSTM, Bi-LSTM, GRU y redes neuronales tradicionales), logrando predicciones más precisas a largo plazo en comparación con los enfoques anteriores.

Según Goswami y Kandali (2020) el objetivo de su investigación es predecir de manera precisa la demanda de carga eléctrica en Assam utilizando un esquema de pronóstico basado en datos. Se evalúan dos modelos de regresión: ARIMA y SARIMA, para predecir la carga eléctrica diaria. La evaluación de desempeño se realizó mediante diferentes métricas de error. Los resultados finales indican que el modelo SARIMA, que tiene en cuenta la estacionalidad de los datos, proporcionó mejores predicciones con un error mínimo.

Según Borucka (2023) en su estudio tiene como objetivo demostrar que, incluso con datos históricos limitados y factores externos desconocidos, es posible pronosticar la demanda de productos con fuertes fluctuaciones estacionales y una tendencia. Se comparan varios modelos estadísticos de pronóstico, incluyendo el modelo SARIMA, el modelo ARIMA con términos de Fourier, el modelo ETS y el modelo TBATS, presentándolos como alternativas a modelos de aprendizaje automático más complejos. Utilizando un estudio de caso, se evaluaron los resultados y se identificó la mejor solución, destacando que cada uno de los métodos utilizados puede mejorar la precisión del pronóstico de demanda en la cadena de suministro.

Según Kumar Dubey et al. (2021), en su investigación se centra en la predicción del consumo de energía que es esencial para la gestión de la demanda eléctrica y la planificación de carga en redes inteligentes. Se utilizaron los modelos ARIMA, SARIMA y LSTM para predecir el consumo energético diario utilizando mediciones de

medidores inteligentes. Los resultados indican que el consumo de energía tiene una alta correlación positiva con la humedad y una correlación negativa con la temperatura. El modelo LSTM resultó ser el más efectivo en comparación con ARIMA y SARIMA, obteniendo un error absoluto medio de 0.23, lo que lo posiciona como el modelo más adecuado para la predicción de consumo energético.

Según Thi et al. (2020) en su artículo de investigación de “Optimizing Warehouse Storage Location Assignment Under Demand Uncertainty” los autores se enfocan en el “storage location assignment problem” (SLAP). Por ello, la investigación se basa en la gestión de almacenamiento que integra el determinante de la cantidad de producción para un sistema de producción con diversos periodos y productos. Los autores, elaboran un modelo matemático para calcular: la cantidad de producción; los niveles de inventario y las ubicaciones de almacenamiento de los productos. Así mismo, se usó un modelo probabilístico para determinar el impacto de la incertidumbre de la demanda en el rendimiento del almacén durante un período de planificación. Esta investigación contribuye con una productividad efectiva en el diseño del almacén.

2.2. Bases Teóricas

2.2.1. Almacén

Se describen el almacén como un lugar o establecimiento para el almacenamiento de grandes cantidades de productos, para luego ser procesados y enviados en las fechas programadas hacia los clientes. Esto permite mantener un continuo flujo de circulación de mercancías obteniendo ganancias beneficiosas para la empresa. Mientras que el almacén disponga de un eficiente control de productos mantendrá un excelente nivel de servicio. Así mismo, el almacén debe ser un lugar para almacenar inventarios y ser un soporte para facilitar el movimiento de los productos de los proveedores al público objetivo en el tiempo rentable (Richards, 2021).

Tipos de almacén

Según Richards (2021), dependiendo del objetivo del almacén pueden tener diferentes tipos:

- **Materias primas:** Este almacén se encarga de la recepción de materias primas en condiciones estables para luego ser usadas en la fabricación de productos.
- **Instalaciones intermedias:** Este almacén se usa para el almacenamiento temporal de productos en diferentes fases de producción.

- **Productos terminados:** Este almacén solo almacena productos en su fase final para ser puestos en venta.
- **Centros de consolidación, centros de secuenciación y almacenes de tránsito:** Centros que reciben diferentes productos para luego ser combinados y finalmente entregarlos a clientes.
- **Centros de transbordo o desguace:** Este centro recibe grandes cantidades de productos de proveedores para luego ser asignados a diferentes ubicaciones.
- **Centros de cross-dock:** Este centro se enfoca en un rápido control de preparación y envío de productos perecibles como frutas, vegetales o carnes.
- **Centro de clasificación:** Centros utilizados por empresas de paquetería o mensajería para el envío de productos a su destino final según código postal.
- **Centros de cumplimiento:** Este almacén sirve para gestionar grandes volúmenes de productos pequeños.
- **Centro de logística inversa:** Este centro se enfoca en reparar productos y devolverlos al público con el fin de obtener alguna ganancia.
- **Sector público:** Son almacenes enfocados en atender al sector público en casos de desastres naturales, fuerzas armadas o situaciones de alta urgencia.

Procesos de almacén

Según Richards (2021), se describen los principales procesos del almacén:

- **Recepción:** Se encarga de la recepción de los productos con las cantidades respectivas y condiciones correctas en una determinada fecha y hora.
- **Put-away:** Asigna los productos a ubicaciones específicas basados en un análisis que toma en cuenta las dimensiones del producto.
- **Preparación de pedidos:** Su función es la preparación de los productos solicitados en el sistema, basándose en una estrategia eficiente de recorrido y recolección para finalizar en tiempos óptimos.
- **Reabastecimiento:** Se encarga de abastecer las unidades en las ubicaciones de los productos necesarios de acuerdo a la programación establecida.
- **Despacho:** Su función es el envío de las órdenes finalizadas a sus respectivos clientes o cadenas. Es el fin del proceso del almacén.

Warehouse Management System

Debido al incremento de la demanda y exigencia de los clientes se necesita un sistema que permita gestionar todos los procesos del almacén. Por ello, el sistema de control de almacén tiene un funcionamiento similar al ERP, permitiendo hacer seguimiento de los productos desde su recepción hasta su envío del pedido. El WMS tiene la capacidad de ejecutar funciones esenciales del almacén, procesar grandes volúmenes de datos de las transacciones de pedidos y generar informes de monitoreo. Como resultado, se obtiene una trazabilidad de los productos a tiempo real; mejora de la productividad del personal; reducción de errores de empaque y devoluciones de productos; cumplimiento con los clientes y sucursales (Richards, 2021).

2.2.2. Slotting

El termino de Slotting hace referencia en la optimización de la asignación de materias primas, productos o componentes de manera adecuada y eficiente con el objetivo para reducir costos operativos y generar mejores ganancias. El Slotting se encarga de evaluar el producto tomando en cuenta su proyección de la demanda, dimensiones y peso en ubicaciones que cubrirá los días de inventario de acuerdo con las políticas del negocio. Existen diferentes métodos y algoritmos que permite hacer análisis, simulaciones o proyecciones que permite clasificar el producto de acuerdo con sus características permitiendo optimizar el proceso de empaque y reducir costos de mermas o pérdidas de los productos (Duque Jaramillo et al., 2020)

Tipos de Slotting

- **Aleatorio:** El Slotting aleatorio es la asignación del producto hacia a la ubicación al azar tomando en cuenta la experiencia y conocimiento de la persona responsable (Duque Jaramillo et al., 2020).
- **Dedicado:** Implica la asignación de productos a ubicaciones cercanas a la zona de picking, basándose en el método Cube-per-Order-Index (COI) (Duque Jaramillo et al., 2020). El COI optimiza el espacio de almacenamiento al considerar el volumen o la frecuencia de los productos, con el objetivo de asignar los de alta rotación a ubicaciones más accesibles o cercanas en las zonas de picking. Mientras que los productos de baja rotación se almacenan en ubicaciones centrales o finales, minimizando así el tiempo de recorrido y reduciendo los movimientos físicos necesarios para acceder a los productos (Lorenc y Lerher, 2020).
- **Clases:** Implica la categorización de productos en diversas clases, asignadas a ubicaciones específicas según un análisis matemático conocido como el principio de Pareto. El criterio comúnmente consiste en tres categorías principales

denominadas ABC, donde cada letra (A, B y C) representa diferentes porcentajes de la variable de demanda, frecuencia, rotación, volumen o valor de los productos (Aase y Petersen, 2022). En esta clasificación, la categoría 'A' abarca aproximadamente el 80 %, la categoría 'B' contiene alrededor del 15 % y la categoría 'C' incluye el 5 % restante (Rios et al., 2022).

- **Correlacionado:** El almacenamiento correlacionado se basa en agrupar SKUs en "clusters" según sus necesidades correlacionadas, analizando cómo se solicitan juntos en las órdenes de preparación de pedidos y otros criterios. Esta metodología prioriza el picking como criterio para la asignación de espacios en el almacén, considerando no solo el flujo inicial de los productos desde su llegada hasta su ubicación, sino también su recolección y preparación para los pedidos (Duque Jaramillo et al., 2020).

2.2.3. Series temporales

Una serie temporal consiste en una sucesión de datos recopilados en orden cronológico, que refleja observaciones interrelacionadas a lo largo del tiempo. Estos datos históricos permiten identificar tendencias y patrones cíclicos, así como desarrollar modelos predictivos adecuados. Las series temporales son comunes en diversas áreas industriales, utilizadas para anticipar eventos futuros, tales como las predicciones meteorológicas, el comportamiento del mercado de valores, la inflación, la propagación de enfermedades, el mantenimiento predictivo, la gestión de inventarios, entre otras aplicaciones (Kumar Dubey et al., 2021).

Suavizado exponencial

El suavizado exponencial da mayor peso a los datos más recientes y reduce progresivamente la influencia de los datos más antiguos, lo que lo convierte en una herramienta eficaz para detectar cambios en las tendencias de las series temporales y para pronosticar patrones no lineales. A continuación, se mencionan los tipos de suavizado exponencial:

- a) **Método de Holt o Suavizamiento Doble Exponencial:** Es una técnica utilizada en el análisis de datos de series temporales para pronosticar datos que tienen una tendencia o componente estacional. Este método es notable por su eficacia cuando se enfrenta a conjuntos de datos con tendencias complejas que resultan desafiantes para que los métodos convencionales capturen eficientemente, especialmente aquellos que muestran patrones discernibles de crecimiento o declive con el tiempo (Parasian et al., 2020). La aplicación de esta técnica implica la

incorporación de dos coeficientes de suavizado: alfa (α) y beta (β). La fórmula general para el Suavizado Exponencial Doble es:

$$\hat{y}_{t+1} = \alpha \cdot y_t + (1 - \alpha) \cdot (\hat{y}_t + T_t) \quad (1)$$

$$T_{t+1} = \beta \cdot (\hat{y}_{t+1} - \hat{y}_t) + (1 - \beta) \cdot T_t \quad (2)$$

Donde:

- $\hat{y}_{t+1}$ representa el valor de pronóstico para el próximo período.
- y_t representa el valor observado en el período t .
- $\hat{y}_t$ representa el valor de pronóstico en el período t .
- T_{t+1} representa la tendencia estimada para el próximo período
- α representa el coeficiente de suavizado para la componente de nivel ($0 \leq \alpha \leq 1$).
- β representa el coeficiente de suavizado para la componente de tendencia ($0 \leq \beta \leq 1$).

b) **Holt-Winters o Suavizado Triple Exponencial:** Está diseñado para identificar y prever patrones en datos que presentan tendencia y estacionalidad. Resulta altamente efectivo para analizar conjuntos de datos con tendencias claras y patrones estacionales repetitivos. El proceso de suavizado exponencial triple ajusta el nivel, la tendencia y los componentes estacionales en cada ciclo, ofreciendo un enfoque preciso y completo para la predicción de series temporales. La implementación de esta técnica requiere la consideración cuidadosa de tres coeficientes de suavizado: alfa (α), beta (β) y gamma (γ) (Koech et al., 2021). La ecuación de suavizado exponencial triple es el siguiente:

$$\hat{y}_{t+m} = (l_t + m \cdot b_t) \cdot s_{t-m+1} \quad (3)$$

$$l_t = \alpha \cdot \frac{y_t}{s_{t-m}} + (1 - \alpha) \cdot (l_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta \cdot (l_t - l_{t-1}) + (1 - \beta) \cdot b_{t-1} \quad (5)$$

$$s_t = \gamma \cdot \frac{y_t}{l_t} + (1 - \gamma) \cdot s_{t-m} \quad (6)$$

Donde:

- $\hat{y}_{t+m}$ es el valor pronosticado para m períodos hacia adelante.
- l_t representa el componente de nivel en el tiempo t .
- b_t corresponde al componente de tendencia en el tiempo t .
- s_t es el componente estacional en el tiempo t para una estación de duración m .
- y_t es el valor observado en el tiempo t .
- α, β y γ son los coeficientes de suavizado ($0 \leq \alpha, \beta, \gamma \leq 1$).
- m denota la cantidad de estaciones.

Autorregresivo Integrado de Promedio Móvil (Estacional))

SARIMA extiende el enfoque ARIMA al incorporar una componente estacional representada por "S". Este modelo combina tres elementos clave: autorregresión (AR), integración (I) y promedio móvil (MA), lo que lo hace adecuado para pronosticar series temporales que contienen tanto patrones estacionarios como no estacionarios. El término AR captura las dependencias entre las observaciones previas y actuales, el término MA modela las relaciones entre los errores presentes y pasados, mientras que la componente I aplica diferenciación para asegurar que la serie temporal sea estacionaria. La implementación de SARIMA sigue un proceso de cuatro pasos: identificación de las variables y evaluación de la estacionariedad, selección de la mejor combinación entre autorregresión y promedio móvil, elección del modelo óptimo, y finalmente, aplicación del modelo para generar predicciones de futuros valores dentro de un rango de confianza (Huang y Petukhina, 2020). En la formulación estándar de un modelo ARIMA (p, d, q), los parámetros p, d y q representan el orden de los componentes autorregresivos, de diferenciación y de promedio móvil, respectivamente; lo mismo se aplica en SARIMA con la inclusión de los órdenes estacionales correspondientes.

$$\begin{aligned} \text{ARIMA: } y_t = & c + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} \\ & - \theta_1 \cdot e_{t-1} - \theta_2 \cdot e_{t-2} - \dots - \theta_q \cdot e_{t-q} + e_t \end{aligned} \quad (7)$$

$$\begin{aligned}
y_t = & c + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} \\
& + \theta_1 \cdot e_{t-1} + \theta_2 \cdot e_{t-2} + \dots + \theta_q \cdot e_{t-q} \\
\text{SARIMA:} \quad & + \phi_1 \cdot y_{t-s} + \phi_2 \cdot y_{t-2s} + \dots + \phi_P \cdot y_{t-Ps} \\
& - \theta_1 \cdot e_{t-s} - \theta_2 \cdot e_{t-2s} - \dots - \theta_Q \cdot e_{t-Qs} + e_t
\end{aligned} \tag{8}$$

Donde:

- y_t es el valor observado en el tiempo t .
- c es una constante.
- $\phi_1, \phi_2, \dots, \phi_p$ son los parámetros autorregresivos.
- e_t es el error o residuo en t .
- $\theta_1, \theta_2, \dots, \theta_q$ son los parámetros del promedio móvil.
- p es el orden del término autorregresivo.
- d es el orden de la diferenciación.
- q es el orden del término de promedio móvil.
- P es el orden del término autorregresivo estacional.
- D es el orden de la diferenciación estacional.
- Q es el orden del término de promedio móvil estacional.

El algoritmo AutoARIMA selecciona los parámetros p , d y q que ofrecen el mejor ajuste de un modelo ARIMA a un conjunto de datos de series temporales. Para ello, examina varias combinaciones posibles de estos parámetros y escoge el modelo con los valores más bajos de AIC y BIC, lo que implica un balance óptimo entre el ajuste del modelo y su complejidad.

Machine Learning

El aprendizaje automático (ML) es una rama de la inteligencia artificial que permite a las computadoras analizar datos mediante la aplicación de diversos algoritmos de aprendizaje. Las Redes Neuronales Recurrentes (RNN), que forman parte de ML, están diseñadas específicamente para trabajar con datos secuenciales o temporales, utilizando conexiones de retroalimentación para modelar las dependencias a lo largo del tiempo. Tras un proceso de entrenamiento y evaluación, estas redes generan un modelo capaz de predecir eventos futuros o identificar patrones en secuencias de datos (Mahesh, 2020).

- a) **Long Short-Term Memory (LSTM):** Se trata de una red neuronal recurrente capaz de captar dependencias a largo plazo en datos secuenciales, siendo muy eficiente en la predicción de series temporales. Su estructura central puede mantener y actualizar un estado a lo largo del tiempo, lo que le permite almacenar información en secuencias largas, así como decidir qué información retener o desechar (Nabipour et al., 2020). Una celda LSTM consta de tres puertas fundamentales: la puerta de entrada, la puerta de olvido y la puerta de salida. Las operaciones realizadas por la celda LSTM se definen de la siguiente manera:

$$\text{Input Gate } (i_t) = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (9)$$

$$\text{Forget Gate } (f_t) = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (10)$$

$$\text{Candidate cell State } (\tilde{C}_t) = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (11)$$

$$\text{Cell State } (C_t) = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (12)$$

$$\text{Output Gate } (o_t) = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (13)$$

$$\text{Hidden State } (h_t) = o_t \cdot \tanh(C_t) \quad (14)$$

Donde:

- i_t corresponde a la señal de entrada de la puerta de entrada en el instante t .
- f_t es la señal de entrada de la puerta de olvido en el instante t .
- C_t representa el estado de la celda en el instante t .
- $\tilde{C}_t$ es el estado candidato de la celda en el instante t .
- h_t es el estado oculto o salida en el instante t .
- o_t es la señal de entrada de la puerta de salida en el instante t .
- x_t denota la entrada en el instante t .
- W_i, W_f, W_C, W_o son las matrices de pesos, mientras que b_i, b_f, b_C, b_o representan los vectores de sesgo.

- σ es la función sigmoide de activación.
- $\tanh$ es la función de activación basada en la tangente hiperbólica.

Las LSTMs determina el momento adecuado para almacenar información en el estado de la celda (C_t), olvidar datos innecesarios (f_t) y generar salidas (h_t). Esta capacidad de gestionar de manera flexible la memoria hace que las LSTMs sean especialmente útiles para modelar datos de pronóstico en series temporales.

- b) **Gated Recurrent Unit (GRU):** Son una variante especializada de las redes neuronales recurrentes, diseñadas específicamente para modelar y captar dependencias en datos de series temporales, lo que ha llevado a su creciente uso en el análisis de este tipo de datos. Lo que distingue a las GRUs es su habilidad para transmitir y mantener información de manera eficiente a lo largo de múltiples pasos temporales, al mismo tiempo que resuelven el problema del gradiente desvaneciente, que es común en las redes neuronales recurrentes tradicionales (Gao et al., 2020). Las operaciones dentro de una celda GRU se definen de la siguiente manera:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (15)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (16)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t]) \quad (17)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (18)$$

Donde:

- z_t representa la activación de la puerta de actualización en el tiempo t .
- r_t indica la activación de la puerta de reinicio en el tiempo t .
- x_t es el valor de entrada en el tiempo t .
- $\tilde{h}_t$ corresponde al estado oculto candidato en el tiempo t .
- h_t es el estado oculto final (o salida) en el tiempo t .
- W_z, W_r, W_h son las matrices asociadas a los pesos.

