



**Universidad
Norbert Wiener**

Powered by **Arizona State University**

**FACULTAD DE INGENIERÍA Y NEGOCIOS
PROGRAMA ACADÉMICO DE INGENIERÍA DE SISTEMAS E
INFORMÁTICA**

Tesis

Aplicación de Machine Learning para la eficiencia en la gestión de inventarios en
el sector farmacéutico limeño, 2024

**Para optar el Título Profesional de
Ingeniero de Sistemas e Informática**

Presentado por:

Autora: Rodas Cortijo, Carmen Liliana

Código ORCID: <https://orcid.org/0000-0002-3008-8803>

Autor: Villacrisis Guerrero, Jahir Jesús

Código ORCID: <https://orcid.org/0000-0003-0751-4154>

Asesor: Mg. Córdova Forero, Julio Alfredo Martin

Código ORCID: <https://orcid.org/0000-0001-5317-8927>

Lima – Perú

2025

 Universidad Norbert Wiener	DECLARACIÓN JURADA DE AUTORIA Y DE ORIGINALIDAD DEL TRABAJO DE INVESTIGACIÓN		
	CÓDIGO: UPNW-GRA-FOR-033	VERSIÓN: 01 REVISIÓN: 01	FECHA: 08/11/2022

Yo Carmen Lilliana Rodas Cortijo egresado de la Facultad de **INGENIERIA Y NEGOCIOS** Elija un elemento y Escuela Académica Profesional de **Ingenierías** de la Universidad privada Norbert Wiener declaro que el trabajo de investigación “Aplicación de Machine Learning para la Eficiencia en la Gestión de Inventarios en el Sector Farmacéutico Limeño, 2024.” Asesorado por el docente: Mg. Julio Alfredo Cordova Forero DNI 09924829 ORCID 0000-0001-5317-8927 tiene un índice de similitud de **15 (quince) %** con código 14912:469303179 verificable en el reporte de originalidad del software Turnitin.

Así mismo:

1. Se ha mencionado todas las fuentes utilizadas, identificando correctamente las citas textuales o paráfrasis provenientes de otras fuentes.
2. No he utilizado ninguna otra fuente distinta de aquella señalada en el trabajo.
3. Se autoriza que el trabajo puede ser revisado en búsqueda de plagios.
4. El porcentaje señalado es el mismo que arrojó al momento de indexar, grabar o hacer el depósito en el turnitin de la universidad y,
5. Asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión en la información aportada, por lo cual nos sometemos a lo dispuesto en las normas del reglamento vigente de la universidad.

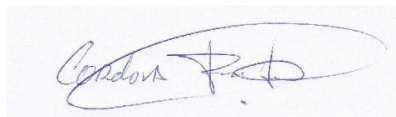


.....

Firma de autor 1
 Jahir Jesus Villacrisis Guerrero
 DNI: 75897946




Firma de autor 2
 Carmen Lilliana Rodas Cortijo
 DNI: 40470854



.....

 Firma
 Mg. Julio Alfredo Cordova Forero
 DNI: 09924829

Lima,de..... de.....

 Universidad Norbert Wiener	DECLARACIÓN JURADA DE AUTORIA Y DE ORIGINALIDAD DEL TRABAJO DE INVESTIGACIÓN		
	CÓDIGO: UPNW-GRA-FOR-033	VERSIÓN: 01 REVISIÓN: 01	FECHA: 08/11/2022

Yo, Jahir Jesus Villacrisis Guerrero egresado de la Facultad de **INGENIERIA Y NEGOCIOS** y Escuela Académica Profesional de **Ingenierías** de la Universidad privada Norbert Wiener declaro que el trabajo de investigación “Aplicación de Machine Learning para la Eficiencia en la Gestión de Inventarios en el Sector Farmacéutico Limeño, 2024” Asesorado por el docente: Mg. Julio Alfredo Cordova Forero DNI 09924829 ORCID 0000-0001-5317-8927 tiene un índice de similitud de **15 (quince) %** con código 14912:469303179 verificable en el reporte de originalidad del software Turnitin.

Así mismo:

1. Se ha mencionado todas las fuentes utilizadas, identificando correctamente las citas textuales o paráfrasis provenientes de otras fuentes.
2. No he utilizado ninguna otra fuente distinta de aquella señalada en el trabajo.
3. Se autoriza que el trabajo puede ser revisado en búsqueda de plagios.
4. El porcentaje señalado es el mismo que arrojó al momento de indexar, grabar o hacer el depósito en el turnitin de la universidad y,
5. Asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión en la información aportada, por lo cual nos sometemos a lo dispuesto en las normas del reglamento vigente de la universidad.

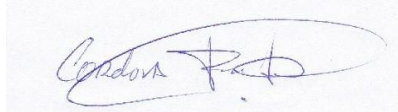


.....

Firma de autor 1
 Jahir Jesus Villacrisis Guerrero
 DNI: 75897946



Firma de autor 2
 Carmen Lilliana Rodas Cortijo
 DNI: 40470854



.....
 Firma
 Mg. Julio Alfredo Cordova Forero
 DNI: 09924829

Lima,de..... de.....

Dedicatoria

El proyecto de tesis va dirigido y dedicado a nuestras familias, quienes nos brindaron el apoyo emocional necesario para poder culminarlo satisfactoriamente.