Las Unidades GRUs introducen dos puertas clave: la puerta de reinicio r_t y la puerta de actualización z_t , que controlan el paso de información dentro de la celda. La

puerta de actualización decide qué cantidad de información del estado oculto anterior h_{t-1} se conserva, mientras que la puerta de reinicio determina qué parte del estado previo se olvida. La interacción entre la puerta de reinicio y la entrada x_t regula el cálculo del estado oculto candidato $\tilde{h}_t$, el cual se actualiza para formar el nuevo estado oculto. Las GRUs logran un equilibrio efectivo entre la captura de dependencias de largo plazo en las secuencias y la optimización computacional.

2.3. Marco Conceptual

2.3.1. Errores de Predicción

Los errores de predicción son una métrica esencial en el análisis de modelos de pronóstico, ya que cuantifican la discrepancia entre los valores predichos por el modelo y los valores reales observados. Existen diversas maneras de medir y analizar estos errores, cada una con características y aplicaciones específicas. Entre las métricas más comúnmente empleadas se encuentran el Error Absoluto Medio (MAE), que calcula la media de las diferencias absolutas entre las predicciones y los valores reales, proporcionando así una interpretación intuitiva en las mismas unidades que los datos originales. Por otro lado, la Raíz del Error Cuadrático Medio (RMSE) eleva al cuadrado las diferencias, lo que penaliza los errores más significativos, convirtiéndose en una métrica útil cuando se desea dar mayor peso a las grandes desviaciones, aunque su sensibilidad a los outliers puede ser una limitación. El Error Porcentual Absoluto Medio (MAPE) ofrece una perspectiva relativa al expresar los errores como un porcentaje del valor real, lo que facilita la comparación entre diferentes series temporales o modelos; sin embargo, presenta restricciones cuando los valores reales se aproximan a cero. Además de estas métricas, el análisis de los residuales, que son las diferencias entre los valores observados y las predicciones, resulta crucial para comprender la efectividad del modelo; un gráfico de residuales puede revelar patrones no capturados, como tendencias o variaciones estacionales, y ayudar a identificar problemas de heterocedasticidad. La evaluación de los errores de predicción permite medir el rendimiento del modelo y proporciona información valiosa sobre su comportamiento en diferentes contextos, lo que a su vez puede guiar mejoras en el modelo y la selección de métodos de pronóstico más adecuados. En consecuencia, un análisis exhaustivo de los errores de predicción es clave para garantizar que los modelos de pronóstico no solo sean precisos, sino también robustos y capaces de generalizar adecuadamente a datos futuros no observados. Las fórmulas de la métrica son:

- Error Absoluto Medio (MAE)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- Raíz del Error Cuadrático Medio (RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- Error Porcentual Absoluto Medio (MAPE)

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

- Residuales

$$e_i = y_i - \hat{y}_i$$

2.3.2. Gráficos de Residuales

Los gráficos de residuales son herramientas visuales esenciales en el análisis de modelos de pronóstico, ya que permiten evaluar la adecuación del modelo a los datos observados. Estos gráficos muestran las diferencias entre los valores reales y las predicciones, facilitando la identificación de patrones que pueden indicar problemas en el ajuste del modelo. Un gráfico de residuales bien elaborado presenta los residuos en el eje vertical y los valores predichos o el tiempo en el eje horizontal. Un patrón aleatorio en la dispersión de los residuales, como el mostrado en la Figura 1, sugiere que el modelo ha capturado adecuadamente la relación entre las variables. En el gráfico, se observa que los puntos azules se distribuyen de manera dispersa y aleatoria alrededor de la línea horizontal de cero (la línea roja), sin seguir ninguna forma o tendencia específica. Esta distribución aleatoria es la señal clave de que el modelo es adecuado. Sin embargo, la presencia de patrones sistemáticos, como tendencias o estacionalidades, puede indicar que el modelo no ha capturado correctamente las características subyacentes de los datos. Además, los gráficos de residuales pueden ser utilizados para verificar supuestos importantes, como la homocedasticidad (constancia de la varianza de los errores) y la normalidad de los residuos. En consecuencia, el análisis de los gráficos de residuales no solo contribuye a evaluar el rendimiento del modelo, sino que también proporciona información valiosa para su ajuste y mejora. Al interpretar adecuadamente estos gráficos, los investigadores pueden tomar decisiones informadas sobre la selección de métodos de pronóstico más apropiados y realizar

ajustes necesarios para optimizar el rendimiento del modelo.





Figura 1

Gráfico residual

Fuente. Elaboración propia.

2.3.3. Pruebas de Estacionariedad

Las pruebas de estacionariedad son procedimientos estadísticos fundamentales en el análisis de series temporales, ya que permiten determinar si una serie presenta propiedades estadísticas constantes a lo largo del tiempo. Una serie temporal es considerada estacionaria si sus características, como la media, la varianza y la autocovarianza, son invariantes respecto al tiempo. La estacionariedad es un supuesto clave en muchos modelos de pronóstico, como los modelos ARIMA, que requieren que los datos sean estacionarios para garantizar la validez de sus estimaciones y predicciones. Existen diversas pruebas para evaluar la estacionariedad, entre las que destacan la prueba de Dickey-Fuller aumentada (ADF), la prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) y la prueba de Phillips-Perron (PP). La prueba ADF, por ejemplo, evalúa la presencia de raíces unitarias en una serie temporal, proporcionando un estadístico que se compara con valores críticos para determinar la estacionariedad. En la Figura 2 muestra un ejemplo de una serie con una tendencia creciente (línea azul), donde el valor p del estadístico ADF (0.998) es mayor que cualquier nivel de significancia común (0.05 o 0.01). Este resultado indica que la serie del ejemplo no es estacionaria y, por lo tanto, tiene una raíz unitaria. La correcta identificación de la estacionariedad es crucial, ya que, si se utilizan modelos inadecuados en series no estacionarias, se corre el riesgo de obtener estimaciones engañosas y pronósticos poco fiables. En consecuencia, las pruebas de estacionariedad constituyen una herramienta esencial para la validación de modelos en el análisis de series temporales, asegurando que las inferencias realizadas sean robustas y confiables.

**Figura 2***Gráfico de prueba de Dickey-Fuller**Fuente. Elaboración propia.*

2.3.4. Intervalos de Confianza

Los intervalos de confianza son herramientas estadísticas que permiten estimar el rango dentro del cual se espera que se encuentre un parámetro poblacional, con un nivel de confianza específico, comúnmente del 90 %, 95 % o 99 %. Estos intervalos se construyen a partir de datos muestrales y proporcionan un marco para evaluar la incertidumbre inherente a cualquier estimación. Un intervalo de confianza del 95 %, por ejemplo, indica que, si se repitieran múltiples muestreos y se calcularan intervalos para cada uno, aproximadamente el 95 % de esos intervalos contendrían el verdadero valor del parámetro. La amplitud del intervalo está influenciada por el tamaño de la muestra, la variabilidad de los datos y el nivel de confianza seleccionado; intervalos más amplios reflejan mayor incertidumbre, mientras que intervalos más estrechos indican estimaciones más precisas. En la Figura 3 muestra un ejemplo de un intervalo de confianza del 95 % alrededor de la media, la línea azul discontinua representa la media de los datos, mientras que las líneas verdes y rojas delimitadas por las líneas punteadas marcan los límites superior e inferior del intervalo de confianza. La mayoría de los puntos de los datos se encuentran dentro de este rango, lo que visualmente apoya la estimación del 95 % de confianza. En la práctica, la construcción de estos intervalos puede llevarse a cabo utilizando distribuciones estadísticas como la normal o la t de Student, dependiendo de las características de los datos y del tamaño de la muestra.




Figura 3

Gráfico de intervalo de confianza

Fuente. Elaboración propia.

2.4. Glosario

- **Redes Neuronales Recurrentes:** Son un tipo de red neuronal diseñadas para procesar datos secuenciales, utilizando conexiones de retroalimentación para modelar dependencias temporales en la información.
- **Seasonal Autoregressive Integrated Moving Average:** Es un modelo de series temporales que combina componentes autorregresivos, de media móvil y de diferenciación, incluyendo ajustes estacionales para capturar patrones temporales en los datos.
- **PARETO ABC:** Es una técnica de clasificación que segmenta los productos o elementos en tres categorías (A, B y C) según su impacto en el volumen de ventas o su valor, siguiendo el principio de Pareto, que establece que el 80 % de los resultados provienen del 20 % de los esfuerzos.
- **Centro de Distribución:** Es una instalación logística que se utiliza para almacenar productos y gestionar su distribución a minoristas o clientes finales, optimizando la eficiencia en el manejo y transporte de mercancías.
- **Almacén:** Es un espacio físico destinado al almacenamiento de bienes y productos, donde se realizan actividades como la recepción, almacenamiento y despacho de mercancías.

- **Preparación de Pedidos:** Es el proceso logístico que implica seleccionar y agrupar productos de inventario para cumplir con un pedido específico de un cliente, asegurando que se recojan y empaquen correctamente.
- **Picking:** Es la actividad de seleccionar y extraer productos del inventario en un almacén para preparar pedidos, utilizando diversas estrategias y métodos para maximizar la eficiencia.
- **Pronóstico:** Es el proceso de estimar o predecir la demanda futura de productos o servicios basándose en datos históricos, patrones observados y métodos estadísticos, con el fin de optimizar la planificación y gestión de inventarios.
- **Slotting:** Proceso de asignación de productos a ubicaciones específicas dentro de un almacén.
- **Cube-per-Order-Index:** Método de optimización del espacio de almacenamiento basándose en el volumen o frecuencia de los productos.
- **Suavizamiento Exponencial:** Técnica de análisis de series temporales que enfatiza datos recientes para identificar cambios en tendencias.
- **AutoARIMA:** Algoritmo de previsión automatizado que integra modelos ARIMA y SARIMA para datos univariantes.
- **Long Short-Term Memory:** Red neuronal recurrente que captura dependencias a largo plazo en datos secuenciales.
- **Gated Recurrent Unit:** Variante de las redes neuronales recurrentes que modela dependencias en datos de series temporales.
- **Mean Absolute Percentage Error:** Métrica de error utilizada para evaluar la precisión de modelos de previsión.

Capítulo III

METODOLOGÍA

3.1. Tipo de la Investigación

La investigación es de tipo aplicada porque tiene como propósito fundamental utilizar conocimientos teóricos y metodológicos de las ciencias de la computación para desarrollar una solución práctica a un problema real del ámbito logístico. Esta aplicación directa de modelos computacionales busca optimizar la precisión de las predicciones y mejorar la asignación de ubicaciones de almacenamiento, demostrando la transferencia del conocimiento científico hacia la práctica operativa (Wohlin et al., 2012).

3.2. Diseño de la Investigación

El diseño de la investigación es experimental, propio de las Ciencias de la Computación, orientado a la evaluación comparativa de algoritmos predictivos. El estudio se estructura mediante la implementación y análisis de diversos métodos de pronóstico aplicados sobre un mismo conjunto de datos históricos de demanda. Cada modelo se desarrolla, entrena y evalúa bajo condiciones controladas y métricas comunes de desempeño, lo que permite contrastar objetivamente su precisión y capacidad de generalización (Wohlin et al., 2012).

3.3. Nivel de la Investigación

El nivel de la investigación es explicativo, ya que analiza la relación entre los métodos de pronóstico utilizados y la precisión de los resultados obtenidos, con el fin de explicar cómo la integración de métodos estadísticos y redes neuronales recurrentes influye en la toma de decisiones para la asignación de ubicaciones de almacenamiento (Wohlin et al., 2012).

3.4. Dataset y Partición

3.4.1. Dataset

El dataset utilizado en este estudio proviene de un centro de distribución mayorista de productos farmacéuticos. Se recopiló información histórica de 50 productos desde enero de 2016 hasta julio de 2023, obteniendo un total de 91 registros para cada producto.

3.4.2. Partición

El conjunto de datos está dividido en dos partes: un subconjunto de **entrenamiento** y otro de **prueba**. Se utilizarán 84 de los 91 registros disponibles para el entrenamiento de los modelos de pronóstico. Este conjunto de entrenamiento se emplea para ajustar y optimizar los parámetros de los modelos, permitiéndoles aprender patrones relevantes y relaciones presentes en los datos históricos. Por otro lado, los 7 registros restantes se reservarán para la evaluación. Esta metodología permite comparar las predicciones obtenidas por los distintos métodos con los valores reales observados.

3.5. Operacionalización de Variables

3.5.1. Identificación de Variables

Variable Independiente

Nombre: Información histórica

Definición conceptual: Los datos históricos de demanda corresponden al conjunto de registros cronológicos que contienen información pasada sobre el comportamiento de la demanda de los productos en un periodo determinado. Estos datos reflejan patrones, tendencias y variaciones temporales que sirven como base para el análisis y la generación de pronósticos mediante modelos estadísticos y redes neuronales recurrentes.

Definición de operacionalidad: Los datos históricos de demanda se operacionalizan mediante series temporales de demanda registradas periódicamente.

Dimensión: Series de tiempo.

Variable Dependiente

Nombre: Pronóstico

Definición conceptual: El pronóstico se refiere al proceso de estimación de valores futuros de la demanda a partir del análisis de los datos históricos, mediante la aplicación de modelos estadísticos y redes neuronales recurrentes, con el fin de anticipar el comportamiento esperado de la demanda.

Definición de operacionalidad: La variable pronóstico se operacionaliza a través de los valores estimados por los modelos de pronóstico, los cuales son comparados con los valores reales observados de la demanda para su evaluación mediante métricas de error.

Dimensión: Rango de precisión del pronóstico.

Tabla 1*Descripción de variables y métodos utilizados*

Variable	Tipo de variable	Definición conceptual	Definición de operacionalidad	Dimensiones	Indicador	Método de Medición
Información histórica	Independiente	Los datos históricos de demanda corresponden al conjunto de registros cronológicos que contienen información pasada sobre el comportamiento de la demanda de los productos en un periodo determinado. Estos datos reflejan patrones, tendencias y variaciones temporales que sirven como base para el análisis y la generación de pronósticos mediante modelos estadísticos y redes neuronales recurrentes.	Los datos históricos de demanda se operacionalizan mediante series temporales de demanda registradas periódicamente.	Series de tiempo	Número de registros históricos	Base de datos histórica
Pronóstico	Dependiente	El pronóstico se refiere al proceso de estimación de valores futuros de la demanda a partir del análisis de los datos históricos, mediante la aplicación de modelos estadísticos y redes neuronales recurrentes, con el fin de anticipar el comportamiento esperado de la demanda.	La variable pronóstico se operacionaliza a través de los valores estimados por los modelos de pronóstico, los cuales son comparados con los valores reales observados de la demanda para su evaluación mediante métricas de error.	Calidad del pronóstico	■ Error Medio ■ Error Absoluto ■ Error Porcentual Medio ■ Tiempo de Ejecución	■ Escala Intervalo ■ Escala Razón

Fuente. Elaboración propia.

3.5.2. Descripción de Dimensiones e Indicadores de Variables

Dimensión: Series de tiempo

Indicadores: Número de registros históricos: cantidad total de observaciones disponibles en la serie temporal de demanda, utilizadas como insumo para el análisis y la aplicación de los modelos de pronóstico.

Dimensión: Precisión del pronóstico.

Indicadores: Error Absoluto Porcentual Medio (MAPE), métrica que evalúa el grado de cercanía entre los valores pronosticados y los valores reales observados de la demanda, permitiendo medir la exactitud de los modelos de pronóstico.

Dimensión: Sesgo del pronóstico.

Indicadores: Error Medio (ME), indicador que permite identificar si un modelo de pronóstico presenta una tendencia sistemática a sobreestimar o subestimar los valores reales de la demanda.

Dimensión: Tiempo de ejecución.

Indicadores: Tiempo promedio de ejecución por producto, medido desde el inicio hasta la finalización del proceso de generación del pronóstico para cada método aplicado.

3.6. Criterios de Evaluación del Desempeño de los Modelos de Pronóstico

En este estudio, la evaluación de los modelos de pronóstico se realizó utilizando la métrica del Error Porcentual Absoluto Medio (MAPE). El análisis se fundamentó en los criterios establecidos en el estudio de referencia Vivas et al. (2020), el cual proporciona directrices para la clasificación de los intervalos de MAPE. Estos intervalos se detallan en la Tabla 2. Para el presente trabajo, se establece que, para que un modelo de pronóstico sea considerado adecuado, al menos el 80 % de los productos evaluados deben presentar un MAPE inferior al 20 %, lo que indica una capacidad de predicción buena. Adicionalmente, se permite que hasta un 20 % de los productos puedan tener un MAPE superior al 20 %, sin comprometer la validez general del modelo. Por otro lado, si más del 10 % del total de productos evaluados supera el umbral de MAPE del 50 %, el modelo se considera inadecuado para la aplicación propuesta. Este criterio garantiza un nivel de confiabilidad en los resultados obtenidos, minimizando el impacto de predicciones con alto margen de error. La expresión matemática que define el MAPE es

la siguiente:

Tabla 2

Criterio de evaluación de MAPE

MAPE (%)	Interpretación de Predicción
<10	pronóstico excelente
10 - 20	pronóstico bueno
20 - 50	pronóstico aceptable
>50	pronóstico deficiente

Fuente: Elaboración propia.

Capítulo IV

FASE IMPLEMENTACIÓN

4.1. Análisis del Dataset *ProductForecastData*

Previo a la fase experimental, se llevó a cabo un análisis exhaustivo de los datos contenidos en el conjunto de datos *ProductForecastData* correspondiente a los pedidos históricos. Este análisis incluyó una revisión detallada de las características clave como el código del producto, las unidades de orden y las fechas de registro. Este enfoque garantiza que la selección de productos y las metodologías de pronóstico a aplicar sean fundamentadas y relevantes, optimizando así la calidad y fiabilidad de los resultados obtenidos en la fase experimental. Las variables identificadas no solo servirán para la matriz de operacionalización de variables Tabla 1 sino que también permitirán un entendimiento más profundo del comportamiento de la demanda, facilitando la aplicación de técnicas de pronóstico efectivas y adecuadas a las particularidades del conjunto de datos.

4.1.1. Ventajas del Uso del Dataset de Productos

- El tamaño del conjunto de datos es suficiente para realizar análisis estadísticos y de machine learning sin comprometer el rendimiento computacional. Este volumen permite capturar tendencias significativas y comportamientos del mercado, facilitando el desarrollo de modelos predictivos más precisos.
- La variable FECHA proporciona una dimensión temporal esencial para el análisis de series de tiempo. Esta característica permite identificar tendencias, estacionalidades y ciclos en la demanda, lo cual es crucial para la planificación de inventarios y la anticipación de cambios en el comportamiento del consumidor.
- La diversidad de registros permite identificar comportamientos anómalos o inesperados en las ventas, lo que puede ser indicativo de problemas en la cadena de suministro, cambios en la demanda del mercado o la efectividad de campañas

promocionales. Esta capacidad de detección es crucial para la toma de decisiones informadas y la mejora continua de procesos.

- La diversidad de registros permite identificar comportamientos anómalos o inesperados en las ventas, lo que puede ser indicativo de problemas en la cadena de suministro, cambios en la demanda del mercado o la efectividad de campañas promocionales. Esta capacidad de detección es crucial para la toma de decisiones informadas y la mejora continua de procesos.
- El conjunto de datos permite realizar análisis más avanzados, como segmentación de clientes y análisis de cohortes, brindando una comprensión más profunda de los patrones de compra y las preferencias del consumidor. Esto puede ser especialmente útil para diseñar estrategias de marketing más efectivas.

4.1.2. Desventajas del Uso del Dataset de Productos

- La representatividad de la muestra puede ser limitada, especialmente si los datos no abarcan una variedad suficiente de productos y periodos. Esto puede afectar la generalización de los resultados.
- La distribución de la columna UND-ORDEN muestra una variabilidad significativa, con algunas órdenes que alcanzan valores extremos. Esto puede llevar a un desbalance en el modelo de pronóstico, dificultando la clasificación adecuada de los datos.
- El rango de fechas abarca desde 2018 hasta 2023, lo que puede implicar que los patrones de demanda no sean representativos de tendencias más amplias o que estén influenciados por eventos específicos. Esto podría limitar la capacidad del modelo para generalizar sobre futuros comportamientos de la demanda.
- El dataset no considera factores externos que pueden influir en las decisiones de compra y la demanda de productos, como cambios en el mercado, estacionalidad, promociones o situaciones económicas. Esta falta de variables contextuales puede limitar la precisión de los pronósticos generados.

4.2. Presentación de Modelo Propuesto

En esta sección, se proporciona una descripción exhaustiva del modelo propuesto para mejorar el proceso de asignación de ubicaciones de productos. Iniciamos con una presentación de las diferentes etapas del modelo, acompañada de una explicación detallada del enfoque integrado. Además, se incluye un análisis pormenorizado de las

principales actividades, las cuales están ilustradas en la Figura 4. Las funciones del modelo se explican en profundidad en la Tabla 3, lo que facilita la comprensión del papel de cada componente en el proceso de optimización.




Figura 4

Modelo de Slotting utilizando métodos estadísticos y redes neuronales

Fuente. Elaboración propia.

4.2.1. Entrada

La sección “Entrada” tiene una función fundamental al suministrar los datos históricos necesarios para el funcionamiento eficiente del centro de distribución o almacén. Durante esta etapa, se recopila información detallada sobre los productos, su historial de pedidos y las ubicaciones dentro del almacén. Usualmente, es imprescindible establecer una conexión con el sistema histórico del almacén para obtener los datos requeridos para su procesamiento posterior. Asimismo, es fundamental realizar una evaluación rigurosa del alcance y la calidad de los datos históricos. Establecer correctamente el rango de los datos históricos es esencial para asegurar que la información recopilada sea representativa y adecuada para los análisis subsiguientes.

4.2.2. Procesamiento

Esta sección, conocida como “Procesamiento”, se encarga de procesar los datos en el Datamart y se divide en tres subsecciones:

Procesamiento de Datos

La fase de procesamiento de datos consta de tres elementos clave. Primero, el componente “Ubicaciones de Información”, que guarda datos esenciales sobre las ubicaciones dentro del centro de distribución, tales como dimensiones, tipos de instalaciones y clasificación. En segundo lugar, “Información de Productos” contiene detalles como las dimensiones de las cajas, peso, categoría y cualquier característica especial relevante para el almacenamiento. Por último, “Historial de Pedidos” desempeña un papel fundamental, ya que resume la información sobre los pedidos realizados durante el mes, calculando los totales mensuales por producto a partir de las unidades diarias obtenidas. En casos donde falten datos de algún mes, se aplican métodos de imputación para completar los registros faltantes, tal como se ilustra en la Figura 5.




Figura 5


Características del procesamiento de datos de muestra

Fuente. Elaboración propia.

Procesamiento Estadístico y Aprendizaje Automático

En primer lugar, en la fase de “Selección de datos”, se eligen de manera secuencial los registros de productos que ya han sido agrupados por mes para su posterior proce-

samiento. Este paso es fundamental, ya que asegura que los datos sean pertinentes y estén debidamente organizados antes de su análisis. En segundo lugar, en la etapa de “Modelado de métodos”, se aplican los métodos analíticos previamente seleccionados utilizando los datos elegidos como conjunto para el análisis. La aplicación de estas técnicas permite una comprensión más detallada de la información recopilada y facilita la generación de pronósticos más precisos, los cuales son esenciales para la toma de decisiones en el centro de distribución. En tercer lugar, en la fase de “Evaluación de la métrica de error”, se analizan los resultados de los pronósticos obtenidos mediante los métodos analíticos, utilizando la métrica MAPE (Error Porcentual Absoluto Medio). Este análisis proporciona una medida cuantitativa de la exactitud de los pronósticos, lo que refuerza considerablemente la confiabilidad del modelo analítico. Un valor más bajo de MAPE indica una mayor precisión del modelo, lo cual es esencial para la correcta planificación y gestión de inventarios. Finalmente, en la actividad de “Selección del modelo de pronóstico”, se lleva a cabo un análisis exhaustivo de los resultados obtenidos a través de la métrica de error MAPE. En este paso, se priorizan los métodos que arrojan los valores de error más bajos, ya que estos indican una mayor capacidad predictiva. Como se muestra en la Figura 6, cuando varios métodos presentan valores de error inferiores al 10 % para distintos productos, se considera la opción de combinarlos con el fin de optimizar los resultados. Esta estrategia de combinación no solo potencia la precisión de los pronósticos, sino que también ofrece mayor flexibilidad en la gestión del inventario y en la capacidad de adaptación a las fluctuaciones en la demanda del mercado.

**Figura 6**

Características del procesamiento de Procesamiento Estadístico y Aprendizaje Automático

Fuente. Elaboración propia.

Procesamiento de Resultado

En la etapa de “Zonas de Selección” se recogen datos detallados sobre las áreas de almacenamiento, las cuales se definen según las características de los productos y las directrices del centro de distribución. Esta recopilación de datos es crucial para optimizar el espacio disponible y mejorar la eficiencia en el proceso de selección de productos. El “Peso ABC” ofrece parámetros clave que facilitan la determinación del nivel adecuado para el almacenamiento de productos. Esto no solo busca maximizar el uso del espacio vertical, sino que también tiene como objetivo prevenir accidentes que puedan involucrar al personal encargado de la selección, garantizando un ambiente de trabajo más seguro. Asimismo, la clasificación de los productos en la “Familia ABC” posibilita agrupar aquellos de características similares en una misma zona, optimizando así la gestión del inventario y acelerando el proceso de picking. Finalmente, el “Pronóstico de Productos” es esencial para evaluar la demanda anticipada de productos para la próxima temporada. Este análisis ayuda a los responsables de la toma de decisiones a determinar si es necesario reubicar productos en otras ubicaciones que puedan satisfacer de manera más efectiva los requisitos de demanda de unidades. Este proceso no solo optimiza el flujo de trabajo en el centro de distribución, sino que tam-

bién asegura que los productos estén disponibles donde más se necesitan, mejorando la satisfacción del cliente. Todo esto se ilustra de manera más detallada en la Figura 7.





Figura 7

Características de Procesamiento de Resultado

Fuente. Elaboración propia.

4.2.3. Salida

En esta fase, el operador comienza el proceso de toma de decisiones, el cual consiste en evaluar la mejor opción de acción para cada producto. Esto podría implicar mover el producto a una ubicación diferente dentro del almacén o ampliar el número de espacios de almacenamiento disponibles. Las decisiones se basan en los conocimientos obtenidos del análisis de resultados, considerando aspectos como las zonas de selección, el peso ABC, la clasificación de productos en familias ABC y las previsiones de demanda de productos, como se muestra en la Figura 8. Este enfoque permite al gerente tomar decisiones fundamentadas que optimizan la distribución de los productos y permiten una mejor respuesta ante las variaciones de la demanda, lo que contribuye a una gestión de inventarios más eficiente y una mayor adaptabilidad a las fluctuaciones del mercado.

**Figura 8**

Características del proceso de toma de decisiones

Fuente. Elaboración propia.

4.2.4. Infraestructura tecnológica

Esta sección proporciona soporte tecnológico a las tres áreas previamente mencionadas, que incluyen: el almacenamiento histórico dentro del centro de distribución, el uso de herramientas ETL (Extracción, Transformación y Carga) para migrar datos clave y su posterior almacenamiento en un Data Mart. Luego de la selección de datos en el proceso de aprendizaje automático, la ejecución se realiza en el entorno de Google Colab. Este enfoque integrado asegura una transferencia eficiente de información y optimiza los procesos de aprendizaje automático, lo que facilita la obtención de información valiosa a partir de los datos y mejora la toma de decisiones en la gestión de inventarios y en la optimización de recursos.

Tabla 3
Descripción de los procesos

Partes	Procesos	Características
Entrada	Fuentes de Datos	Base de datos de pedidos de productos.
		Base de datos con especificaciones de las cajas de productos, incluyendo medidas y peso.
		Base de datos de información sobre las ubicaciones de almacenamiento: medidas y características de las ubicaciones dentro del almacén.
Procesamiento	Procesamiento de Datos	Filtrado y limpieza de los registros de pedidos.
		Datos relevantes de los productos.
		Información sobre las ubicaciones de almacenamiento.
	Procesamiento Estadístico y de Aprendizaje Automático	Selección de un conjunto de datos adecuado para realizar análisis detallados o procesamiento.
		Aplicación del modelo analítico sobre el conjunto de datos seleccionado.
		Cálculo y análisis de métricas de error, comparando previsiones con valores reales.
		Selección del mejor modelo de predicción en función de su precisión en las métricas de error.
	Procesamiento de Resultados	Capacidad de almacenamiento de productos en las ubicaciones específicas dentro del almacén.
		Clasificación del producto según su peso y ubicación en el almacén.
		Clasificación de los productos según su tipo y ubicación dentro del almacén.
		Estimación de la demanda futura de los productos en función de los datos históricos.
Resultado	Proceso de Decisión	Toma de decisiones sobre la ubicación y almacenamiento de los productos, basado en el análisis de resultados.

Fuente. Elaboración propia.

4.3. Implementación de los modelos de Suavización Exponencial

El objetivo específico es demostrar que la implementación de técnicas de suavización exponencial doble y triple proporcionará pronósticos más precisos en comparación con métodos. Para ello, se compararán los resultados de varios modelos de suavización exponencial aplicados a un conjunto de datos de series temporales. En este análisis, se considerarán diferentes configuraciones, tales como la suavización exponencial doble y la suavización exponencial triple, asegurando que se evalúen las capacidades predictivas de cada técnica en función de la variabilidad y el comportamiento de los datos.

A continuación, se presenta la función `predict_using_smoothexponential`, que implementa estas técnicas de suavización en Python:

```

1 def predict_using_smoothexponential(df, n_output):
2     sku = df['ID'].unique()
3     pronosticos_smoothexponential = pd.DataFrame(columns=['ID', '
    COD_SKU_SAP', 'UND_ORDEN', 'HWES2_ADD', 'HWES2_MUL', '

```

```

HWES3_MM', 'HWES3_MA', 'HWES3_AM', 'HWES3_AA'])

4
5 for n in sku:
6     nuevo = df[df['ID'] == n]
7     total_reg = len(nuevo)
8
9     train = nuevo[:total_reg - n_output]
10    test = nuevo[total_reg - n_output:]
11
12
13    model_HWES2_MUL = ExponentialSmoothing(train['UND_ORDEN'],
14                                             trend='mul').fit(optimized=True)
15    model_HWES2_ADD = ExponentialSmoothing(train['UND_ORDEN'],
16                                             trend='add').fit(optimized=True)
17    sm_exp3_mm = ExponentialSmoothing(train['UND_ORDEN'], trend=
18                                     'mul', seasonal='mul', seasonal_periods=12).fit(optimized
19                                     =True)
20    sm_exp3_ma = ExponentialSmoothing(train['UND_ORDEN'], trend=
21                                     'mul', seasonal='add', seasonal_periods=12).fit(optimized
22                                     =True)
23    sm_exp3_am = ExponentialSmoothing(train['UND_ORDEN'], trend=
24                                     'add', seasonal='mul', seasonal_periods=12).fit(optimized
25                                     =True)
26    sm_exp3_aa = ExponentialSmoothing(train['UND_ORDEN'], trend=
27                                     'add', seasonal='add', seasonal_periods=12).fit(optimized
28                                     =True)
29
30    COD_SKU_SAP_value = test.loc[test['ID'] == n, 'COD_SKU_SAP']
31    ].tolist()
32    und_orden = test.loc[test['ID'] == n, 'UND_ORDEN'].tolist()
33
34    pronosticos_temp = pd.DataFrame({
35        'ID': [n] * len(model_HWES2_ADD.forecast(n_output)),
36        'COD_SKU_SAP': COD_SKU_SAP_value,
37        'UND_ORDEN': und_orden,
38        'HWES2_ADD': model_HWES2_ADD.forecast(n_output),
39        'HWES2_MUL': model_HWES2_MUL.forecast(n_output),
40        'HWES3_MM': pd.Series(sm_exp3_mm.forecast(n_output)),
41        'HWES3_MA': pd.Series(sm_exp3_ma.forecast(n_output)),
42        'HWES3_AM': pd.Series(sm_exp3_am.forecast(n_output)),
43        'HWES3_AA': pd.Series(sm_exp3_aa.forecast(n_output))
44    })
45
46    pronosticos_smoothexponential = pd.concat([
47        pronosticos_smoothexponential, pronosticos_temp],
48        ignore_index=True)
49
50
51
52
53
54
55
56

```

```
37         return pronosticos_smoothexponential
```

Listing IV.1: Función predict_using_smoothexponential

La función `predict_using_smoothexponential` implementa técnicas de suavización exponencial para predecir la demanda futura de productos específicos identificados por un SKU. Al inicio, la función identifica todos los SKU únicos en el conjunto de datos proporcionado, permitiendo así procesar cada producto de forma independiente. Para cada SKU, extrae los datos históricos de demanda, dividiéndolos en un conjunto de entrenamiento y un conjunto de prueba, reservando las últimas observaciones para evaluar el rendimiento de los modelos de pronóstico. Luego, el código entrena varios modelos de suavización exponencial en el conjunto de entrenamiento para capturar patrones de tendencia y estacionalidad específicos de la demanda de cada SKU. Los modelos incluyen suavización exponencial doble con tendencias aditiva y multiplicativa (HWES2_ADD y HWES2_MUL), así como modelos de triple suavización que combinan tendencias y estacionalidades en formas aditivas y multiplicativas (HWES3_MM, HWES3_MA, HWES3_AM y HWES3_AA). Estos modelos se ajustan automáticamente a los datos de entrenamiento, optimizando los parámetros para representar de manera precisa las variaciones en la demanda. La función genera pronósticos para un número determinado de períodos futuros (`n_output`) para cada SKU y almacena estos pronósticos en un DataFrame temporal junto con la información del SKU, los valores reales de demanda y los períodos de pronóstico. Este enfoque permite organizar los pronósticos de cada modelo de suavización de forma que se puedan evaluar y comparar con los datos reales del período de prueba, facilitando la interpretación de los resultados y la comparación de los métodos. Finalmente, los pronósticos de todos los SKU se consolidan en un DataFrame principal, `pronosticos_smoothexponential`, que se devuelve como resultado de la función. Este DataFrame contiene los pronósticos generados por cada modelo de suavización exponencial, lo que facilita la evaluación de cuál de estos enfoques es más efectivo para modelar la demanda de productos. En resumen, la función permite comparar múltiples enfoques de suavización exponencial y determinar cuál es el más adecuado para pronosticar series de tiempo de demanda de productos.

Luego, se toman los datos de pronóstico para evaluar la precisión utilizando métricas de error:

```
1 metric_error_MAPE = pd.DataFrame(columns=[ 'ID' , 'COD_SKU_SAP' , '
      HWES2_ADD' , 'HWES2_MUL' , 'HWES3_MM' , 'HWES3_MA' , 'HWES3_AM' , 'HWES3_AA
      ' ])
2
3 sku = pronosticos_smoothexponential[ 'ID' ].unique()
4
5 for n in sku:
```

```

6      nuevo = pronosticos_smoothexponential[
          pronosticos_smoothexponential['ID'] == n]
7
8      test = nuevo["UND_ORDEN"]
9      sm_exp2_add = nuevo['HWES2_ADD']
10     sm_exp2_mul = nuevo['HWES2_MUL']
11     sm_exp3_mm = nuevo['HWES3_MM']
12     sm_exp3_ma = nuevo['HWES3_MA']
13     sm_exp3_am = nuevo['HWES3_AM']
14     sm_exp3_aa = nuevo['HWES3_AA']
15
16     COD_SKU_SAP_value = nuevo.loc[nuevo['ID'] == n, 'COD_SKU_SAP'].
        unique()
17
18     metric_error_MAPE_temp = pd.DataFrame({
19         'ID': [n],
20         'COD_SKU_SAP': COD_SKU_SAP_value,
21         'HWES2_ADD': MAPE(test, sm_exp2_add),
22         'HWES2_MUL': MAPE(test, sm_exp2_mul),
23         'HWES3_MM': MAPE(test, sm_exp3_mm),
24         'HWES3_MA': MAPE(test, sm_exp3_ma),
25         'HWES3_AM': MAPE(test, sm_exp3_am),
26         'HWES3_AA': MAPE(test, sm_exp3_aa)
27     })
28
29     metric_error_MAPE = pd.concat([metric_error_MAPE,
        metric_error_MAPE_temp], ignore_index=True)
30
31
32 metric_error_MAPE

```

Listing IV.2: Metrica error MAPE

4.4. Implementación del modelo Autorregresivo Integrado de Promedio Móvil (Estacionalidad)

El objetivo específico es demostrar que la implementación del Modelo Autorregresivo Integrado de Media Móvil con o sin Estacional permitirá obtener pronósticos más precisos en series temporales. Para ello, se realizarán comparaciones entre el modelo SARIMA y ARIMA. En este análisis, se considerarán diferentes configuraciones del modelo, ajustando los parámetros de autorregresión, integración, media móvil con o sin estacionalidad, con el fin de evaluar la capacidad predictiva en función de la variabilidad y las tendencias estacionales de los datos.

La primera actividad es verificar la estacionariedad de las series temporales asocia-

das a diferentes productos (SKU) en el conjunto de datos y aplicar transformaciones de diferenciación para lograr una serie estacionaria que es requisito fundamental para el modelo de (S)ARIMA. Para cada SKU, el proceso comienza aplicando una primera diferenciación a los datos de demanda (UND_ORDEN), generando una serie diferenciada y utilizando la prueba de Dickey-Fuller (ADF) para verificar si esta serie es estacionaria. Si el resultado de la prueba ADF muestra que la serie sigue siendo no estacionaria con un p-valor mayor a 0.05, se aplica una segunda diferenciación. En caso de que la serie continúe sin ser estacionaria, se realiza una tercera diferenciación. Una vez determinada la transformación necesaria para alcanzar la estacionariedad, los resultados se almacenan en una lista, incluyendo el SKU, el nivel de diferenciación aplicado y el p-valor de la prueba ADF. Finalmente, se crea un DataFrame con estos resultados y se añade una columna al DataFrame original indicando el método de diferenciación utilizado para cada SKU, facilitando así la identificación de la técnica necesaria para cada serie temporal en el conjunto de datos. El tiempo total de ejecución fue de 45 minutos, lo cual se considera regular para esta evaluación.