Agradecimiento

Queremos expresar nuestro más profundo agradecimiento a nuestros amados padres, quienes han sido el pilar fundamental en nuestras vidas y en este proceso académico. Su amor incondicional, apoyo constante y sacrificios han sido nuestra guía en cada paso del camino. Este logro es también suyo, y deseamos retribuirles todo lo que nos han brindado. Este proyecto de tesis es un homenaje a su dedicación y amor inquebrantable.

CAPÍTULO I: EL PROBLEMA.....	10
1.1. Planteamiento del problema.....	10
1.2. Formulación del problema.....	14
1.2.1. Problema general.....	14
1.2.2. Problemas específicos.....	14
1.3. Objetivos de la investigación.....	15
1.3.1. Objetivo general.....	15
1.3.2. Objetivos específicos.....	15
1.4. Justificación de la investigación.....	15
1.4.1. Teórica.....	15
1.4.2. Metodológica.....	16
1.4.3. Practica.....	17
1.5. Limitaciones de la investigación.....	17
CAPITULO II MARCO TEORICO	18
2.1. Antecedentes de la investigación.....	18
2.2. Bases teóricas.....	21
2.3. Formulación de hipótesis.....	44
2.3.1. Hipótesis general.....	44
2.3.2. Hipótesis específica.....	44
CAPÍTULO III: METODOLOGÍA.....	45
3.1. Método de Investigación.....	45
3.2. Tipo de investigación.....	46
3.3. Diseño de la investigación.....	47
3.4. Población, muestra y muestreo.....	48
3.5. Variables y Operacionalización.....	50
3.6. Técnicas e instrumentos de recolección de datos.....	51
3.6.1. Técnica.....	51
3.6.2. Descripción de instrumentos.....	51
3.6.3. Validación.....	52
3.6.4. Confiabilidad.....	52

3.7.	Plan de procesamiento y análisis de datos.....	73
3.8.	Aspectos éticos.....	73
3.9.	ASPECTOS ADMINISTRATIVOS.....	74
3.9.1	Cronogramas de actividades	74
CAPÍTULO IV: PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS		76
4.1	Resultados	76
4.1.1.	Análisis descriptivo de los resultados	76
4.2	Desarrollo del Sistema empleando la metodología SCRUM.....	90
4.2.1.	Interfaz principal del sistema	91

Resumen

La gestión de inventarios en el sector farmacéutico enfrenta desafíos importantes, como la variabilidad en la demanda y las estrictas regulaciones. Este estudio analiza cómo el uso de Machine Learning (ML) puede mejorar la eficiencia en la gestión de inventarios en Lima Metropolitana durante 2024. El objetivo principal es determinar el impacto del ML en este proceso, evaluando su capacidad para predecir la demanda, reducir desabastecimientos, mejorar la rotación y optimizar los niveles de stock. Esto es clave, considerando que alrededor del 70% de las empresas farmacéuticas en Lima sufren desabastecimientos frecuentes, afectando tanto su operatividad como la salud pública. La investigación adopta un diseño experimental, utilizando registros históricos de una empresa farmacéutica (1,000 datos, con una muestra de 278) para analizar el efecto del ML mediante herramientas estadísticas. Se espera demostrar que la implementación de ML mejora indicadores clave como el stock óptimo y la tasa de rotación, reduciendo también los costos operativos. Finalmente, este trabajo no solo propone soluciones concretas a problemáticas actuales del sector, sino que también abre la puerta a nuevas investigaciones sobre el uso de tecnologías inteligentes en la cadena de suministro farmacéutica.

Palabras claves: Machine Learning, gestión de inventarios, sector farmacéutico, predicción de la demanda, optimización de stock

Abstract

Inventory management in the pharmaceutical sector faces significant challenges, such as variability in demand and strict regulations. This study analyzes how the use of Machine Learning (ML) can improve the efficiency of inventory management in Metropolitan Lima during 2024. The main objective is to determine the impact of ML in this process, evaluating its ability to predict demand, reduce stock-outs, improve turnover and optimize stock levels. This is key, considering that around

70% of pharmaceutical companies in Lima suffer frequent stock-outs, affecting both their operations and public health. The research adopts an experimental design, using historical records of a pharmaceutical company (1,000 data, with a sample of 278) to analyze the effect of ML using statistical tools. It is expected to demonstrate that the implementation of ML improves key indicators such as optimal stock and turnover rate, also reducing operating costs. Finally, this work not only proposes concrete solutions to current problems in the sector, but also opens the door to new research on the use of intelligent technologies in the pharmaceutical supply chain.

Keywords: Machine Learning, inventory management, pharmaceutical sector, demand prediction, stock optimization.

Introducción

La gestión de inventarios es un aspecto crítico en el funcionamiento de las empresas farmacéuticas, y la presente investigación se centra en abordar las serias deficiencias que enfrenta una empresa en este ámbito. Actualmente, la falta de un sistema efectivo para gestionar los productos con stock excesivo, aquellos de lenta rotación y los que están próximos a vencer ha generado no solo pérdidas económicas significativas, sino también insatisfacción entre los clientes. La carencia de modelos predictivos y el registro inexacto de datos limitan la capacidad de la empresa para mantener un stock óptimo, lo que resulta en desabastecimiento de medicamentos esenciales y un control deficiente sobre las existencias.