A continuación, se presenta la función `predict_using_smoothexponential`, que implementa estas técnicas de suavización en Python:

```

1  import pandas as pd
2  from statsmodels.tsa.stattools import adfuller
3
4  # Lista para almacenar los resultados de la diferenciacion
5  resultados_diferenciacion = []
6
7  # Iterar sobre cada SKU
8  for n, nuevo in df.groupby('ID'):
9      COD_SKU_SAP_value = nuevo['COD_SKU_SAP'].unique()
10
11     # Metodo 1: Diferencia
12     nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff()
13     serie_temporal = nuevo['serie_estacionaria'].dropna()
14
15     # Aplicar la prueba de Dickey-Fuller
16     resultado_adf = adfuller(serie_temporal)
17
18     # Determinar si la serie es estacionaria
19     estacionariedad = "Estacionaria" if resultado_adf[1] <= 0.05
20     else "NoEstacionaria"
21     metodo_utilizado = "Diferencia"
22
23     # Metodo 2: Doble Diferencia
24     if estacionariedad == "NoEstacionaria":
25         nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff().diff

```

```

    ()
25     serie_temporal = nuevo['serie_estacionaria'].dropna()
26     resultado_adf = adfuller(serie_temporal)
27     estacionariedad = "Estacionaria" if resultado_adf[1] <= 0.05
        else "NoEstacionaria"
28     metodo_utilizado = "DobleDiferencia"
29
30     # Metodo 3: Triple Diferencia
31     if estacionariedad == "NoEstacionaria":
32         nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff().diff()
            ().diff()
33         serie_temporal = nuevo['serie_estacionaria'].dropna()
34         resultado_adf = adfuller(serie_temporal)
35         estacionariedad = "Estacionaria" if resultado_adf[1] <= 0.05
            else "NoEstacionaria"
36         metodo_utilizado = "TripleDiferencia"
37
38     # Agregar los resultados a la lista
39     resultados_diferenciacion.append({
40         'ID': n,
41         'COD_SKU_SAP': COD_SKU_SAP_value[0], # Usar el primer valor
            unico
42         'ESTACIONARIEDAD': estacionariedad,
43         'METODO_UTILIZADO': metodo_utilizado,
44         'RESULTADO_ADF': '{:.6f}'.format(resultado_adf[1])
45     })
46
47     # Crear el DataFrame final
48     Diferenciacion = pd.DataFrame(resultados_diferenciacion)
49
50     # Agregar columna al DataFrame original indicando el tipo de metodo
        de diferenciacion
51     df['TIPO_METODO_DIFERENCIACION'] = df.apply(lambda x: Diferenciacion
        .loc[Diferenciacion['ID'] == x['ID'], 'METODO_UTILIZADO'].values
        [0], axis=1)

```

Listing IV.3: Código en Python para verificar estacionariedad

Este código en Python implementa un proceso de pronóstico de demanda utilizando modelos (S)ARIMA, adaptado a diferentes niveles de diferenciación de series temporales según la estacionariedad de los datos de cada producto. Inicialmente, se identifican los distintos SKU en el conjunto de datos y se recorre cada uno individualmente.

Posteriormente, se emplea la función `auto_arima`, que ajusta automáticamente el

orden del modelo y selecciona el mejor conjunto de parámetros de (S)ARIMA y su estacionalidad para cada serie temporal. Una vez definidos estos parámetros, el modelo (S)ARIMA es entrenado utilizando los datos históricos de la demanda. Tras ajustar el modelo, se generan pronósticos para los próximos siete períodos, aplicando una reversión de la diferenciación para que los valores previstos reflejen la demanda en su escala original. Finalmente, los resultados son organizados en un nuevo DataFrame que consolida, para cada SKU, tanto los valores reales de la demanda como los pronósticos generados y los parámetros del modelo (S)ARIMA utilizado. Este procedimiento permite evaluar y analizar la precisión de los pronósticos en relación con las observaciones reales, proporcionando una base robusta para la comparación de modelos en el análisis de series temporales para cada producto.

A continuación, se presenta la programación que implementa estas técnicas de ARIMA y SARIMA en Python:

```
1 sku = df['ID'].unique()
2 pronosticos_sarima = pd.DataFrame(columns=['ID', 'COD_SKU_SAP', 'UND_ORDEN', 'AR', 'I', 'MA', 'SO_AR', 'SO_D', 'SO_MA', 'SARIMA'])
3
4 for n in sku:
5     nuevo = df[df['ID'] == n]
6
7     COD_SKU_SAP_value = nuevo.loc[nuevo['ID'] == n, 'COD_SKU_SAP'].unique()
8
9     # Aplicar el tipo de diferenciacion adecuado
10    if 'Diferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].values:
11        nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff()
12    elif 'DobleDiferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].values:
13        nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff().diff()
14    elif 'TripleDiferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].values:
15        nuevo['serie_estacionaria'] = nuevo['UND_ORDEN'].diff().diff().diff()
16
17    # Ajustar modelo auto_arima para encontrar los mejores parametros
18    model_auto2 = auto_arima(nuevo.serie_estacionaria.dropna(), m=12, max_order=None, max_p=9, max_q=9, max_d=2, max_P=5, max_Q=5, max_D=3,
19                               maxiter=60, alpha=0.05, n_jobs=-1, trend='ct', information_criterion='')
```

```

                                oob', out_of_sample_size=7)

20
21 # Asignar los parametros del modelo
22 ar = model_auto2.order[0]
23 i = model_auto2.order[1]
24 ma = model_auto2.order[2]
25 so_ar = model_auto2.seasonal_order[0]
26 so_d = model_auto2.seasonal_order[1]
27 so_ma = model_auto2.seasonal_order[2]
28
29 # Entrenar el modelo SARIMA con los parametros seleccionados
30 model = SARIMAX(
31     nuevo.serie_estacionaria[: -7].dropna(),
32     order=(ar, i, ma),
33     seasonal_order=(so_ar, so_d, so_ma, 12)
34 )
35 result = model.fit()
36
37 # Obtener los valores de UND_ORDEN y las fechas
38 und_orden = df.loc[df['ID'] == n, 'UND_ORDEN'].tolist()
39 fecha = nuevo.index.tolist()
40
41 # Invertir la diferenciacion segun el tipo de metodo
42 if 'Diferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].values:
43     result_forecast = und_orden[-1] + np.cumsum(result.forecast(
44         steps=7))
45 elif 'DobleDiferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].
46     values:
47     result_forecast = und_orden[-1] + np.cumsum(np.cumsum(result
48         .forecast(steps=7)))
49 elif 'TripleDiferencia' in nuevo['TIPO_METODO_DIFERENCIACION'].
50     values:
51     result_forecast = und_orden[-1] + np.cumsum(np.cumsum(np.
52         cumsum(result.forecast(steps=7))))
53
54 # Crear DataFrame temporal con los pronosticos
55 pronosticos_temp = pd.DataFrame({
56     'ID': [n] * 7,
57     'COD_SKU_SAP': COD_SKU_SAP_value[0],
58     'UND_ORDEN': und_orden[-7:], # Selecciona los ultimos 7
59         valores de UND_ORDEN
60     'FECHA': fecha[-7:], # Selecciona las ultimas 7 fechas
61     'AR': ar,
62     'I': i,
63     'MA': ma,
64     'SO_AR': so_ar,
65     'SO_D': so_d,

```

```

60         'SO_MA': so_ma,
61         'SARIMA': result_forecast
62     })
63
64     # Concatenar los pronósticos al DataFrame principal
65     pronosticos_sarima = pd.concat([pronosticos_temp,
        pronosticos_sarima], ignore_index=True)

```

Listing IV.4: Código en Python usando el metodo de (S)ARIMA

Una vez obtenidos los pronósticos, se evalúa el rendimiento del modelo (S)ARIMA en la predicción de la demanda de productos a nivel de SKU. La métrica empleada es el error porcentual absoluto medio, que ofrece una medida de la precisión relativa de los pronósticos generados.

Inicialmente, el código crea un DataFrame vacío, `metric_error_MAPE`, con columnas para almacenar los identificadores de cada SKU, el código de producto `COD_SKU_SAP`, y el valor de error `SARIMA_MAPE`. Posteriormente, el código obtiene una lista de SKU únicos a partir del DataFrame `pronosticos_sarima`, que contiene los pronósticos del modelo (S)ARIMA junto con las observaciones reales.

Para cada SKU, el código extrae los datos de prueba y los pronósticos generados por el modelo (S)ARIMA. Luego, se calcula el MAPE entre la demanda real y el pronóstico de (S)ARIMA para cada SKU, y se almacena en un DataFrame temporal junto con el identificador del producto, el código de SKU, y los parámetros del modelo (S)ARIMA: AR (Autorregresivo), I (integrado), MA (media móvil), y los parámetros estacionales `SO_AR`, `SO_D` y `SO_MA`.

Finalmente, el DataFrame `metric_error_MAPE` se concatena para formar `resumen_metricas_error_SARIMA`, un resumen que agrupa todos los errores de cada SKU. En este resumen, se genera la columna `MET_SARIMA`, que representa la configuración completa del modelo (S)ARIMA en formato `(AR,I,MA)(SO_AR,SO_D,SO_MA,12)`, donde 12 indica la periodicidad estacional. Este resumen final permite comparar la precisión de diferentes configuraciones de (S)ARIMA para cada SKU, facilitando la selección de la parametrización más adecuada para el pronóstico de demanda.

```

1 metric_error_MAPE = pd.DataFrame(columns=['ID', 'COD_SKU_SAP', '
    SARIMA_MAPE'])
2
3 sku = pronosticos_sarima['ID'].unique()
4
5 for n in sku:
6     nuevo = pronosticos_sarima[pronosticos_sarima['ID'] == n]
7
8     test=nuevo["UND_ORDEN"]

```

```

9     sarima=nuevo[ 'SARIMA' ]
10
11     COD_SKU_SAP_value = nuevo.loc[nuevo[ 'ID' ] == n, 'COD_SKU_SAP' ].
        unique()
12
13     metric_error_MAPE_temp = pd.DataFrame({
14         'ID': [n] ,
15         'COD_SKU_SAP': COD_SKU_SAP_value,
16         'SARIMA_MAPE': MAPE( test , sarima) ,
17         'AR': nuevo[ 'AR' ].unique() ,
18         'I': nuevo[ 'I' ].unique() ,
19         'MA': nuevo[ 'MA' ].unique() ,
20         'SO_AR': nuevo[ 'SO_AR' ].unique() ,
21         'SO_D': nuevo[ 'SO_D' ].unique() ,
22         'SO_MA': nuevo[ 'SO_MA' ].unique()
23     })
24
25     metric_error_MAPE =pd.concat([ metric_error_MAPE_temp ,
        metric_error_MAPE], ignore_index=True)
26
27
28
29     resumen_metricas_error_SARIMA =metric_error_MAPE
30
31     resumen_metricas_error_SARIMA[ 'MET_SARIMA' ]=' (' +
        resumen_metricas_error_SARIMA[ 'AR' ].astype( str)  + ', '+
        resumen_metricas_error_SARIMA[ 'I' ].astype( str)  + ', '+
        resumen_metricas_error_SARIMA[ 'MA' ].astype( str) + ') (' +
        resumen_metricas_error_SARIMA[ 'SO_AR' ].astype( str) + ', '+
        resumen_metricas_error_SARIMA[ 'SO_D' ].astype( str) + ', '+
        resumen_metricas_error_SARIMA[ 'SO_MA' ].astype( str) + ',12)'
32
33     resumen_metricas_error_SARIMA

```

Listing IV.5: Métrica de error (S)ARIMA

4.5. Implementación del modelo de Memoria a Largo y Corto Plazo

El objetivo específico de esta sección es demostrar la eficacia del modelo de Red Neuronal Recurrente de Memoria a Largo Plazo (LSTM) en la obtención de pronósticos más precisos en series temporales. Se considerarán diferentes configuraciones del modelo LSTM, ajustando sus hiperparámetros y arquitecturas para capturar las complejas relaciones y patrones no lineales en los datos. Esta investigación se enfocará en

cómo el LSTM maneja la variabilidad y las tendencias estacionales de las series temporales, proporcionando así una visión más robusta y fiable para la toma de decisiones en la planificación de la demanda.

Este código implementa un modelo de Redes Neuronales con Memoria a Largo Corto Plazo (LSTM) para predecir la demanda de productos a nivel de SKU, basándose en un conjunto de datos de órdenes anteriores. Inicialmente, se establece una semilla aleatoria (`seed_value`) para garantizar la reproducibilidad de los resultados en varias ejecuciones, y se define un DataFrame vacío `pronosticos_rn_lstm` para almacenar las predicciones del modelo.

Para cada SKU en la lista, el código filtra el DataFrame original para obtener los datos específicos de dicho SKU, luego los divide en conjuntos de entrenamiento y prueba según la longitud total de registros y el número de períodos de predicción deseado (`n_output`). Los datos de entrenamiento se escalan utilizando el método `MinMaxScaler` para mejorar la eficiencia del modelo LSTM, y se generan secuencias de series de tiempo mediante `TimeseriesGenerator`, que transforma los datos en un formato adecuado para el entrenamiento del modelo.

El modelo LSTM se configura con una capa LSTM de 100 unidades y activación ReLU, seguida de una capa densa. Se compila utilizando el optimizador Adam y una función de pérdida de error cuadrático medio (`mse`). Tras entrenarse en los datos de entrenamiento durante el número de épocas especificado (`n_epochs`), el modelo genera predicciones sobre los datos de prueba.

Para realizar la predicción en múltiples pasos, el código utiliza un lote de evaluación inicial (`first_eval_batch`) y realiza una iteración en la que el modelo genera un valor de pronóstico que se utiliza como entrada para el siguiente paso. Este proceso se repite hasta obtener todos los pronósticos para el conjunto de prueba. Las predicciones escaladas se convierten a su escala original mediante el inverso del escalador, y se añaden al DataFrame test junto con el identificador del SKU, código del producto y fecha de orden.

Finalmente, el código concatena los resultados de todos los SKU en el DataFrame `pronosticos_rn_lstm`, establece `FECHA_ORDEN` como índice y devuelve el conjunto de pronósticos completos para la demanda de cada producto. A continuación, se detalla el código de `predict_using_lstm`:

```

1  seed_value = 42
2
3  def predict_using_lstm(df, n_output, n_epochs):
4      # Configuración de las semillas aleatorias para reproducibilidad
5      random.seed(seed_value)
6      np.random.seed(seed_value)
7      tf.random.set_seed(seed_value)
8

```

```

9      # DataFrame para almacenar los pronosticos generados
10     pronosticos_rn_lstm = pd.DataFrame(columns=['ID', 'COD_SKU_SAP',
11         'UND_ORDEN', 'LSTM'])
12
13     # Lista de SKU unicos en el DataFrame de entrada
14     sku_list = df['ID'].unique()
15
16     for n in sku_list:
17         # Filtrado de datos por SKU
18         nuevo = df[df['ID'] == n]
19         total_reg = len(nuevo)
20
21         # Extraccion de datos necesarios para el pronostico
22         COD_SKU_SAP = nuevo[['COD_SKU_SAP']][total_reg - n_output:]
23         ID = nuevo[['ID']][total_reg - n_output:]
24         FECHA_ORDEN = nuevo.index[total_reg - n_output:]
25
26         # Division en datos de entrenamiento y prueba
27         nuevo = nuevo[['UND_ORDEN']]
28         train = nuevo[:total_reg - n_output]
29         test = nuevo[total_reg - n_output:]
30
31         # Escalado de los datos de entrenamiento y prueba
32         scaler = MinMaxScaler()
33         scaler.fit(train)
34         scaled_train = scaler.transform(train)
35         scaled_test = scaler.transform(test)
36
37         # Generador de series temporales
38         generator = TimeseriesGenerator(scaled_train, scaled_train,
39             length=n_output, batch_size=1)
40         X, y = generator[0]
41
42         n_features = 1
43
44         # Definicion y configuracion del modelo LSTM
45         model = Sequential()
46         model.add(LSTM(100, activation='relu', input_shape=(n_output
47             , n_features)))
48         model.add(Dense(1))
49         model.compile(optimizer='adam', loss='mse')
50         model.fit(generator, epochs=n_epochs)
51
52         # Preparacion del primer lote de evaluacion y generacion de
53         predicciones
54         first_eval_batch = scaled_train[-n_output:]
55         first_eval_batch = first_eval_batch.reshape((1, n_output,

```

```

        n_features))
52 predictions = []
53
54 current_batch = first_eval_batch.copy()
55
56 for i in range(len(test)):
57     current_pred = model.predict(current_batch)[0]
58     predictions.append(current_pred)
59     current_batch = np.append(current_batch[:, 1:, :], [[
        current_pred]], axis=1)
60
61     # Inversion del escalado de las predicciones para
        # interpretabilidad
62 true_predictions = scaler.inverse_transform(predictions)
63
64     # Agregado de las predicciones al DataFrame de prueba
65 test['ID'] = ID
66 test['COD_SKU_SAP'] = COD_SKU_SAP
67 test['FECHA_ORDEN'] = FECHA_ORDEN
68 test['LSTM'] = true_predictions
69
70     # Concatenacion de resultados
71 pronosticos_rn_lstm = pd.concat([pronosticos_rn_lstm, test])
72
73     # Establecimiento de 'FECHA_ORDEN' como indice del DataFrame
        # final
74 pronosticos_rn_lstm.set_index('FECHA_ORDEN', inplace=True)
75
76 return pronosticos_rn_lstm

```

Listing IV.6: Función predict_using_lstm en Python

Una vez obtenidos los pronósticos, se calcula el error de predicción para cada producto utilizando el índice MAPE. Se inicializa un DataFrame vacío, `metric_error_MAPE`, que tendrá las columnas 'ID', 'COD_SKU_SAP' y 'LSTM'. Este DataFrame se usará para almacenar el error calculado para cada producto, basado en la comparación entre las cantidades reales y las predicciones generadas por el modelo LSTM.

En primer lugar, el código obtiene todos los valores únicos de la columna 'ID' en el DataFrame `pronosticos_rn`, representando los distintos productos para los cuales se calculará el error. Luego, se inicia un ciclo for para iterar sobre cada valor único de 'ID'. En cada iteración, se filtra el DataFrame `pronosticos_rn` para obtener solo las filas correspondientes al producto actual, creando así un nuevo DataFrame llamado `nuevo`.

Para cada producto, el código extrae las cantidades reales de pedidos, almacenadas en la columna 'UND_ORDEN', y las predicciones generadas por el modelo LSTM, almacenadas en la columna 'LSTM'. Además, se obtiene el valor único de

'COD_SKU_SAP', que identifica el producto en el sistema, utilizando el valor correspondiente del DataFrame filtrado.

El siguiente paso consiste en calcular el error MAPE entre las cantidades reales y las predicciones de LSTM para el producto actual. Este valor se almacena junto con el identificador del producto y su código SKU en un DataFrame temporal, `metric_error_MAPE_temp`. A continuación, esta fila temporal se agrega al DataFrame principal `metric_error_MAPE` mediante la función `append()`. Este proceso se repite para cada producto en la lista de productos únicos.

Al finalizar el ciclo, el DataFrame `metric_error_MAPE` contiene el error MAPE para cada producto, con las columnas correspondientes a 'ID', 'COD_SKU_SAP' y el valor calculado de LSTM. El resultado final es un DataFrame que proporciona una visión detallada del desempeño del modelo LSTM en términos de su error de predicción para cada producto. A continuación, se detalla el código de MAPE para LSTM:

```

1
2  metric_error_MAPE = pd.DataFrame(columns=['ID', 'COD_SKU_SAP', 'LSTM'
3      ])
4  sku = pronosticos_rn['ID'].unique()
5
6  for n in sku:
7      nuevo = pronosticos_rn[pronosticos_rn['ID'] == n]
8
9      test=nuevo["UND_ORDEN"]
10
11     rn_lstm=nuevo['LSTM']
12
13     COD_SKU_SAP_value = nuevo.loc[nuevo['ID'] == n, 'COD_SKU_SAP'].
14         unique()
15
16     metric_error_MAPE_temp = pd.DataFrame({
17         'ID': [n] ,
18         'COD_SKU_SAP': COD_SKU_SAP_value,
19         'LSTM': MAPE(test , rn_lstm )
20     })
21     metric_error_MAPE = metric_error_MAPE.append(
22         metric_error_MAPE_temp , ignore_index=True)
23 metric_error_MAPE

```

Listing IV.7: Código de MAPE de LSTM

4.6. Implementación del modelo de Unidad Recurrente con Puertas

El objetivo de esta sección es evaluar la efectividad del modelo de Red Neuronal Recurrente Gated Recurrent Unit (GRU) en la predicción precisa de series temporales. A través de diferentes configuraciones y ajustes de los hiperparámetros, se busca determinar cómo el GRU puede captar patrones no lineales y relaciones complejas en los datos históricos de demanda. Este análisis se centrará en la capacidad del GRU para manejar la variabilidad estacional y las fluctuaciones de los datos a lo largo del tiempo, lo que permitirá una mejora significativa en los pronósticos y proporcionará una herramienta más robusta y fiable para la toma de decisiones en la gestión de la demanda de productos.

En este código se implementa un modelo de Red Neuronal Recurrente basado en la arquitectura Gated Recurrent Unit (GRU) para la predicción de series temporales de demanda de productos. La función `predict_using_gru` toma como parámetros un DataFrame `df` con los datos de entrada, el número de entradas (`n_input`) y las épocas de entrenamiento (`n_epochs`). Primero, se establece una semilla aleatoria para asegurar la reproducibilidad de los resultados en la generación de números aleatorios y en la configuración de la red neuronal.

Dentro de la función, se crea un DataFrame vacío `pronosticos_rn_gru` para almacenar los resultados de los pronósticos, con columnas como `'ID'`, `'COD_SKU_SAP'`, `'UND_ORDEN'`, y `'GRU'`. Luego, se itera sobre cada SKU único en los datos de entrada para realizar la predicción individualmente para cada uno. Para cada SKU, se divide el conjunto de datos en dos partes: una para entrenamiento y otra para prueba, y se normalizan utilizando el `MinMaxScaler` para escalar los valores entre 0 y 1, lo que mejora el rendimiento del modelo.

A continuación, se utiliza la clase `TimeseriesGenerator` para crear los lotes de datos secuenciales necesarios para el entrenamiento de la red neuronal. Se define una red neuronal secuencial en la que se emplea una capa GRU con 100 unidades y una activación `ReLU`, seguida de una capa densa que predice un único valor. El modelo se compila utilizando el optimizador `'adam'` y el error cuadrático medio (MSE) como función de pérdida. Posteriormente, el modelo se entrena durante el número especificado de épocas (`n_epochs`) usando los datos de entrenamiento.

Después de entrenar el modelo, se realizan las predicciones sobre el conjunto de prueba. Para cada paso, se hace una predicción utilizando el modelo entrenado, y la predicción se agrega a las predicciones previas. Finalmente, las predicciones se desescalan utilizando el inverso del escalador y se incorporan al DataFrame de prueba, que también contiene las columnas `'ID'`, `'COD_SKU_SAP'` y `'FECHA_ORDEN'`.

Al finalizar el proceso de predicción para todos los SKUs, el DataFrame `pronos-`

ticos_rn_gru contiene los resultados finales y se establece el índice a la columna 'FECHA_ORDEN'. El resultado final es un DataFrame con los pronósticos generados por el modelo GRU para cada SKU y sus respectivas fechas. A continuación, se detalla el código de predict_using_gru:

```

1
2 seed_value = 42
3
4 def predict_using_gru(df, n_input, n_epochs):
5     random.seed(seed_value)
6     np.random.seed(seed_value)
7     tf.random.set_seed(seed_value)
8     pronosticos_rn_gru = pd.DataFrame(columns=['ID', 'COD_SKU_SAP', '
        UND_ORDEN', 'GRU'])
9
10    sku_list = df['ID'].unique()
11
12    for n in sku_list:
13
14        nuevo = df[df['ID'] == n]
15        total_reg = len(nuevo)
16        ID = nuevo[['ID']][total_reg - n_input:]
17        COD_SKU_SAP = nuevo[['COD_SKU_SAP']][total_reg - n_input:]
18        FECHA_ORDEN = nuevo.index[total_reg - n_input:]
19
20        nuevo = nuevo[['UND_ORDEN']]
21        train = nuevo[:total_reg - n_input]
22        test = nuevo[total_reg - n_input:]
23
24        scaler = MinMaxScaler()
25        scaler.fit(train)
26
27        scaled_train = scaler.transform(train)
28        scaled_test = scaler.transform(test)
29
30        generator = TimeseriesGenerator(scaled_train, scaled_train,
            length=n_input, batch_size=1)
31        X, y = generator[0]
32
33        n_features = 1
34
35        model = Sequential()
36        model.add(GRU(100, activation='relu', input_shape=(n_input,
            n_features)))
37        model.add(Dense(1))
38        model.compile(optimizer='adam', loss='mse')
39        model.fit_generator(generator, epochs=n_epochs)

```

```

40
41     first_eval_batch = scaled_train[-n_input:]
42     first_eval_batch = first_eval_batch.reshape((1, n_input,
43         n_features))
44     predictions = []
45
46     current_batch = first_eval_batch.copy()
47
48     for i in range(len(test)):
49         current_pred = model.predict(current_batch)[0]
50         predictions.append(current_pred)
51         current_batch = np.append(current_batch[:, 1:, :], [[
52             current_pred]], axis=1)
53
54     true_predictions = scaler.inverse_transform(predictions)
55
56     test['ID'] = ID
57     test['GRU'] = true_predictions
58     test['COD_SKU_SAP'] = COD_SKU_SAP
59     test['FECHA_ORDEN'] = FECHA_ORDEN
60
61     pronosticos_rn_gru = pd.concat([pronosticos_rn_gru, test])
62
63     pronosticos_rn_gru.set_index('FECHA_ORDEN', inplace=True)
64
65     return pronosticos_rn_gru

```

Listing IV.8: Función predict_using_gru en Python

Una vez obtenidos los pronósticos, se calcula el error de predicción para cada producto utilizando el índice MAPE. Se inicializa un DataFrame vacío, `metric_error_MAPE`, que tendrá las columnas 'ID', 'COD_SKU_SAP' y 'GRU'. Este DataFrame se usará para almacenar el error calculado para cada producto, basado en la comparación entre las cantidades reales y las predicciones generadas por el modelo GRU.

En primer lugar, el código obtiene todos los valores únicos de la columna 'ID' en el DataFrame `pronosticos_rn`, representando los distintos productos para los cuales se calculará el error. Luego, se inicia un ciclo for para iterar sobre cada valor único de 'ID'. En cada iteración, se filtra el DataFrame `pronosticos_rn` para obtener solo las filas correspondientes al producto actual, creando así un nuevo DataFrame llamado `nuevo`.

Para cada producto, el código extrae las cantidades reales de pedidos, almacenadas en la columna 'UND_ORDEN', y las predicciones generadas por el modelo GRU, almacenadas en la columna 'GRU'. Además, se obtiene el valor único de 'COD_SKU_SAP', que identifica el producto en el sistema, utilizando el valor correspondiente del DataFrame filtrado.

El siguiente paso consiste en calcular el error MAPE entre las cantidades reales

y las predicciones de GRU para el producto actual. Este valor se almacena junto con el identificador del producto y su código SKU en un DataFrame temporal, `metric_error_MAPE_temp`. A continuación, esta fila temporal se agrega al DataFrame principal `metric_error_MAPE` mediante la función `append()`. Este proceso se repite para cada producto en la lista de productos únicos.

Al finalizar el ciclo, el DataFrame `metric_error_MAPE` contiene el error MAPE para cada producto, con las columnas correspondientes a `'ID'`, `'COD_SKU_SAP'` y el valor calculado de GRU. El resultado final es un DataFrame que proporciona una visión detallada del desempeño del modelo GRU en términos de su error de predicción para cada producto. A continuación, se detalla el código de MAPE para GRU:

```

1
2
3 metric_error_MAPE = pd.DataFrame(columns=[ 'ID' , 'COD_SKU_SAP' , 'GRU' ])
4
5 sku = pronosticos_rn[ 'ID' ].unique()
6
7 for n in sku:
8     nuevo = pronosticos_rn[pronosticos_rn[ 'ID' ] == n]
9
10    test=nuevo[ "UND_ORDEN" ]
11
12    rn_gru=nuevo[ 'GRU' ]
13
14    COD_SKU_SAP_value = nuevo.loc[ nuevo[ 'ID' ] == n, 'COD_SKU_SAP' ].
        unique()
15
16
17    metric_error_MAPE_temp = pd.DataFrame({
18        'ID': [n] ,
19        'COD_SKU_SAP': COD_SKU_SAP_value ,
20        'GRU': MAPE( test , rn_gru )
21    })
22    metric_error_MAPE = metric_error_MAPE.append(
        metric_error_MAPE_temp , ignore_index=True)
23
24
25 metric_error_MAPE

```

Listing IV.9: Código de MAPE de GRU

Capítulo V

RESULTADOS

5.1. Objetivo Específico 1: Suavizaciones Exponenciales

Los resultados obtenidos del pronóstico utilizando el conjunto de datos analizado en la Tabla 4 revelan patrones significativos en la serie temporal de órdenes. A través de la implementación de modelos de suavización exponencial, se logró proyectar la demanda de productos para un período de 7 meses. Para el producto SKU 42, los pronósticos muestran un aumento constante en la demanda de enero a julio. Los modelos HWES2_ADD y HWES2_MUL presentan valores relativamente cercanos entre sí, pero se observa una diferencia significativa cuando se comparan con los modelos HWES3_MM, HWES3_MA, HWES3 AM y HWES3 AA. Este comportamiento sugiere que los modelos HWES podrían estar sobreestimando la demanda en los últimos meses, especialmente con los modelos más complejos como HWES3. La precisión del pronóstico depende de cómo se ajusten los parámetros de los modelos, por lo que se puede considerar que la predicción es razonablemente buena para los primeros meses, pero los modelos más complejos podrían necesitar ajustes para evitar sobreestimaciones. En el caso del producto SKU 389, el pronóstico muestra una tendencia de aumento moderado en la demanda desde enero hasta julio. Las predicciones de los modelos HWES2_ADD y HWES2_MUL son bastante consistentes, lo que sugiere estabilidad y fiabilidad en los pronósticos. Sin embargo, el modelo HWES3_MM presenta algunas fluctuaciones notables, especialmente en los meses de mayor demanda, lo que indica que este modelo podría no estar capturando correctamente las tendencias de los datos. Aunque la precisión es aceptable, el modelo HWES3 podría requerir ajustes para mejorar su desempeño. Finalmente, para el producto SKU 464, las predicciones muestran una variabilidad más amplia en comparación con los otros productos. Este comportamiento refleja que la demanda es más volátil, y los modelos están capturando diferentes aspectos de esta variabilidad. Mientras que los modelos HWES2_ADD y

HWES2_MUL tienden a generar predicciones más altas, los modelos HWES3_MM, HWES3_MA, HWES3_AM y HWES3_AA presentan resultados más estables. La amplia diferencia en los pronósticos podría indicar que algunos modelos no se están ajustando bien a la variabilidad de la demanda del producto. Aunque los resultados generales muestran una tendencia de crecimiento, la predicción es menos precisa debido a la mayor fluctuación en los datos. El tiempo total de ejecución fue de 13 minutos, lo cual se considera óptimo para esta evaluación.

Tabla 4*Resultados de Pronósticos: Suavizaciones Exponenciales Dobles y Triples*

SKU	UND ORDEN	MES	HWES2_ADD	HWES2_MUL	HWES3_MM	HWES3_MA	HWES3_AM	HWES3_AA	SESGO HWES2_ADD	SESGO HWES2_MUL	SESGO HWES3_MM	SESGO HWES3_MA	SESGO HWES3_AM	SESGO HWES3_AA
42	136	1	135.51	134.2	145.66	151.66	149.26	144.29	0.49	-133.2	-10.15	-17.46	-3.6	7.37
42	112	2	136.81	134.93	161.93	156.78	161.5	146.01	-24.81	-132.93	-25.12	-21.85	0.43	10.77
42	122	3	138.11	135.67	219.48	171.69	212.86	157.44	-16.11	-132.67	-81.37	-36.02	6.62	14.25
42	156	4	139.41	136.41	244.36	187.84	246.01	170.02	16.59	-132.41	-104.95	-51.43	-1.65	17.82
42	146	5	140.71	137.16	265.76	195.27	268.76	173.73	5.29	-132.16	-125.05	-58.11	-3	21.54
42	118	6	142.01	137.91	314.31	201.51	314.05	176.01	-24.01	-131.91	-172.3	-63.6	0.26	25.5
42	128	7	143.32	138.67	183.89	182.79	184	153.99	-15.32	-131.67	-40.57	-44.12	-0.11	28.8
389	141	1	110.22	111.46	116.86	115.02	116.54	114.93	30.78	-110.46	-6.64	-3.56	0.32	0.09
389	132	2	111.23	112.82	115.61	114.93	115.04	114.78	20.77	-110.82	-4.38	-2.11	0.57	0.15
389	130	3	112.24	114.19	127.1	122.69	126.09	122.5	17.76	-111.19	-14.86	-8.5	1.01	0.19
389	146	4	113.25	115.59	111	113.32	109.96	113.05	32.75	-111.59	2.25	2.27	1.04	0.27
389	136	5	114.26	117	106.81	111.68	105.65	111.35	21.74	-112	7.45	5.32	1.16	0.33
389	132	6	115.26	118.43	123.23	119.73	121.46	119.34	16.74	-112.43	-7.97	-1.3	1.77	0.39
389	138	7	116.27	119.87	107.58	113.2	106.08	112.79	21.73	-112.87	8.69	6.67	1.5	0.41
464	114	1	152.37	156.2	291.01	167.25	184	170.73	-38.37	-155.2	-138.64	-11.05	107.01	-3.48
464	117	2	153.73	160.4	125.83	133	145.14	138.95	-36.73	-158.4	27.9	27.4	-19.31	-5.95
464	166	3	155.09	164.71	249.22	153.24	198.04	161.86	10.91	-161.71	-94.13	11.47	51.18	-8.62
464	169	4	156.46	169.14	306.9	171.69	307.54	183.39	12.54	-165.14	-150.44	-2.55	-0.64	-11.7
464	169	5	157.82	173.69	349.1	158.31	236.23	171.52	11.18	-168.69	-191.28	15.38	112.87	-13.21
464	165	6	159.18	178.36	298.83	151.96	195.32	165.68	5.82	-172.36	-139.65	26.4	103.51	-13.72
464	163	7	160.54	183.16	382.57	192.25	320.28	211.82	2.46	-176.16	-222.03	-9.09	62.29	-19.57

Fuente. Elaboración propia.

Se aplicó el procedimiento para evaluar las métricas de error MAPE en la Tabla 5, en las predicciones realizadas utilizando los métodos de suavización exponencial. La tabla presenta los resultados obtenidos para cada método, incluyendo las columnas HWES2_ADD, HWES2_MUL, HWES3_MM, HWES3_MA, HWES3_AM y HWES3_AA, que reflejan el rendimiento de los modelos en relación con los diferentes identificadores de producto SKU. Los valores en cada celda representan la magnitud del MAPE, donde un valor más bajo indica un mejor desempeño del modelo en términos de precisión de la predicción. Se observa que ciertos SKU presentan errores significativamente más altos en determinadas metodologías, como el SKU 464, que muestra un MAPE elevado en varios métodos, lo que sugiere dificultades particulares en la predicción de este producto. En contraste, el SKU 485 tiene métricas de error notablemente más bajas, lo que indica que los modelos se ajustan mejor a los datos de este producto.

Tabla 5


Resultados de MAPE: Suavizaciones Exponenciales Dobles y Triples

SKU	HWES2_ADD	HWES2_MUL	HWES3_MM	HWES3_MA	HWES3_AM	HWES3_AA
4	0.29473883	0.32407304	0.47290344	0.31425391	0.30506323	0.25442121
6	0.12889457	0.10507545	0.11573829	0.13503107	0.10967966	0.12862658
18	0.1303665	0.15524887	0.23961876	0.15814559	0.31049321	0.15062534
42	0.1175562	0.10975066	0.68612565	0.3713688	0.68585199	0.23278202
389	0.16868157	0.15123429	0.15128362	0.14930762	0.15902518	0.15122292
464	0.12956658	0.14030669	0.88133208	0.14548658	0.48768225	0.15913031
485	0.13590735	0.07170524	0.053801	0.07024871	0.06736591	0.05857643
543	0.18935969	0.21869796	0.27892144	0.18924295	0.22407217	0.14365319
854	0.12898095	0.12152025	0.10827334	0.10859143	0.13538893	0.13701144
994	0.05348411	0.06143441	0.11169215	0.09430318	0.10294966	0.08588101
1126	0.15182948	0.25097722	0.26091378	0.21850788	0.18142348	0.15073257
1180	0.09683906	0.11472907	0.25729701	0.17645228	0.22560675	0.17338984
1203	0.0965938	0.15808187	0.20248981	0.17394307	0.1472017	0.12380798
1269	0.15294614	0.11950361	0.28738654	0.20601602	0.30690137	0.23180608
1329	0.17143244	0.24348396	0.09042313	0.12736923	0.08856068	0.12336962


Fuente. Elaboración propia.