Además, la resistencia al cambio y el uso de procesos manuales contribuyen a una gestión ineficaz, sobrecargando al personal y dificultando la elaboración de reportes precisos. Si estas deficiencias persisten, se anticipa un aumento en el sobre stock de productos de lenta rotación y un deterioro en la imagen de la empresa debido a la insatisfacción del cliente. Por lo tanto, esta tesis tiene como objetivo proponer un sistema integral que mejore la gestión de inventarios, optimizando así los procesos operativos y garantizando una atención adecuada a los usuarios. A través de esta investigación, se espera contribuir a la solución de los problemas identificados y fomentar una cultura organizacional orientada a la mejora continua en la gestión farmacéutica.

El propósito del estudio es la Aplicación de Machine Learning para la Eficiencia en la Gestión de Inventarios en el Sector Farmacéutico Limeño, 2024. La misma se ha dividido en cinco capítulos.

El capítulo I, se plasma el planteamiento del problema, formulación del problema, los objetivos, la justificación y las limitaciones de la investigación.

El capítulo II, se plasma el marco teórico, presentación de los antecedentes, las bases teóricas y la formulación de la hipótesis.

El capítulo III, trata de la metodología que se usó para el desarrollo, la población, la muestra, las técnicas e instrumentos de investigación.

El capítulo IV, comprende el análisis, pruebas y discusión de los resultados.

El capítulo V, presenta las conclusiones y recomendaciones.

Consecuentemente se presenta, las referencias bibliográficas y los anexos.

CAPÍTULO I: EL PROBLEMA

1.1. Planteamiento del problema

Hoy en día, la gestión eficiente de inventarios es un aspecto crucial para el éxito de las empresas en el sector farmacéutico, especialmente en un entorno competitivo. La variabilidad en la demanda y la necesidad de cumplir con regulaciones estrictas plantean desafíos significativos para las empresas farmacéuticas. En este contexto, la implementación de técnicas de Machine Learning (ML) emerge como una solución innovadora para optimizar la gestión de inventarios. Al integrar ML en la gestión de inventarios, las empresas pueden anticipar fluctuaciones en la demanda, optimizar sus niveles de stock y mejorar su eficiencia operativa. Este enfoque no solo aporta ventajas competitivas, sino que también asegura la disponibilidad de productos esenciales, garantizando así una atención al cliente de calidad. El ML permite analizar grandes volúmenes de datos históricos y en tiempo real, identificando patrones y tendencias que facilitan la planificación de inventarios y minimizan el riesgo de desabastecimiento o sobre stock, situaciones que pueden resultar costosas para las empresas.

La variable "Machine Learning" ha cobrado una importancia significativa en Europa, donde se estima que el mercado de inteligencia artificial alcanzará los 126 mil millones de euros para 2025, con un crecimiento anual del 20% (Statista, 2023). En Latinoamérica, el uso de Machine Learning ha crecido un 25% entre 2020 y 2022, destacándose en sectores como la salud y la logística, lo que refleja su potencial para optimizar procesos (Banco Central de Reserva del Perú, 2022). En Perú, se proyecta que la inversión en tecnologías de inteligencia artificial, incluido el Machine Learning, alcanzará los 500 millones de dólares en 2024, lo que representa un aumento del 30% respecto a 2023 (Ministerio de Economía y Finanzas 2023). En Lima, específicamente, la adopción de Machine Learning en el sector farmacéutico ha permitido reducir los tiempos de control de

inventarios en un 15%, mejorando la eficiencia operativa (Diario Gestión, 2024). Sin embargo, a pesar de estos avances, persisten problemas en Lima Metropolitana, como la falta de infraestructura adecuada y la escasez de capacitación en tecnologías digitales, lo que limita el potencial de estas herramientas. Por otro lado, la implementación de Machine Learning podría transformar el sector farmacéutico, facilitando un acceso más rápido y eficiente a medicamentos, lo que es crucial para la salud pública.

La variable "Machine Learning" presenta diversos problemas en Europa, donde se estima que el 30% de las empresas aún carecen de una estrategia clara para su implementación (European Commission, 2022). En Asia, la adopción de esta tecnología se ve obstaculizada por la escasez de talento especializado, con un 40% de las organizaciones reportando dificultades para encontrar profesionales capacitados (Asia-Pacific Economic Cooperation, 2023). En Latinoamérica, las inversiones en Machine Learning han crecido un 25% en los últimos dos años, pero la infraestructura tecnológica sigue siendo un desafío crítico (Inter-American Development Bank, 2021). En Perú, el sector empresarial enfrenta un rezago significativo, con solo un 15% de las empresas utilizando algoritmos de aprendizaje automático en sus operaciones (Instituto Nacional de Estadística e Informática, 2023). A nivel de Lima, la situación es aún más preocupante, ya que el 50% de las empresas informan no tener acceso a herramientas adecuadas para implementar soluciones de Machine Learning (Diario Gestión, 2023). Esta falta de preparación y recursos en el sector farmacéutico de Lima metropolitana es alarmante, ya que limita la capacidad de innovación y mejora en la atención al cliente, lo que podría tener un impacto negativo en la salud pública.

La gestión de inventarios enfrenta serios desafíos a nivel global. En Europa, el 35% de las empresas reportan ineficiencias en sus sistemas de gestión de inventarios, lo que afecta su competitividad (European Commission, 2022). En Asia, la falta de visibilidad en la cadena de

suministro ha llevado a un incremento del 20% en los costos de almacenamiento, afectando la rentabilidad de las empresas (Asian Development Bank, 2023). En Latinoamérica, se estima que el 40% de las empresas no utilizan tecnologías avanzadas para la gestión de inventarios, lo que limita su capacidad de respuesta ante cambios en la demanda (Inter-American Development Bank, 2021). En Perú, el 60% de las empresas pequeñas y medianas enfrentan problemas significativos en la gestión de inventarios, lo que se traduce en pérdidas económicas considerables (Instituto Nacional de Estadística e Informática, 2023). A nivel de Lima, un 70% de las empresas del sector farmacéutico reportan desabastecimiento frecuente, lo que pone en riesgo la salud pública (Diario Gestión, 2023). Esta situación es alarmante, ya que la ineficiencia en la gestión de inventarios en el sector farmacéutico de Lima metropolitana no solo afecta la rentabilidad de las empresas, sino que también compromete el acceso a medicamentos esenciales para la población.

La falta de atención a los problemas relacionados con "Machine Learning" y la gestión de inventarios en el sector salud podría tener consecuencias graves. En Europa, se estima que el 30% de los hospitales no implementan adecuadamente tecnologías de "Machine Learning", lo que podría resultar en un aumento del 20% en errores médicos para 2025 (European Commission, 2022). En Latinoamérica, la ineficiencia en la gestión de inventarios ha llevado a un desabastecimiento del 40% de medicamentos esenciales, afectando la atención médica (Pan American Health Organization, 2023). En Perú, se ha reportado que el 50% de los centros de salud carecen de sistemas eficientes de gestión de inventarios, lo que podría incrementar los costos operativos en un 15% (Ministerio de Salud, 2023). En Lima, específicamente, la falta de adopción de "Machine Learning" en la gestión de salud pública podría resultar en un 25% de pacientes sin el diagnóstico adecuado, lo que afectaría gravemente la calidad de atención (Instituto Nacional de Estadística e Informática, 2023). La crítica a esta situación es que, si bien hay un potencial significativo para

mejorar la salud pública mediante estas tecnologías, la falta de inversión y capacitación en Lima Metropolitana limita las oportunidades de avance, perpetuando problemas de ineficiencia y desabastecimiento que afectan a la población más vulnerable.

La empresa farmacéutica objeto de estudio actualmente enfrenta serias deficiencias en su sistema de gestión de inventarios. En particular, carece de un mecanismo efectivo que permita verificar adecuadamente los productos con stock excesivo, aquellos de lenta rotación y los que están próximos a vencer. Estos desafíos no solo generan pérdidas económicas, sino que también provocan insatisfacción entre los clientes. La ausencia de un sistema eficiente limita la búsqueda óptima de productos, lo que resulta en una gestión ineficaz por parte del personal y un creciente descontento entre los usuarios. Se detallan a continuación los problemas encontrados: (a) la carencia de modelos predictivos, lo que conlleva a un desabastecimiento de medicamentos básicos y genera un control deficiente de los requisitos para mantener el stock óptimo de los diversos productos farmacéuticos; (b) el registro de datos inexactos, debido a la falta de actualización en tiempo real, lo que requiere la implementación de procedimientos estrictos antes de la comercialización para supervisar las existencias de productos farmacéuticos vencidos. Por esta razón, la importancia de una gestión efectiva de inventarios radica en contar con un registro apropiado. En muchos casos, el uso de procesos manuales conduce a una gestión y control inapropiados de las existencias. Por último, (c) la resistencia al cambio puede resultar en una disminución de la productividad del equipo, lo que se traduce en bajo rendimiento y en el incumplimiento de los objetivos, afectando así la conservación de los medicamentos. Además, el sistema obsoleto actual no permite un control adecuado; estos problemas repercuten en los trabajadores, quienes enfrentan una sobrecarga laboral al depender únicamente de información manual, lo que retrasa la elaboración de reportes sobre los productos existentes.

Si la empresa farmacéutica continúa trabajando con las mismas deficiencias en su gestión de inventarios, los efectos seguirán afectando: (a) un sobre stock de los productos de lenta rotación, provocará altas probabilidades de contar con productos vencidos, básicamente por no tener un control al desconocer los stocks reales, esto generará pérdidas en la empresa farmacéutica; (b) la pérdida o alteración de la información podría ocasionar una ineficiente gestión en la toma de decisiones por no seguir con un adecuado control de los productos farmacéuticos al no planificar de forma adecuada; (c) la pérdida de las ventas sumado a la insatisfacción de los clientes generará el deterioro de la imagen de la empresa, así como pérdidas económicas todo ello ocasionará una falta de control en los medicamentos.

1.2. Formulación del problema

1.2.1. Problema general

¿Cómo puede la aplicación de Machine Learning contribuir a mejorar la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024?