La Figura 9 muestra un conjunto de gráficos comparativos que representan los pronósticos de demanda generados mediante técnicas de suavización exponencial para diversos productos, identificados por sus respectivos SKU. Cada subgráfico presenta la evolución de las órdenes UND_ORDEN junto con las proyecciones realizadas por el modelo de suavización, lo que permite evaluar la efectividad del modelo en la predicción de la demanda. En el primer gráfico, correspondiente al Producto SKU 3261, se observa que la serie original presenta un patrón cíclico con altibajos regulares. Por otro lado, el pronóstico muestra una tendencia general al alza, representada por una línea recta ascendente. Esto indica que el modelo HWES2_MUL captura la tendencia general de crecimiento, pero no logra modelar con precisión las fluctuaciones estacio-


nales de los datos. El segundo gráfico, correspondiente al Producto SKU 2419, revela patrones de demanda más irregulares, con un patrón cíclico claro, caracterizado por altibajos regulares que sugieren una estacionalidad marcada. Sin embargo, el pronóstico, representado por una línea recta ascendente, no captura esta estacionalidad. El modelo parece captar la tendencia general al alza, pero no logra modelar adecuadamente las fluctuaciones periódicas, lo que sugiere que el pronóstico podría no ser muy preciso. El tercer gráfico, correspondiente al Producto SKU 2014, muestra una excelente concordancia entre la serie original UND_ORDEN y el pronóstico generado por el modelo HWES3_MM. Ambas líneas siguen un patrón cíclico muy similar, con picos y valles que coinciden en el tiempo. Esto indica que el modelo ha capturado efectivamente tanto la tendencia general como la estacionalidad de los datos. La cercanía entre ambas líneas sugiere que el pronóstico es bastante preciso y que el modelo HWES3_MM es adecuado para modelar esta serie de tiempo en particular. Finalmente, el gráfico correspondiente al Producto SKU 1742 muestra que ambas líneas presentan un patrón cíclico similar, con picos y valles que coinciden en el tiempo. Esto sugiere que el modelo ha capturado de manera efectiva tanto la tendencia general como la estacionalidad de los datos. La cercanía entre ambas líneas indica que el pronóstico es bastante preciso y que el modelo HWES3_AA es adecuado para modelar esta serie de tiempo en particular. Los resultados obtenidos mediante la evaluación de los métodos de Suavización Exponencial Doble y Triple indican que ambos modelos presentan un desempeño adecuado en el pronóstico de la demanda de productos. En particular, la distribución del MAPE evidencia que más del 80 % de los productos tienen errores inferiores al 20 %, lo que confirma la precisión y confiabilidad de estos métodos. Asimismo, no se registran valores de MAPE superiores al 50 %, lo que garantiza que el margen de error se mantiene dentro de los límites aceptables. En consecuencia, el uso de estos métodos contribuye significativamente a la mejora en la toma de decisiones para la asignación de ubicaciones de almacenamiento, validando la hipótesis planteada en este estudio.




(a) Gráfico Comparativo del Producto con SKU = 3261



(b) Gráfico Comparativo del Producto con SKU = 2419



(c) Gráfico Comparativo del Producto con SKU = 2014



(d) Gráfico Comparativo del Producto con SKU = 1742

Figura 9

Gráficos de UND_ORDEN y Pronósticos usando Suavización Exponencial

Fuente. Elaboración propia.

5.2. Objetivo Específico 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad

La Tabla 6 presenta los pronósticos de demanda generados por el modelo (S)ARIMA para una variedad de productos, identificados por su SKU. En ella se incluyen los valores históricos de órdenes UND_ORDEN para cada producto, junto con los parámetros ajustados del modelo: AR (AutoRegresivo), I (Integrado), MA (Media Móvil) y los componentes estacionales SO_AR (AutoRegresivo Estacional), SO_D (Diferenciación Estacional) y SO_MA (Media Móvil Estacional). Los resultados muestran patrones significativos en la variabilidad de las órdenes, lo que puede facilitar la planificación de inventarios y la toma de decisiones estratégicas en la gestión de productos. Los pronósticos de demanda generados por el modelo (S)ARIMA muestran diversas tendencias a lo largo de los meses para los productos evaluados. Para el producto con SKU 1742, se observa estabilidad en las predicciones, lo que sugiere una demanda relativamente constante durante el período analizado. Las diferencias entre las unidades ordenadas UND_ORDEN no son pronunciadas, y los valores del pronóstico (S)ARIMA se mantienen cercanos, lo que indica que el modelo es adecuado para predecir una demanda

constante. Por otro lado, el producto con SKU 1771 muestra una ligera disminución en la demanda a lo largo de los meses. La variabilidad en los valores refleja una tendencia decreciente, lo que sugiere que el modelo (S)ARIMA está capturando una reducción en la demanda de este producto. Finalmente, el producto con SKU 3509 presenta pronósticos más bajos y fluctuantes. La caída progresiva en las predicciones podría indicar una demanda decreciente o inestable, reflejada en los valores más bajos de (S)ARIMA a medida que avanzan los meses. En general, los pronósticos son razonablemente adecuados, aunque las variaciones en los resultados podrían requerir ajustes dependiendo de las fluctuaciones reales del mercado. Se observa también que algunos SKUs presentan valores de 0 en los componentes estacionales, lo que sugiere que estos productos no siguen patrones estacionales en su demanda, indicando un comportamiento más lineal y posiblemente más predecible.

Tabla 6

Resultados de Pronósticos: (S)ARIMA

SKU	UND_ORDEN	MES	AR	I	MA	SO_AR	SO_D	SO_MA	(S)ARIMA	Sesgo
1742	909	1	1	0	2	0	0	0	790.084564	-118.92
1742	799	2	1	0	2	0	0	0	787.131164	-11.87
1742	831	3	1	0	2	0	0	0	789.885113	-41.11
1742	796	4	1	0	2	0	0	0	787.317145	-8.68
1742	869	5	1	0	2	0	0	0	789.711692	-79.29
1742	799	6	1	0	2	0	0	0	787.478855	-11.52
1742	796	7	1	0	2	0	0	0	789.560903	-6.44
1771	203	1	2	0	2	3	0	1	208.768162	5.77
1771	213	2	2	0	2	3	0	1	201.223997	-11.78
1771	241	3	2	0	2	3	0	1	206.613607	-34.39
1771	242	4	2	0	2	3	0	1	201.854537	-40.15
1771	252	5	2	0	2	3	0	1	202.126423	-49.87
1771	211	6	2	0	2	3	0	1	189.418517	-21.58
1771	204	7	2	0	2	3	0	1	191.880394	-12.12
3509	32	1	4	0	1	1	0	3	46.0091142	14.01
3509	28	2	4	0	1	1	0	3	38.3877186	10.39
3509	42	3	4	0	1	1	0	3	44.5468185	2.55
3509	39	4	4	0	1	1	0	3	40.8834382	1.88
3509	26	5	4	0	1	1	0	3	39.762627	13.76
3509	35	6	4	0	1	1	0	3	42.2063004	7.21
3509	43	7	4	0	1	1	0	3	39.5348194	-3.47

Fuente. Elaboración propia.

Los resultados del MAPE para el modelo (S)ARIMA se presentan en la tabla 7. Este análisis se llevó a cabo para cada producto identificado por su código SKU, lo que permite evaluar la precisión de las predicciones del modelo. Se observan variaciones significativas en los valores de MAPE, con el SKU 1329 mostrando un MAPE notablemente alto de 2.3099, lo que sugiere que las predicciones para este producto son considerablemente menos precisas en comparación con otros SKUs. Por otro lado, el SKU 6 se destaca por su bajo MAPE de 0.0580, indicando un desempeño altamente satisfactorio del modelo en sus pronósticos. Esta tabla no solo proporciona una visión

clara del rendimiento del modelo (S)ARIMA, sino que también ofrece una base para comparar la eficacia de este método con otros modelos de pronóstico utilizados en el análisis.

Tabla 7


Resultados de MAPE: (S)ARIMA

SKU	(S)ARIMA MAPE	MET_(S)ARIMA
4	0.308375519	(0,0,1)(0,0,0,12)
6	0.058028146	(0,0,0)(0,0,2,12)
18	0.423994832	(2,0,0)(0,0,0,12)
42	0.180463052	(1,0,0)(0,0,0,12)
389	0.040666143	(1,0,0)(0,0,1,12)
464	0.132026625	(0,0,0)(0,0,0,12)
485	0.052819558	(1,0,0)(0,0,0,12)
543	0.134739076	(3,0,0)(3,0,0,12)
854	0.061744132	(2,0,3)(2,0,1,12)
994	0.068077022	(0,0,0)(4,0,0,12)
1126	0.135584034	(0,0,0)(0,0,0,12)
1180	0.106937095	(1,0,0)(0,0,0,12)
1203	0.097430343	(2,0,0)(1,0,0,12)
1269	0.078849583	(0,0,0)(0,0,0,12)
1329	2.30988717	(3,0,2)(3,1,0,12)


Fuente. Elaboración propia.

La Figura 10 presentan una serie de gráficos comparativos que ilustran los pronósticos de demanda generados por el modelo (S)ARIMA para diferentes productos, identificados por sus respectivos SKU. Cada subgráfico muestra la evolución de las órdenes reales UND_ORDEN junto con las proyecciones del modelo, lo que facilita una visualización clara de la precisión del pronóstico. En el primer gráfico, correspondiente al producto con SKU 2014, ambas líneas exhiben un patrón cíclico con picos y valles recurrentes a lo largo del tiempo, lo que sugiere una marcada estacionalidad en los datos. El modelo ajusta de manera adecuada la serie original, capturando efectivamente los patrones estacionales y cíclicos. Por otro lado, el gráfico del producto con SKU 1329 revela una discrepancia significativa: mientras los valores reales permanecen relativamente estables, el modelo predice una tendencia decreciente marcada. Esto sugiere un ajuste inadecuado, posiblemente debido a una selección incorrecta de hiperparámetros o a la ausencia de patrones claros en los datos históricos. En el caso del producto con SKU 1978, se observan patrones de estacionalidad más definidos, con picos y valles pronunciados en la demanda. Aunque el modelo sigue la forma general de los datos reales, hay diferencias en la amplitud de las fluctuaciones, lo que indica un ajuste parcial. Esto sugiere la necesidad de refinar los parámetros del modelo para capturar de manera más precisa la variabilidad presente en los datos históricos. Finalmente, el gráfico del producto con SKU 3773 muestra fluctuaciones más pronunciadas, caracterizadas por picos y caídas significativas, mientras que el modelo genera un pro-


nóstico más suavizado. Si bien logra capturar la forma general de la serie, no refleja completamente la amplitud de las variaciones. Esto evidencia que el modelo podría no estar capturando adecuadamente los cambios abruptos en la demanda, lo que requeriría ajustes adicionales en los parámetros para mejorar su capacidad predictiva. Los resultados obtenidos al aplicar el método Promedio Móvil Integrado Autorregresivo (ARIMA y SARIMA) en el pronóstico de la demanda de productos muestran una distribución del MAPE que sugiere ciertas limitaciones en su precisión. Si bien el 66 % de los productos presentan un MAPE menor al 20 %, indicando una buena capacidad predictiva en estos casos, se observa que 34 % de los productos tienen un error superior al 20 %, y un 8 % supera el umbral del 50 %, lo que los clasifica como pronósticos inexactos. Estos resultados sugieren que, aunque (S)ARIMA puede ser útil en ciertos escenarios, su desempeño es menos consistente en comparación con otros métodos evaluados. La presencia de valores de error elevados podría afectar la confiabilidad del modelo en la toma de decisiones para la asignación de ubicaciones de almacenamiento. Por lo tanto, su aplicabilidad debe considerarse con precaución, especialmente en contextos donde se requiere una alta precisión en los pronósticos.




(a) *Gráfico Comparativo del Producto*
SKU = 2014



(b) *Gráfico Comparativo del Producto*
SKU = 1329



(c) *Gráfico Comparativo del Producto*
SKU = 1978



(d) *Gráfico Comparativo del Producto*
SKU = 3773

Figura 10

Gráficos de UND_ORDEN y Pronósticos usando (S)ARIMA

Fuente. Elaboración propia.

5.3. Objetivo Específico 3: Memoria a Largo y Corto Plazo

Los resultados obtenidos en la Tabla 8 mediante el modelo LSTM evidencian variaciones significativas entre los valores reales de unidades ordenadas UND_ORDEN y los valores pronosticados, lo que refleja el rendimiento del modelo en la predicción de la demanda para diferentes productos SKU. Los pronósticos generados muestran una considerable variabilidad en la demanda proyectada a lo largo del tiempo. En el caso del producto con SKU 4, la predicción inicial sigue una tendencia creciente. Aunque las unidades ordenadas reales presentan fluctuaciones, el modelo LSTM mantiene valores pronosticados relativamente estables, lo que sugiere que está capturando una demanda más constante. Por otro lado, para el producto con SKU 6, el pronóstico muestra una ligera tendencia a estabilizarse con un aumento gradual, lo que indica un comportamiento más predecible y consistente en comparación con el SKU 4. Finalmente, el producto con SKU 18 presenta una dinámica completamente distinta, destacándose por un crecimiento significativo en la predicción de la demanda. Este comportamiento sugiere un posible aumento exponencial en la demanda, lo que podría requerir ajustes en las estrategias de almacenamiento y distribución para satisfacer las necesidades proyectadas de manera eficiente. El tiempo total de ejecución fue de 65 minutos, lo cual se considera regular para esta evaluación.

Tabla 8*Resultados de Pronósticos: LSTM*

SKU	MES	UND_ORDEN	LSTM	Sesgo
4	1	582	648.129058	-66.129058
4	2	663	676.281942	-13.281942
4	3	626	695.935408	-69.935408
4	4	666	697.809869	-31.809869
4	5	743	697.607167	45.392833
4	6	255	697.000713	-442.000713
4	7	491	697.527823	-206.527823
6	1	261	280.018216	-19.018216
6	2	272	281.484172	-9.484172
6	3	283	286.495723	-3.495723
6	4	266	287.561047	-21.561047
6	5	275	278.87224	-3.87224
6	6	231	276.843763	-45.843763
6	7	256	270.781097	-14.781097
18	1	125	138.745333	-13.745333
18	2	104	175.832263	-71.832263
18	3	145	239.637496	-94.637496
18	4	180	356.389239	-176.389239
18	5	132	623.672827	-491.672827
18	6	129	1305.88379	-1176.88379
18	7	160	3015.4249	-2855.4249

Fuente. Elaboración propia.

En los resultados obtenidos en la tabla 9, se evaluó la precisión de los pronósticos generados por el modelo LSTM mediante el cálculo del MAPE para cada producto individual, identificado por su SKU. Este análisis se enfocó en comparar las cantidades reales de unidades ordenadas UND_ORDEN con los valores pronosticados por el modelo. Para cada SKU, se calculó el MAPE con el objetivo de reflejar el nivel de precisión de los resultados.

Los datos obtenidos muestran variaciones significativas en los valores de MAPE entre los diferentes SKUs. Por ejemplo, el SKU 18 presenta un MAPE de 4.7325, lo que indica una menor precisión en sus pronósticos respecto de otros productos, como el SKU 6, que obtuvo un MAPE de tan solo 0.0673, evidenciando un desempeño notablemente superior. La tabla también presenta los valores correspondientes a los demás SKUs, lo que permite una comparación directa del rendimiento del modelo. Estos resultados proporcionan información valiosa para la toma de decisiones en la gestión de inventarios y la planificación de la demanda, al identificar los productos con mayor y menor precisión en los pronósticos. Por otro lado, el producto SKU 4 presenta un MAPE de 0.3583, lo que indica una alta precisión en el pronóstico. Aunque no es perfecto, este nivel de error es suficientemente bajo como para considerar el modelo útil en la estimación de la demanda de este producto.

Tabla 9*Resultados de MAPE: LSTM*


ID	SKU	MAPE_LSTM
1	4	0.3583135
2	6	0.0673459
3	18	4.7325143
4	42	0.1876232
5	389	0.0988873
6	464	0.4831417
7	485	0.1558728
8	543	0.1532642
9	854	0.2037437
10	994	0.2012104
11	1126	0.1783951
12	1180	0.1543409
13	1203	0.1210258
14	1269	0.1201573
15	1329	0.1220697

Fuente. Elaboración propia.


La Figura 11 presentan una serie de gráficos que ilustran los resultados obtenidos a partir del modelo LSTM. El primer gráfico corresponde al producto SKU 1336 e incluye una comparación entre la serie temporal de UND_ORDEN y el pronóstico generado por el modelo LSTM. En este caso, ambas líneas exhiben un patrón similar, lo que indica que el modelo ha capturado satisfactoriamente las características principales de los datos. La cercanía entre ambas líneas sugiere que el pronóstico es bastante preciso. En contraste, el gráfico del producto SKU 3772 muestra que, aunque el modelo LSTM logra capturar la tendencia general ascendente de los datos, se observa una discrepancia significativa entre el pronóstico y los valores reales, especialmente en los picos. Esto sugiere que, aunque el modelo ha aprendido algunas características de los datos, no está capturando completamente la complejidad de la serie temporal. Por otro lado, el gráfico correspondiente al producto SKU 6 revela que el modelo LSTM identifica de manera general la tendencia cíclica de la serie temporal, pero subestima claramente los picos y valles. Esto indica que, aunque el modelo ha aprendido algunas características clave de los datos, no logra captar completamente la complejidad de la serie temporal, lo que limita su capacidad para reflejar con precisión los extremos de la demanda. De manera similar, en el caso del producto SKU 1329, tanto la serie original como el pronóstico presentan un patrón estacional claramente definido, con picos y valles recurrentes. Sin embargo, el modelo LSTM no replica adecuadamente la amplitud de estos ciclos, ya que los valores máximos y mínimos pronosticados son considerablemente más bajos que los reales. Esto evidencia una deficiencia en la capacidad del modelo para predecir con precisión los rangos de fluctuación de la demanda,

lo que podría afectar la efectividad de las decisiones basadas en este pronóstico.


Los resultados obtenidos al aplicar el modelo de Memoria a Largo y Corto Plazo (LSTM) en el pronóstico de la demanda de productos muestran una distribución del MAPE que plantea ciertos desafíos en términos de precisión. Solo el 30 % de los productos presentan un MAPE menor al 20 %, lo que indica que la mayoría de los pronósticos no alcanzan un nivel óptimo de precisión. Además, el 40 % de los productos presentan un error superior al 20 %, y un 10 % supera el umbral del 50 %, clasificándose como pronósticos inexactos. Estos resultados sugieren que el desempeño del modelo LSTM, en este contexto específico, no alcanza la confiabilidad esperada para su uso en la asignación de ubicaciones de almacenamiento. La presencia significativa de errores elevados compromete su aplicabilidad, por lo que su uso debería ser reconsiderado o complementado con otros enfoques para mejorar la precisión de los pronósticos.




(a) Gráfico Comparativo del Producto con SKU = 1336



(b) Gráfico Comparativo del Producto con SKU = 3772



(c) Gráfico Comparativo del Producto con SKU = 6



(d) Gráfico Comparativo del Producto con SKU = 1329

Figura 11

Gráficos de UND_ORDEN y Pronósticos usando LSTM

Fuente. Elaboración propia.

5.4. Objetivo Específico 4: Unidad Recurrente con Puertas

Los resultados obtenidos en la Tabla 10 para los productos SKU 4, SKU 6 y SKU 18 muestran las predicciones de demanda generadas por el modelo GRU a lo largo de varios meses de orden. En el caso del producto SKU 4, el modelo GRU presenta una tendencia creciente en la predicción de la demanda. Este comportamiento sugiere que el modelo logra capturar una tendencia de aumento, aunque las fluctuaciones entre los diferentes puntos de la serie no son muy pronunciadas. Para el producto SKU 6, las predicciones del modelo GRU se mantienen dentro de un rango relativamente estable, lo que indica que el modelo no detecta una tendencia clara en la demanda, limitándose a capturar una variabilidad moderada alrededor de un valor central. Finalmente, en el caso del producto SKU 18, el modelo GRU muestra predicciones con ciertas fluctuaciones a lo largo de las fechas de orden. Esto sugiere que el modelo está detectando variaciones en la demanda de este producto, aunque no logra identificar una tendencia definida, lo que podría señalar la necesidad de ajustar los parámetros del modelo para mejorar su precisión. El tiempo total de ejecución fue de 90 minutos, lo cual se considera regular para esta evaluación.