1.2.2. Problemas específicos

PE1: ¿Qué impacto tiene la predicción de la demanda en la reducción de desabastecimientos en el sector farmacéutico limeño, 2024?

PE2: ¿Qué algoritmo de Machine Learning puede ser implementado para mejorar la tasa de rotación en la gestión de inventarios en el sector farmacéutico limeño, 2024?

PE3: ¿Cómo puede el Machine Learning contribuir en la optimización de los stocks a los niveles de inventario en el sector farmacéutico limeño, 2024?

1.3. Objetivos de la investigación

1.3.1. Objetivo general

Determinar cómo Machine Learning mejora la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024.

1.3.2. Objetivos específicos

OE1: Determinar el impacto de la predicción de la demanda en la reducción de desabastecimientos en el sector farmacéutico limeño, 2024.

OE2: Determinar qué algoritmo de Machine Learning se puede implementar para mejorar la tasa de rotación en la gestión de inventarios en el sector farmacéutico limeño, 2024.

OE3: Determinar cómo Machine Learning mejora el stock óptimo en el sector farmacéutico limeño, 2024.

1.4. Justificación de la investigación

1.4.1. Teórica

La teoría general de sistemas cuyo representante es Von Bertalanffy en el año de 1968 sostiene un marco útil que optimiza recursos y mejora la adaptación de los sistemas al entorno. Esta teoría se aplica para mejorar el control de actividades, facilitando el acceso a información y reduciendo costos (Hamidian y Ospino, 2015). La tecnología es clave para optimizar procesos y gestionar inventarios eficientemente (Álvarez, 2015). La teoría enfatiza un enfoque robusto que proporciona una base que contribuye a entender la complejidad del sistema de inventarios resaltando la importancia de la adaptabilidad e los diversos elementos del proceso.

La teoría del aprendizaje estadístico establece que el aprendizaje se basa en la minimización de errores para generalizar a partir de datos limitados fue expuesto por Vapnik, 1998. Esto permite prever la demanda futura utilizando datos históricos, mejorando así la eficiencia operativa y el

servicio al cliente (Bishop, 2006). Este enfoque permite a las empresas ajustar sus modelos y la mejora continua de sus predicciones.

La teoría de la información propuesta por Shannon en el año de 1948 mide la incertidumbre en los datos a través de la entropía, lo que optimiza decisiones en la gestión de inventarios. Esto permite a las empresas analizar patrones de demanda y ajustar niveles de stock (Bishop, 2006). Con esta teoría se podrá analizar y medir la información en los campos de las telecomunicaciones, procesamiento de datos optimizando la transmisión eficiente de los datos.

La teoría general de inventarios resalta la importancia del control de inventarios para reducir costos (Vidal, 2010). La gestión adecuada implica el uso de tecnología que permita obtener información en tiempo real y evitar desabastecimientos (Salas et al., 2019). Esta teoría proporciona un entendimiento de cómo gestionar los recursos de la empresa.

Finalmente, (Mauleón 2013) define el almacén como un lugar crucial para controlar stocks, (Fernández, 2019) propone modelos que mejoran tiempos de espera y reducen costos. (Silver *et al.* 2021) enfatizan que una gestión efectiva de inventarios asegura la disponibilidad y mejora del servicio al cliente mediante el uso de algoritmos de Machine Learning para ajustar niveles de stock en tiempo real (Ziegler, 2020).

1.4.2. Metodológica

El presente estudio, denominado “Aplicación de Machine Learning para la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024”, adopta un enfoque cuantitativo, el cual trata de un experimento observable y medible, orientado a obtener resultados precisos y objetivos. Este enfoque permite evidenciar mejoras en la gestión de inventarios, facilitando la medición confiable de variables y el análisis de los resultados mediante herramientas estadísticas. Asimismo, plantea un diseño experimental que garantiza la confiabilidad y validez de las mejoras implementadas en la

gestión de inventarios, a través de la praxis. Finalmente, el estudio busca mejorar el stock óptimo, la tasa de rotación y predicción de stocks. Asimismo, la investigación aportará conocimiento a futuros profesionales que busquen optimizar la gestión de inventarios mediante la aplicación de Machine Learning.

1.4.3. Practica

Respecto a la relevancia práctica, el estudio presenta los siguientes beneficios en la gestión de inventarios de una empresa farmacéutica: (i) la mejora la identificación de los medicamentos; (ii) la mejora en el control de la fecha de vencimiento; (iii) la ubicación eficiente; (iv) la información en tiempo real; (v) la capacitación del personal; (vi) la mejora del servicio al cliente; (vii) el aumento de la rentabilidad. Por último, con los resultados del estudio se espera lograr un contraste positivo mediante el cumplimiento de los objetivos específicos a nivel estadístico que garantice la mejora de la gestión de inventarios en una empresa farmacéutica.

1.5. Limitaciones de la investigación

El presente estudio presentó diversas dificultades que permitieron superarse a tiempo para continuar con el estudio. Dentro de ello tenemos: (i) el conseguir la validación de los expertos para la aprobación de los instrumentos; (ii) el conseguir la autorización formal de la empresa; (iii) el superar lo mínimo del turnitin como punto de aprobación; (iv) el repasar la estadística inferencial; (v) la falta de disponibilidad de tiempo durante la semana del personal encargado de la farmacia. Por otro lado, el estudio será desarrollado en una empresa farmacéutica ubicada en el distrito del Cercado de Lima. Así mismo, el estudio será efectuado desde agosto hasta diciembre del 2024, cuyo monto asciende a S./ 5000,00 soles que serán ejecutadas en un 100 % por el tesista.