Tabla 10*Resultados de Pronósticos: GRU*

SKU	UND_ORDEN	MES	GRU	Sesgo
4	582	1	663.217731	-81.217731
4	663	2	697.220466	-34.220466
4	626	3	722.126974	-96.126974
4	666	4	735.128520	-69.128520
4	743	5	738.964832	4.035168
4	255	6	738.913997	-483.913997
4	491	7	738.806251	-247.806251
6	261	1	309.898385	-48.898385
6	272	2	299.193010	-27.193010
6	283	3	311.606025	-28.606025
6	266	4	311.726907	-45.726907
6	275	5	309.680830	-34.680830
6	231	6	312.427988	-81.427988
6	256	7	310.128785	-54.128785
18	125	1	121.289044	3.710956
18	104	2	113.830375	-9.830375
18	145	3	123.083313	21.916687
18	180	4	132.127915	47.872085
18	132	5	143.338734	-11.338734
18	129	6	147.111495	-18.111495
18	160	7	116.385507	43.614493

Fuente. Elaboración propia.

Se aplicó el MAPE en la tabla 11 los resultados obtenidos en la tabla anterior. Para el producto SKU 4, el valor obtenido fue 0.408, lo que sugiere que el modelo GRU logró una predicción moderadamente precisa, aunque con margen para mejorar. En contraste, el producto SKU 6 obtuvo una puntuación de 0.179, indicando dificultades del modelo para ajustarse a los datos de este producto, probablemente debido a una menor variabilidad o a la falta de patrones claros en la serie temporal. Por otro lado, el producto SKU 18 presentó una puntuación de 0.149, reflejando también una predicción subóptima, similar a la de SKU 6, lo que podría deberse a comportamientos más erráticos en la serie temporal o a la necesidad de ajustar los parámetros del modelo. Otros productos, como SKU 4, 6 y 18, registraron puntuaciones de 0.302, 0.098 y 0.780, respectivamente. Esto sugiere que productos como SKU 6 tienen un rendimiento relativamente bueno en términos de predicción, mientras que otros, como SKU 389 y SKU 485, evidencian una baja precisión, lo que indica que el modelo no logró capturar adecuadamente las fluctuaciones de demanda de estos productos.

Tabla 11*Resultados de MAPE: GRU*


ID	SKU	GRU
1	4	0.4080497
2	6	0.17862375
3	18	0.14860076
4	42	0.30241768
5	389	0.09761994
6	464	0.77972617
7	485	0.10405073
8	543	0.15001859
9	854	0.18642422
10	994	0.17493314
11	1126	0.36273882
12	1180	0.13049096
13	1203	0.10392935
14	1269	0.12491266
15	1329	0.12270942

Fuente. Elaboración propia.


La Figura 12 presentan una serie de gráficos comparativos que ilustran los pronósticos de demanda generados por el modelo GRU para diferentes productos. El gráfico del producto SKU 464 muestra un desfase entre el pico del pronóstico del modelo GRU y el pico aparente en la variable UND_ORDEN, lo que sugiere que el modelo podría estar retrasado en la detección de los cambios en la tendencia y, además, ser demasiado sensible al ruido en los datos. Por otro lado, el gráfico del producto SKU 3772 evidencia que el modelo predice un crecimiento sostenido en los primeros meses y luego se estabiliza en un nivel ligeramente superior al valor promedio de UND_ORDEN. Esta discrepancia indica que el modelo GRU podría estar sobreestimando el crecimiento a largo plazo. En el caso del producto SKU 1676, se observa que ambas series exhiben un patrón cíclico, lo que sugiere una estacionalidad en los datos. Sin embargo, el modelo GRU presenta un ligero desfase en relación con los picos y valles de los datos reales, además de una amplitud de fluctuaciones predichas inferior a la observada. Aunque logra capturar la estacionalidad, persisten discrepancias en la precisión. Finalmente, el gráfico del producto SKU 1742 muestra que el modelo subestima la amplitud de las fluctuaciones de UND_ORDEN, y los picos y valles de las predicciones no coinciden exactamente con los datos reales, lo que indica que, si bien el modelo GRU logra capturar ciertos aspectos de la estacionalidad, no es adecuado para realizar pronósticos precisos.

Los resultados obtenidos al aplicar el modelo de Unidad Recurrente con Puertas en


el pronóstico de la demanda de productos evidencian una distribución del MAPE que presenta limitaciones en términos de precisión. Solo el 29 % de los productos alcanzan un MAPE inferior al 20 %, lo que sugiere que la mayoría de las predicciones no cumplen con los criterios de precisión establecidos. Además, el 42 % de los productos presentan un error entre el 20 % y el 50 %, mientras que un 7 % supera el umbral del 50 %, clasificándose como pronósticos inexactos. Estos resultados indican que el desempeño del modelo GRU, en este contexto, no garantiza una precisión adecuada para la asignación de ubicaciones de almacenamiento. La proporción de productos con errores elevados sugiere la necesidad de ajustes en el modelo o la exploración de enfoques alternativos para mejorar la calidad de los pronósticos.




(a) *Gráfico Comparativo del Producto con SKU = 464*



(b) *Gráfico Comparativo del Producto con SKU = 3772*



(c) *Gráfico Comparativo del Producto con SKU = 1676*



(d) *Gráfico Comparativo del Producto con SKU = 1742*

Figura 12

Gráficos de UND_ORDEN y Pronósticos usando GRU

Fuente. Elaboración propia.

5.5. Resultados de los modelos de pronósticos por MAPE

5.5.1. Resumen de los modelos de MAPE

El análisis de los resultados de la Tabla 12 evidencia la distribución de productos según los rangos de MAPE alcanzados por cada método de pronóstico. (S)ARIMA

lidera en el rango de alta precisión menor al 10 % con 18 productos, seguido por la suavización exponencial triple con 17 productos, la suavización exponencial doble con 14 productos, LSTM con 6 productos y GRU con 4 productos. En el rango de MAPE entre 10 % y 20 %, la suavización doble se posiciona como el mejor método con 29 productos, seguido de suavización triple con 23, LSTM con 24, GRU con 25 y (S)ARIMA 15 respectivamente. En el rango de MAPE entre 20 % y 50 %, las redes neuronales y (S)ARIMA destacan con un número considerable de productos: 18 para GRU, 16 para LSTM y 13 para (S)ARIMA. En contraste, los métodos de suavización exponencial presentan un menor desempeño en este rango, con 10 productos para la suavización triple y 7 para doble. Finalmente, en el rango de MAPE superior al 50 %, solo (S)ARIMA presenta 4 productos, mientras que GRU y LSTM clasifican 3 y 4 productos, respectivamente, y los métodos de suavización no presentan productos en esta categoría. Estos resultados resaltan que, aunque (S)ARIMA logra alta precisión para más productos, las redes neuronales recurrentes como GRU y LSTM son competitivas en rangos intermedios, mientras que los métodos de suavización destacan por su consistencia.

Tabla 12

Resultados de MAPE de los modelos de pronósticos

MAPE(%)	SMOOTH. DOUBLE	SMOOTH. TRIPLE	(S)ARIMA	LSTM	GRU
<10	14	17	18	6	4
10 - 20	29	23	15	24	25
20 - 50	7	10	13	16	18
>50	0	0	4	4	3

Fuente. Elaboración propia.

5.5.2. Resumen de los modelos de pronósticos MAPE

El análisis de los resultados de la tabla 13 en términos de precisión pronóstica, medida por el MAPE, revela diferencias notables entre los métodos evaluados. La técnica de GRU presenta un desempeño consistente, con un rango de valores entre un mínimo de 3.52 % y un máximo de 66.90 %, y un MAPE promedio de 22.81 %, lo que indica una estabilidad relativa en sus predicciones. Por su parte, LSTM muestra una mayor dispersión en los valores de error, con un promedio de 29.99 %, un mínimo de 6.09 % y un máximo significativamente más alto de 472.91 %, lo que sugiere una sensibilidad a patrones más complejos o a variaciones extremas en los datos. En el caso de (S)ARIMA, aunque alcanza un mínimo bajo de 3. %, su valor máximo de 7837.15 % y su promedio de 217.31 % reflejan una mayor vulnerabilidad ante datos atípicos o variabilidad extrema. Los métodos de suavización exponencial, tanto doble como triple, destacan por su estabilidad, con promedios de MAPE de 13.94 % y

14.55 %, respectivamente, y rangos acotados entre 3.99 %-31.93 % para la suavización doble y 3.17 %-44.40 % para la triple. Estos resultados evidencian que, mientras las redes neuronales ofrecen ventajas para manejar patrones más complejos, los métodos estadísticos de suavización son opciones confiables en escenarios de menor variabilidad.

Tabla 13

Análisis de los Valores Mínimos, Máximos y Promedios del MAPE en los Modelos de Pronóstico

Método	Máximo	Mínimo	Promedio
GRU	66.90 %	3.52 %	22.81 %
LSTM	472.91 %	6.09 %	29.99 %
(S)ARIMA	7837.15 %	3.92 %	217.31 %
DOUBLE SMOOTHING	31.93 %	3.99 %	13.94 %
TRIPLE SMOOTHING	44.40 %	3.17 %	14.55 %

Fuente. Elaboración propia.

5.5.3. Resumen de los modelos de MAPE agrupados

Los resultados obtenidos en la Tabla 14 evidencian diferencias significativas en la precisión de los modelos de pronóstico evaluados, categorizados en rangos de MAPE. Los métodos de suavización exponencial destacan en el rango de alta precisión ($\text{MAPE} < 10\%$), logrando predecir con alta exactitud para 20 productos, superando a (S)ARIMA con 18 productos y a las redes neuronales recurrentes, que alcanzaron 8 productos en este rango. En el rango de MAPE entre 10 y 20 %, los métodos de suavización exponencial y las redes neuronales recurrentes se muestran competitivos, con 24 productos cada uno, mientras que (S)ARIMA queda rezagado con 15 productos. En el rango de MAPE entre 20 y 50 %, las redes neuronales lideran con 16 productos, seguidas de (S)ARIMA con 13 productos y los métodos de suavización con solo 6. Finalmente, en el rango de menor precisión ($\text{MAPE} > 50\%$), los métodos de suavización no presentan productos en esta categoría, mientras que (S)ARIMA y las redes neuronales registran 4 y 2 productos, respectivamente. Estos resultados subrayan la consistencia de los métodos de suavización exponencial en rangos de alta precisión y la capacidad de las redes neuronales para manejar patrones más complejos, aunque con cierta dispersión en los resultados.

Tabla 14*Resultados de MAPE de los modelos Agrupados*

MAPE	Suavización Exponencial	(S)ARIMA	Redes Neuronales Recurrentes
<10	20	18	8
10 - 20	24	15	24
20 - 50	6	13	16
>50	0	4	2

Fuente. Elaboración propia.

Capítulo VI

DISCUSIÓN

6.1. Hipótesis Específica 1: Suavizaciones Exponenciales

Se analizaron los resultados obtenidos de la métrica de error MAPE en la predicción de la demanda utilizando modelos de suavización exponencial doble y triple, con el fin de contrastar los hallazgos con los reportados en estudios previos.

Por un lado, el estudio de Parasian et al. (2020) empleó enfoques de suavización exponencial doble, alcanzando un MAPE de 27.72 %. Este valor es superior al valor promedio obtenido en este trabajo 13.94 % para el mismo modelo. En otro estudio, Riawan y Pardede (2023) obtuvieron un MAPE de 21.09 %, también mayor que el valor promedio del presente estudio. Sin embargo, en ambos trabajos, los valores de MAPE fluctuaron entre el 20 % y el 50 %, un rango considerado aceptable para modelos de predicción en entornos prácticos. En contraste, los resultados obtenidos son más favorables. Finalmente, Delgado Delgado Eraso et al. (2022) evaluaron varios productos, y el ítem con el menor MAPE fue de 12 %, mientras que el valor máximo alcanzado fue del 66 %, lo cual demuestra resultados considerablemente elevados en comparación con los presentados, resaltando la eficacia de los métodos de pronóstico utilizados.

Por otro lado, el modelo de suavización exponencial triple analizado por Bustami et al. (2023) alcanzó un MAPE de 6.52 %, mientras que el presente estudio reportó un valor mínimo de 3.17 %, lo que evidencia una mayor precisión en las predicciones obtenidas. De manera similar, Koech et al. (2021) presentó valores de MAPE inferiores a 2.55 %, cercanos al resultado mínimo encontrado. Sin embargo, en el estudio de Khairina et al. (2021), se realizó un análisis similar en el que los resultados mostraron un MAPE de 9.85 %, superior al valor mínimo registrado, pero inferior al valor promedio. Estos hallazgos destacan la efectividad del método de suavización exponencial triple, que mantiene consistentemente valores de MAPE por debajo del 10 %, consolidándose como una herramienta altamente precisa para aplicaciones de pronóstico. Finalmente,

en el estudio de Delgado Eraso et al. (2022), se evaluaron varios productos, siendo el producto con el menor MAPE de 12 %, mientras que el valor máximo alcanzó el 52 %. Estos resultados son considerablemente más altos en comparación con los obtenidos, lo que refuerza la efectividad de los métodos de pronóstico utilizados.

6.2. Hipótesis Específica 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad

Se analizaron los resultados obtenidos de la métrica de error MAPE en la predicción de la demanda utilizando modelos autorregresivos integrados de media móvil (ARIMA y SARIMA), con el fin de contrastar los hallazgos con los reportados en estudios previos.

Por un lado, el modelo ARIMA analizado por Borucka (2023) alcanzó un MAPE extremadamente preciso de 1.01 %, lo que demuestra su alta exactitud en la predicción, aunque el valor mínimo obtenido fue de 3.92 % también refleja un desempeño sólido. De manera similar, en el estudio de Pasupuleti et al. (2024), ARIMA obtuvo un MAPE de 3.7 %, ligeramente inferior al rendimiento de CNN en el mismo trabajo, pero comparable a los resultados de este trabajo y mostrando que ARIMA sigue siendo confiable en términos de precisión. En la misma línea, Kumar Dubey et al. (2021) reportó un MAPE de 5.23 % con su modelo SARIMA, valor que, aunque superior al obtenido, evidencia que ambos enfoques son efectivos para el pronóstico de demanda. Por su parte, Arnita (2020) alcanzó un MAPE de 2.93 %, nuevamente resaltando la consistencia de los métodos (S)ARIMA para mantener errores de predicción bajos, consolidándose como herramientas de alta precisión en aplicaciones de pronóstico. No obstante, en la investigación de Goswami y Kandali (2020), los valores de MAPE reportados para ARIMA y SARIMA fueron de 13.73 % y 10.7 %, respectivamente, mientras que el presente estudio presentó un MAPE promedio de 17.96 %. Aunque este valor refleja un mayor error de predicción, sigue siendo aceptable para aplicaciones prácticas, destacando la utilidad de los métodos empleados. En general, dado que todos los estudios reportan valores de MAPE por debajo del 20 %, estos métodos se consideran muy eficientes; sin embargo, en este trabajo, los resultados solo se aplican de manera confiable a 33 productos, lo que limita su alcance y no representa el escenario más óptimo para la totalidad del inventario.

6.3. Hipótesis Específica 3: Memoria a Largo y Corto Plazo

Se analizaron los resultados obtenidos de la métrica de error MAPE en la predicción de la demanda utilizando el modelo de memoria a corto-largo plazo (LSTM), con el fin de contrastar los hallazgos con los reportados en estudios previos.

En el estudio de Ozdemir et al. (2022) mostraron resultados de 7.06 % para LSTM, valores cercanos a los resultados mínimos obtenidos de 6.09 %, lo que indica un excelente desempeño del modelo LSTM para el pronóstico de ciertos productos. Este nivel de error sugiere que, bajo condiciones adecuadas de calidad de datos y parametrización, el modelo LSTM puede capturar patrones temporales de la demanda de forma muy precisa. Por el contrario, Hamayel y Owda (2021) obtuvieron resultados de MAPE altamente precisos de 1.55 % para LSTM, superando los resultados respectivos de este trabajo, lo cual puede atribuirse a diferencias en la naturaleza del conjunto de datos, la cantidad de observaciones disponibles, la estacionalidad o el proceso de optimización de hiperparámetros empleado. Asimismo, Karim et al. (2022) reportaron un MAPE de 28.16 % para LSTM, en comparación con el promedio registrado de 29.99 %, lo que pone de manifiesto que, aunque el modelo presenta un desempeño competitivo frente a otros estudios, su exactitud puede verse afectada por la variabilidad de los productos, la dispersión en las series de tiempo y las limitaciones del propio método de predicción. Finalmente, en el caso de Robles Rakov y Valverde Campos (2021), aunque el estudio se centró únicamente en el día 30, se procedió a recalcular el error utilizando los datos reportados para los cinco días anteriores. Este análisis complementario arrojó un MAPE de 175.11 %, considerablemente inferior al error máximo encontrado de 472.91 %, lo que sugiere que para ciertos productos no resulta factible aplicar este modelo de predicción.

6.4. Hipótesis Específica 4: Unidad Recurrente con Puertas

Se analizaron los resultados obtenidos de la métrica de error MAPE en la predicción de la demanda utilizando el modelo de Unidades Recurrentes con Puertas (GRU), con el fin de contrastar los hallazgos con los reportados en estudios previos.

En el estudio de Ozdemir et al. (2022) se reportaron resultados de MAPE de 6.93 % para el modelo GRU, valores comparables con el resultado mínimo obtenido en el presente estudio (3.52 %). Sin embargo, en este caso dicho nivel de precisión excelente solo se alcanzó en cuatro productos, lo que evidencia que el rendimiento óptimo no es uniforme en todo el conjunto analizado. Por su parte, Hamayel y Owda (2021) logró

resultados de MAPE altamente precisos de 0.83 % para GRU, superando los resultados obtenidos en este estudio, lo que demuestra que este tipo de modelo podría incluso alcanzar valores por debajo del 1 % de MAPE en casos especiales o bajo condiciones muy favorables del conjunto de datos. En contraste, el estudio de Karim et al. (2022) reportó resultados de MAPE de 28.44 % para GRU, frente al promedio obtenido aquí (22.81 %), lo que sugiere que los modelos de pronóstico GRU presentan una capacidad razonable para la predicción de ciertos productos. De manera similar, Riatma et al. (2025) obtuvieron valores de MAPE variables en función del número de epochs; al considerar 100 epochs, el mismo número empleado en el presente estudio, reportaron un MAPE de 20 %, mientras que en el presente trabajo se alcanzó 22.81 %, siendo resultados de pronósticos buenos. No obstante, aunque se obtuvieron valores de MAPE aceptables, esta precisión solo se logró para un total de 29 productos.

Capítulo VII

CONCLUSIONES

7.1. Conclusión General

El estudio permitió comparar el desempeño de distintos modelos de pronóstico aplicados a la demanda de productos, con el fin de fortalecer la toma de decisiones en la asignación de ubicaciones de almacenamiento. Los resultados evidenciaron que los métodos de suavización exponencial presentaron el mejor desempeño al generar pronósticos con menor error y mayor estabilidad, seguidos del modelo (S)ARIMA, que mostró resultados aceptables; en contraste, las redes neuronales recurrentes (LSTM y GRU) obtuvieron un rendimiento inferior y demandaron mayores tiempos de procesamiento, lo que limita su aplicabilidad en escenarios donde la rapidez y la eficiencia son factores determinantes.

7.2. Objetivo Específica 1: Suavizaciones Exponenciales

7.3. Objetivo Específica 1: Suavizaciones Exponenciales

El análisis del Objetivo 1 permitió evaluar los métodos de suavización exponencial doble y triple para pronosticar la demanda de productos, con el propósito de apoyar la toma de decisiones en la asignación de ubicaciones de almacenamiento. Los resultados muestran que estos métodos obtuvieron un desempeño favorable en comparación con otros modelos, ya que el 88 % de los productos presentó un MAPE menor a 20 % y el 12 % restante superó un error de 20–50 %, según los resultados del cuadro 14. Asimismo, las suavizaciones evidenciaron un tiempo de ejecución rápido, de aproximadamente 15 minutos, y un sesgo generalmente bajo y controlado, lo que indica que las

predicciones se ajustan de manera consistente a los valores reales de demanda, según la Tabla 4. En consecuencia, los resultados obtenidos permiten afirmar que se cumple la hipótesis planteada para este objetivo específico, al evidenciar que los métodos de suavización exponencial generan pronósticos con un nivel de precisión adecuado para la planificación de ubicaciones de almacenamiento.

7.4. Objetivo Específica 2: Autorregresivo Integrado de Promedio Móvil - Estacionalidad

El análisis del Objetivo 2 permitió evaluar el desempeño del método Autorregresivo Integrado de Promedio Móvil, con y sin estacionalidad (S)ARIMA, para pronosticar la demanda de productos y apoyar la toma de decisiones en la asignación de ubicaciones de almacenamiento. Los resultados indican que el modelo presentó un desempeño moderado: el 66 % de los productos obtuvo un MAPE menor al 20 %, un 26 % se ubicó en el rango de 20–50 % y solo un 8 % superó un error de 50 %, según la Tabla 14. Aunque el tiempo de ejecución fue considerablemente mayor, aproximadamente 45 minutos, el sesgo de las predicciones se mantuvo controlado y cercano a los valores reales de demanda, como se observa en la Tabla 6. En consecuencia, los resultados permiten afirmar que se cumple la hipótesis planteada para este objetivo específico, evidenciando que el método (S)ARIMA es capaz de generar pronósticos con un nivel de precisión aceptable para la planificación de ubicaciones de almacenamiento, aunque con un mayor requerimiento de tiempo computacional.

7.5. Objetivo Específica 3: Memoria a Largo y Corto Plazo

El modelo de Memoria a Largo y Corto Plazo (LSTM) presentó un rendimiento moderado en el pronóstico de la demanda de productos, según la Tabla 12. Aproximadamente un 12 % de los productos obtuvo un MAPE menor a 10 %, mientras que el 80 % se ubicó en el rango de 10–50 % y un 4 % superó un error de 50 %. Si bien estos resultados indican que LSTM es capaz de capturar dependencias a largo plazo y patrones no lineales, su desempeño fue inferior en comparación con los métodos estadísticos evaluados. Asimismo, el tiempo de ejecución fue considerablemente elevado, alcanzando aproximadamente 65 minutos para 50 productos, lo que incrementa el costo computacional del modelo. El análisis del sesgo evidenció variaciones en determinados SKUs, como se muestra en la Tabla 8, lo que refleja una mayor variabilidad en las predicciones. En consecuencia, los resultados obtenidos permiten afirmar que la

hipótesis planteada no se cumple para este objetivo específico, ya que el modelo LSTM presentó mayor variabilidad y menor precisión en los pronósticos frente a los métodos estadísticos, limitando su viabilidad práctica en escenarios logísticos con volúmenes de datos moderados.

7.6. Objetivo Específica 4: Unidad Recurrente con Puertas

El modelo de Unidad Recurrente con Puertas (GRU) mostró un desempeño inferior en comparación con los modelos evaluados previamente, según lo reflejado en la Tabla 12. Solo un 8 % de los productos obtuvo un MAPE menor a 10 %, mientras que el 86 % se situó en el rango de 10–50 % y un 5 % presentó errores superiores al 50 %, evidenciando una menor consistencia y precisión en relación con los métodos estadísticos y el modelo LSTM. Asimismo, el tiempo de ejecución fue considerablemente elevado, alcanzando aproximadamente 90 minutos para 50 productos, lo que reduce su viabilidad práctica para conjuntos de datos de mayor tamaño. El análisis del sesgo reveló variaciones más amplias en las predicciones, como se muestra en la Tabla 10, indicando una menor estabilidad y mayores desviaciones respecto a los valores reales de demanda. En consecuencia, los resultados obtenidos permiten afirmar que la hipótesis planteada no se cumple para este objetivo específico, ya que el modelo GRU presentó un desempeño intermedio, sin superar a los métodos estadísticos y con un mayor costo computacional, lo que limita su aplicación en escenarios logísticos que requieren rapidez y consistencia en la toma de decisiones.

Capítulo VIII

RECOMENDACIONES

Basado en los hallazgos obtenidos en la presente investigación, se formulan las siguientes recomendaciones orientadas tanto a la aplicación práctica de los resultados como al fortalecimiento de futuros estudios. Dichas sugerencias buscan proporcionar lineamientos que faciliten la implementación de modelos de pronóstico en entornos logísticos y fomentar la mejora continua en los procesos de asignación de ubicaciones de almacenamiento.

8.1. Monitoreo y Reevaluación de Modelos

Es recomendable establecer un sistema de monitoreo continuo que permita evaluar de manera periódica el rendimiento de los modelos de previsión. La implementación de mecanismos de control facilitará la identificación temprana de desviaciones en la precisión de los pronósticos y permitirá realizar ajustes oportunos frente a cambios en los patrones de demanda y en las condiciones del mercado. De esta manera, se asegura que las proyecciones mantengan un nivel de confiabilidad adecuado para la toma de decisiones operativas y estratégicas.

8.2. Capacitación del Personal

Se sugiere desarrollar programas de capacitación dirigidos al personal encargado del análisis de datos y la gestión de modelos predictivos. La formación especializada permitirá que los colaboradores comprendan en profundidad las herramientas utilizadas, optimicen el uso de técnicas de pronóstico y fortalezcan sus competencias en el manejo de software estadístico y de inteligencia artificial. Un equipo de trabajo capacitado constituye un factor clave para garantizar la correcta implementación de las metodologías propuestas y para aprovechar al máximo los beneficios derivados de ellas.

8.3. Exploración de Nuevas Técnicas

La innovación tecnológica en el campo del análisis de datos avanza a un ritmo acelerado, por lo que resulta fundamental fomentar la exploración de nuevas técnicas y enfoques en el ámbito del pronóstico de la demanda. Se recomienda que futuros estudios consideren la incorporación de modelos híbridos, técnicas de aprendizaje profundo y herramientas de optimización que puedan complementar los métodos tradicionales. Por ejemplo, se pueden emplear métodos como TBATS, diseñado para manejar series con múltiples estacionalidades; DeepAR, basado en redes neuronales recurrentes para pronósticos conjuntos; N-BEATS, una red profunda con alto rendimiento; o enfoques basados en Transformers, capaces de capturar dependencias a largo plazo. Esta apertura a la innovación contribuirá a mantener la competitividad de las organizaciones y a mejorar la eficiencia de los procesos logísticos.

8.4. Mejora en la Calidad de los Datos

La calidad de los datos constituye un elemento esencial para la obtención de resultados confiables. Se aconseja implementar procedimientos de validación, limpieza y preprocesamiento de la información con el fin de minimizar errores, inconsistencias o valores faltantes que puedan afectar la precisión de los modelos. Asimismo, resulta conveniente establecer políticas de gestión de datos que aseguren la disponibilidad de registros completos y actualizados, lo que permitirá contar con insumos sólidos para la generación de pronósticos más exactos.

8.5. Propuesta de nuevo rango de MAPE

Para investigaciones futuras, recomendamos utilizar intervalos de MAPE más refinados, ya que los intervalos actuales son bastante amplios para la previsión de la demanda. En este contexto, hemos preparado una clasificación más detallada, presentada en la Tabla 15, que proporciona un esquema claro para interpretar y evaluar la precisión de los modelos de pronóstico.

La tabla clasifica la capacidad de predicción de los modelos según los valores de MAPE (Mean Absolute Percentage Error), una métrica ampliamente utilizada para medir la precisión en los pronósticos. Cada rango de MAPE define el nivel de exactitud alcanzado, ofreciendo una referencia útil para interpretar el rendimiento de diferentes enfoques de predicción.

En el nivel más alto de precisión, los modelos con un MAPE inferior al 10 % son considerados sobresalientes, ya que sus predicciones son excepcionalmente confiables y se ajustan con gran exactitud a los datos reales, siendo ideales para aplicaciones

críticas. Un MAPE entre el 10 % y 20 % se clasifica como una buena capacidad de predicción, adecuada para la mayoría de las aplicaciones prácticas debido a su solidez.

Para valores de MAPE entre el 20 % y 30 %, la capacidad de predicción se considera aceptable. Aunque la precisión disminuye, estos modelos pueden seguir siendo útiles en contextos donde la exactitud no sea crucial. Sin embargo, cuando el MAPE se encuentra entre el 30 % y 40 %, el modelo demuestra una capacidad de predicción deficiente, lo que limita su utilidad en situaciones que requieren alta precisión. Finalmente, un MAPE superior al 40 % indica una capacidad de predicción inexacta, lo que sugiere la necesidad de ajustes en el modelo o de explorar alternativas. Se recomienda evaluar usando intervalo de MAPE <20 % como margen mínimo de error, con el fin de clasificar de manera más clara la precisión de los pronósticos y facilitar la toma de decisiones operativas.

Tabla 15

Nueva propuesta de intervalo MAPE

Intervalo de MAPE (%)	Nivel de Predicción
<10	Sobresaliente
10–20	Buena
20–30	Aceptable
30–40	Inexacta
>40	Deficiente

Fuente. Elaboración propia

Se recomienda evaluar los modelos utilizando un intervalo de MAPE menor al 20 % como margen mínimo de error, ya que permite clasificar con mayor claridad la precisión de los pronósticos, facilitar la toma de decisiones operativas y servir como referencia más precisa para futuras investigaciones en previsión de la demanda.

Referencias bibliográficas

- Aase, G. R., y Petersen, C. G. (2022). A decision support system for re-slotting a case pick distribution center. *Open Journal of Business and Management*, 10(4), 1923–1935.
- Arnita, A. (2020). Comparison of single exponential smoothing, naive model, and sarima methods for forecasting rainfall in medan. *Jurnal Matematika, Statistika Dan Komputasi*, 17(1), 117–128.
- Bernaola Velarde, D. E., y Varillas Trujillo, P. D. (2022). *Sistema predictivo con machine learning para la gestión de inventario para la empresa inversiones ferreteras mendoza s.a.c* (Tesis Doctoral no publicada). Universidad César Vallejo, Lima, Perú.
- Borucka, A. (2023). Seasonal methods of demand forecasting in the supply chain as support for the company's sustainable growth. *Sustainability*, 15(9). Descargado de <https://www.mdpi.com/2071-1050/15/9/7399> doi: 10.3390/su15097399
- Bustami, Yolanda, A. M., y Thahira, N. (2023). Forecasting non-oil and gas exports in indonesia using double and triple exponential smoothing methods. *International Journal of Industrial Engineering and Engineering Management*, 5(1), 45–49. Descargado de <https://ojs.uaajy.ac.id/index.php/IJIEEM/article/view/6211> doi: 10.24002/ijieem.v5i1.6211
- Castañeda Mauricio, C. R. (2020). Slotting en la gestión de inventarios de la empresa costeo alimentos sac, callao 2020. *Universidad César Vallejo*.
- Delgado Eraso, D. S., Martínez Villalobos, J. E., Ibañez Martinez, B. A., y Cubillos Conde, D. E. (2022). Diseño de un aplicativo para la predicción de demanda y manejo de inventario de productos perecederos. caso de estudio: Restaurante boludo parrilla. *Pontificia Universidad Javeriana*.
- Duque Jaramillo, J. C., Cuellar Molina, M., y Cogollo Flórez, J. M. (2020). Slotting y picking: una revisión de metodologías y tendencias. *Ingeniare. Revista chilena de ingeniería*, 28(3), 514–527.

- Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., y Lin, Q. (2020). Short-term runoff prediction with gru and lstm networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188.
- Goswami, K., y Kandali, A. B. (2020). Electricity demand prediction using data driven forecasting scheme: Arima and sarima for real-time load data of assam. En *2020 international conference on computational performance evaluation (compe)* (p. 570-574). doi: 10.1109/ComPE49325.2020.9200031
- Hamayel, M. J., y Owda, A. Y. (2021). A novel cryptocurrency price prediction model using gru, lstm and bi-lstm machine learning algorithms. *AI*, 2(4), 477–496. Descargado de <https://www.mdpi.com/2673-2688/2/4/30> doi: 10.3390/ai2040030
- Huang, C., y Petukhina, A. (2020). Applied time series analysis and forecasting with python. *International Journal of Science and Research (IJSR).[Internet]*, 9(1), 381–386.
- Karim, M. E., Foysal, M., y Das, S. (2022). Stock price prediction using bi-lstm and gru-based hybrid deep learning approach. En *Proceedings of third doctoral symposium on computational intelligence: Dosci 2022* (pp. 701–711).
- Khairina, D., Daniel, Y., y Widagdo, P. (2021). Comparison of double exponential smoothing and triple exponential smoothing methods in predicting income of local water company. En *Journal of physics: Conference series* (Vol. 1943, p. 012102).
- Koech, E. K., Wagala, A., y Muriithi, D. K. (2021). Triple exponential smoothing techniques: Application to kenya's industrial inputs price index. *Conferences 7th International Research Conference of Chuka University*.
- Kumar Dubey, A., Kumar, A., García-Díaz, V., Kumar Sharma, A., y Kanhaiya, K. (2021). Study and analysis of sarima and lstm in forecasting time series data. *Sustainable Energy Technologies and Assessments*, 47, 101474. Descargado de <https://www.sciencedirect.com/science/article/pii/S2213138821004847> doi: <https://doi.org/10.1016/j.seta.2021.101474>
- Lorenc, A., y Lerher, T. (2020). Pickupsimulo–prototype of intelligent software to support warehouse managers decisions for product allocation problem. *Applied Sciences*, 10(23), 8683.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9(1), 381–386.

- Montero Lopez, R. C. (2025). *Sistema web inteligente basado en machine learning para apoyar la gestión de inventarios en la empresa e.b pareja lecaros s.a.* (Tesis Doctoral no publicada). Universidad Católica Santo Toribio de Mogrovejo, Chiclayo, Perú.
- Nabipour, M., Nayyeri, P., Jabani, H., S., S., y Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8. doi: 10.1109/ACCESS.2020.3015966
- Ozdemir, A. C., Buluş, K., y Zor, K. (2022). Medium- to long-term nickel price forecasting using lstm and gru networks. *Resources Policy*, 78, 102906. Descargado de <https://www.sciencedirect.com/science/article/pii/S0301420722003506> doi: <https://doi.org/10.1016/j.resourpol.2022.102906>
- Parasian, S., Hidayatulah, H., y Romanus, D. (2020). Forecasting acceptance of new students using double exponential smoothing method. *Journal of Critical Review*, 7(1), 300–305.
- Pasupuleti, V., Thuraka, B., Kodete, C. S., y Malisetty, S. (2024). Enhancing supply chain agility and sustainability through machine learning: Optimization techniques for logistics and inventory management. *Logistics*, 8(3). Descargado de <https://www.mdpi.com/2305-6290/8/3/73> doi: 10.3390/logistics8030073
- Peña Valdiviezo, C. D. (2021). Mejora del proceso de preparación de pedidos del operador logístico dinet sa con la aplicación de la metodología de slotting y clasificación abc con enfoque multicriterio para reducir los costos logísticos. *Universidad Privada del Norte*.
- Riatma, D. L., Ari Roshinta, T., Masbahah, Rachman, Y. F., Azizul Hakimi, N., y Alika, R. (2025). Comparison of deep learning algorithms (lstm & gru) for predicting product stocks. En *2025 international conference on computer sciences, engineering, and technology innovation (icocseti)* (p. 1-6). doi: 10.1109/ICoCSETI63724.2025.11019594
- Riawan, P. L., y Pardede, A. M. (2023). Forecasting system for increasing crime at the binjai city police station with the application of the website-based exponential smoothing method. *Journal of Artificial Intelligence and Engineering Applications (JAIEA)*, 3(1), 308–314.
- Richards, G. (2021). *Warehouse management: The definitive guide to improving efficiency and minimizing costs in the modern warehouse*. Kogan Page Publishers.

- Rios, J., Morillo-Torres, D., Olmedo, A., Coronado-Hernandez, J., y Gatica, G. (2022). A faster optimal model slotting in rack positions with mono sku pallet. *Procedia Computer Science*, 203, 588-593. Descargado de <https://www.sciencedirect.com/science/article/pii/S1877050922006895> (17th International Conference on Future Networks and Communications / 19th International Conference on Mobile Systems and Pervasive Computing / 12th International Conference on Sustainable Energy Information Technology (FNC/MobiSPC/SEIT 2022), August 9-11, 2022, Niagara Falls, Ontario, Canada) doi: <https://doi.org/10.1016/j.procs.2022.07.084>
- Robles Rakov, M. A., y Valverde Campos, M. Y. (2021). *Sistema de predicción para incrementar las ventas de accesorios y repuestos automotrices en la empresa ggp automotriz* (Tesis Doctoral no publicada). Universidad de San Martín de Porres, Lima, Perú.
- Sedano Rosales, P. I. (2022). *Desarrollo de un sistema de predicción con machine learning para la gestión logística en megaelectric Perú SAC* (Escuela profesional de ingeniería de sistemas). Universidad César Vallejo, Lima, Perú.
- Thi, N. T., Phung, P. T. K., y Tham, T. T. (2020). Optimizing warehouse storage location assignment under demand uncertainty. En *2020 5th international conference on green technology and sustainable development (gtsd)* (p. 562-568). doi: 10.1109/GTSD50082.2020.9303113
- Vivas, E., Allende-Cid, H., y Salas, R. (2020). A systematic review of statistical and machine learning methods for electrical power forecasting with reported mape score. *Entropy*, 22(12). Descargado de <https://www.mdpi.com/1099-4300/22/12/1412> doi: 10.3390/e22121412
- Wohlin, C., Runeson, P., Höst, M., Ohlsson, M. C., Regnell, B., y Wesslén, A. (2012). *Experimentation in software engineering*. Berlin, Heidelberg: Springer. Descargado de <https://doi.org/10.1007/978-3-642-29044-2> doi: 10.1007/978-3-642-29044-2