CAPITULO II MARCO TEORICO

2.1. Antecedentes de la investigación

Nacionales

Según (Gonzales y Pérez 2023) sostuvieron que, su estudio se centró en la “Implementación de un sistema de Machine Learning para mejorar la gestión de inventarios en A&M Confecciones”, donde se han identificado problemas en el área de almacén. La investigación tuvo como objetivo evaluar los indicadores de requerimiento y despacho para encontrar soluciones que no afecten el desarrollo del área. Se buscó determinar el impacto positivo del sistema en la gestión de inventarios durante 2023. Para llevar a cabo el proyecto, se utilizó la metodología XP (Extreme Programming) en un sistema web, empleando tecnologías como PHP, Jupyter Notebook, MySQL y Visual Studio Code. La investigación fue de tipo aplicada, con un diseño pre experimental y un enfoque cuantitativo, considerando una muestra de 30 registros por conveniencia debido a la variabilidad de la población observada. Los datos se recolectaron mediante observación los cuales se validaron con expertos. Las pruebas que utilizaron fue la prueba de normalidad para la variable y en los indicadores de pre y post, se tomó en cuenta los grados de libertad los que fueron menores a 50 por lo que se empleó Shapiro-Wilk, se evidenció los resultados de dicha prueba por lo que la variable resultó de una distribución normal, procediendo aplicar la prueba paramétrica T de Student. Los resultados mostraron que el indicador de requerimiento aumentó más del doble en comparación con los registros anteriores, y el indicador de despacho presentó mejoras similares. Estos hallazgos permiten concluir que el sistema basado en Machine Learning mejora efectivamente la gestión de inventarios en A&M Confecciones. Además, se sugiere la posibilidad de aplicar este sistema en otras áreas de la empresa para seguir optimizando procesos y mejorar su competitividad a nivel nacional.

En su investigación efectuada por (Zavala y Sanchez, 2023) el objetivo principal de esta investigación fue analizado la “Relación entre la IA y la optimización de la cadena logística en

almacenes de empresas farmacéuticas importadoras durante 2018-2021". Se utilizó un enfoque cuantitativo, aplicando encuestas a profesionales del sector con experiencia en logística. Los datos fueron procesados con SPSS, comprobándose a través de la prueba de la normalidad utilizada de Shapiro-Wilk y la de Kolmogorov-Smirnov, determinó la optimización de la cadena logística en las empresas farmacéuticas, con el objetivo de utilizar el coeficiente correcto de correlación y los resultados mostraron una relación positiva entre las variables estudiadas, finalmente se concluye que la implementación de IA puede mejorar significativamente la gestión logística en el sector farmacéutico, recomendando considerar la inversión necesaria y la capacitación del personal para su correcta utilización.

Para (Aguinaga y Salvador 2023), desarrollaron un proyecto que se centró en crear un sistema inteligente que utiliza Machine Learning para predecir inundaciones en áreas agrícolas de Perú. Para llevar a cabo el pronóstico y evaluar su efectividad, se aplicaron tres métricas de precisión: la raíz del error cuadrático medio (RMSE) y el error porcentual medio absoluto (MAPE), mediante el uso de redes neuronales LSTM (Long Short-Term Memory). Se determinó que el sistema logró una precisión superior al 94%, con un RMSE por debajo de 8 y un MAPE inferior al 9% en todos los pronósticos relacionados con inundaciones. En conclusión, la implementación de este sistema inteligente basado en Machine Learning ha permitido realizar predicciones eficientes con un alto grado de exactitud.

Según (Huaman, 2022), su investigación tuvo como objetivo implementar un sistema de data mining que permita optimizar la gestión de inventarios en una empresa en el distrito de Santa Anita, realizó un diseño experimental, usando una metodología aplicada conocida como CRISP-DM con un enfoque sistemático cuya técnica empleada fue la de observación y cuyos resultados permitieron la mejora del rendimiento activo en un 8.67% aumentando la rotación de inventarios a

12.21, además su rendimiento de inventarios se incrementó a 1.41%, se concluyó pudo contribuir a mejorar la eficiencia y reducción de costos.

Internacionales

Según (Lestario, 2024) llevó a cabo una investigación que aborda la mejora de la gestión de inventarios en Versuni mediante el uso de Machine Learning para la predicción de demanda y optimización del tamaño de lote. El objetivo principal fue desarrollar modelos que mejoren la precisión de las previsiones de inventario y eviten el desabastecimiento. La investigación se clasificó como aplicada y utilizó un enfoque cuantitativo con un diseño no experimental. La población del estudio incluyó los productos gestionados por Versuni, utilizando datos históricos de ventas y niveles de inventario como muestra. Los resultados mostraron que los modelos de Machine Learning, especialmente las Redes Neuronales, lograron una reducción del 76% en el error cuadrático medio (MSE) y un 26% en el error absoluto medio (MAE), mejorando significativamente la precisión en las previsiones de demanda y reduciendo costos totales.

En la investigación de (Bernaola y Varillas, 2022) desarrollaron un “Sistema predictivo utilizando Machine Learning para mejorar la gestión de inventarios en Inversiones Ferretera Mendoza S.A.C.”, los cuales abordaron problemas de discrepancias entre las cantidades físicas y lógicas de productos. El objetivo principal fue implementar un sistema que optimizara el manejo de entradas y salidas de productos. La investigación se clasificó como aplicada y utilizó un enfoque cuantitativo, siguiendo la metodología CRISP-DM. La población del estudio consistió en 190 productos, seleccionando una muestra aleatoria de 30 artículos para el análisis. Se empleó una técnica de fichaje para recopilar datos sobre el rendimiento del inventario antes y después de la implementación del sistema. Los resultados mostraron que la implementación del sistema predictivo con Machine Learning redujo el tiempo y costo asociados a la gestión de inventarios, mejorando el manejo general del stock en la empresa.

De acuerdo con (Mas Jaumot, 2021) desarrolló un modelo predictivo basado en algoritmos de Machine Learning con el objetivo de predecir el nivel óptimo de stock en el sector farmacéutico, buscando mejorar la gestión de inventarios y evitar roturas de stock. La investigación, clasificada como aplicada y de nivel cuantitativo, utilizó un diseño no experimental y se centró en una población de empresas farmacéuticas que enfrentan problemas en la gestión de inventarios. Se seleccionó una muestra por conveniencia que incluyó 50 registros históricos de inventario y ventas, y se empleó un cuestionario estructurado para recopilar datos relevantes. Los resultados mostraron que el modelo predictivo mejora significativamente la gestión del inventario, reduciendo costos operativos y mejorando el servicio al cliente.

Según (Zambrano, 2019) diseñó un modelo predictivo del stock de medicamentos utilizando algoritmos de Machine Learning con el objetivo de optimizar las estrategias de volumen de ventas en laboratorios. La investigación se clasifica como aplicada y utiliza un enfoque cuantitativo, con un diseño no experimental que permite observar y analizar la situación actual sin manipular variables. La población del estudio incluye laboratorios farmacéuticos que enfrentan desafíos en la gestión de inventarios, y se seleccionó una muestra por conveniencia que abarca datos históricos sobre ventas y stock. Se empleó un cuestionario estructurado como instrumento para recopilar información relevante para el modelo. Los resultados indicaron que el uso de técnicas de Machine Learning mejora la precisión en las proyecciones de stock, facilitando la toma de decisiones y reduciendo costos asociados a la inmovilización de inventarios. Como conclusión, se determinó que la implementación del modelo predictivo puede contribuir significativamente a mejorar la gestión del inventario en los laboratorios.

2.2. Bases teóricas

Variable Independiente: Machine Learning

Se define como el proceso por el cual los algoritmos permiten a las máquinas aprender de los datos sin ser programadas explícitamente (Jordan y Mitchell, 2015). Es decir, este tipo de lenguaje de programación permitirá que las máquinas puedan entender las instrucciones que se le den para poder resolver algún problema. De acuerdo con (Espino, 2021), esta técnica se basa en el desarrollo de modelos que pueden realizar predicciones a partir de patrones observados en los datos. En consecuencia, dichos modelos desarrollaran predicciones a partir de datos que puedan contener la información necesaria para obtener un buen pronóstico. Según (Vasudevan *et al.* 2021), los avances en el aprendizaje profundo han revolucionado aplicaciones en diversas áreas, desde la visión por computadora hasta el procesamiento del lenguaje natural. En este caso, los progresos en el aprendizaje han transformado radicalmente las aplicaciones en los diversos campos. Por otro lado, (Chowdhary, 2019) destacó que, machine learning mejora la toma de decisiones al ofrecer análisis predictivos en tiempo real. Así pues, se resaltó la optimización de machine learning en la toma de decisiones proporcionando en tiempo real las predicciones. En un contexto empresarial, (Ezugwu *et al.*, 2023) argumentan que, estas herramientas permiten optimizar procesos y reducir costos. En resumen, se sostiene que las herramientas pueden facilitar la mejora de los procesos disminuyendo los costos Finalmente, como mencionan (Daumé et al., 2019) hace referencia que es crucial considerar los aspectos éticos y de privacidad en la implementación de estas tecnologías. Finalmente, es fundamental tener en cuenta los aspectos éticos y la privacidad de estas tecnologías al ser implementadas.

2.2 Teorías:

Se pueden mencionar tres teorías que están relacionadas con machine learning:

Teoría del aprendizaje inductivo: Para (Gold, 1967) introdujo el concepto de identificación en el límite, explorando cómo las máquinas pueden aprender un lenguaje a partir de ejemplos, lo cual es un aspecto importante del aprendizaje.

Para el autor Gordon Plotkin en el año de 1972 nos dice que, su teoría establece fundamentos teóricos para el aprendizaje inductivo en un contexto lógico, abordando cómo los sistemas pueden aprender de ejemplos y generalizar a partir de ellos.

Según (Michalski, 1983) su teoría estuvo basada en ejemplos y en los métodos de aprendizaje en reglas, sentando las bases para futuros avances en el aprendizaje inductivo y los sistemas de IA.

En su obra (Vapnik, 1995) presenta el marco de la teoría del aprendizaje estadístico y discute la dimensión VC, ambos conceptos fundamentales permitieron entender los límites y la capacidad de generalización del aprendizaje inductivo. Es decir, estas aportaciones han sido muy importantes para el avance de machine learning los cuales desarrollaran nuevas técnicas y algoritmos en el campo.

Teoría del modelo probablemente aproximadamente correcto (PAC): Para (Kearns y Vazirani, 1994) exploraron las bases teóricas y las aplicaciones del aprendizaje PAC en diversos algoritmos. Según Leslie Valiant en su libro publicado en el año 2013 describe que este modelo proporciona un marco que permita entender el aprendizaje automático, definiendo condiciones bajo las cuales un algoritmo puede aprender de manera efectiva y garantizar que su rendimiento se mantenga dentro de ciertos límites probabilísticos.

Según los autores (Shalev y Shai, 2014) su libro se centró en el aprendizaje basado en boosting en donde se explica los fundamentos del modelo PAC y la mejora en la precisión de los modelos de aprendizaje. Por ende, estas teorías se enfocan en relacionar las clases entre sí, dicho problema es

una tarea resuelta por una computadora mediante la aplicación empleando pasos matemáticos como un algoritmo.

Teoría de complejidad del aprendizaje: Según (Vapnik, 1995) desarrolló el marco de la teoría estadística de aprendizaje incluye conceptos claves sobre la complejidad y la capacidad en la minimización del riesgo. Este trabajo es fundamental en el desarrollo de máquinas de vectores de soporte y márgenes de clasificación.

Para el autor Tom Mitchell en 1997, define formalmente el aprendizaje automático y discute como medir la complejidad de los algoritmos de aprendizaje, así como su capacidad para aprender de la experiencia en relación con tareas específicas.

Para (Schapire y Freund, 2012) investigaron el aprendizaje de conjuntos y el método Boosting que combina los modelos simples mejorando el rendimiento, esto permite aumentar la robustez y la precisión.

En esta teoría se destaca la importancia de la capacidad de definir límites y posibilidades en los sistemas de aprendizaje al diseñar algoritmos que sean más efectivos eligiendo modelos apropiados de acuerdo a las necesidades del problema.

2.3 El principal concepto de la variable:

Según el autor (Pantaleo, 2016) abordó temas relacionados con la calidad en el desarrollo del software, incluyendo aspectos como la métrica, mejora continua y la integración de herramientas automatizadas para asegurar la calidad.

Entre las características de la calidad en el desarrollo de software tenemos:

Confiabilidad: Es la capacidad del software para funcionar sin fallos en un entorno determinado durante un periodo específico.

Portabilidad: Capacidad del software para poder funcionar en diversos entornos y plataformas.

Mantenibilidad: Es la facilidad para mejorar y modificar el software.

Escalabilidad: Capacidad del software que permite manejar el crecimiento en la carga de trabajo sin que pueda comprometer el funcionamiento.

Modelos de calidad

Modelo McCall: Propone un enfoque basado en tres perspectivas que se enuncian como: operaciones del producto, revisión del producto y la transición de este, a su vez evalúa atributos como: corrección, flexibilidad y eficiencia.

Modelo ISO/IEC 25010: Se define la calidad del software en base a ocho principales características: seguridad, eficiencia, compatibilidad, funcionalidad, portabilidad, fiabilidad y fiabilidad y mantenibilidad.

Modelo CMMI (Capability Maturity Model Integration): Se evalúa los procesos de desarrollo de software, identificada los niveles de optimización de la calidad del proceso de desarrollo.

Beneficios:

- Reducción de costos de mantenimiento y soporte a largo plazo.

- Mejora en la satisfacción del usuario final.

- Mayor competitividad en el mercado.

Ventajas:

- Facilita el mantenimiento y l evolución del software.

- Aumenta la confiabilidad del producto final.

- Reduce el tiempo y esfuerzo en detectar y corregir errores.

Desventajas:

- El seguimiento de modelos de calidad complejos que pueden ser exigentes en términos de recursos y tiempo.

La implementación de prácticas de calidad que puede incrementar costos iniciales.

Altos estándares de calidad que pueden restringir la flexibilidad del desarrollo.

Se explica las siguientes dimensiones e indicadores:

Dimensiones:

Rendimiento: Según (Pressman, 2005) define a esta dimensión como indispensable porque aportará en el desarrollo de un sistema predictivo el cual debe de manejar de forma adecuada los diferentes productos que se gestionará dentro de la misma, así mismo, (Capers, 2008) define a esta dimensión, como aquella que pretende mejorar los tiempos de control de productos y de almacenado.

Entre las teorías se puede mencionar:

Teoría de la generalización: Es fundamental esta teoría para (Vapnik, 1995) para evaluar el rendimiento de los modelos de machine learning, debido a que, busca realizar predicciones precisas a través del uso de datos nuevos.

Teoría del aprendizaje estocástico: (Bishop C. , 1995) lo describe como los algoritmos de machine learning que pueden aprender a partir de datos que contienen variabilidad, enfocados en el modelo de enfrentar datos incompletos e inciertos.

Teoría de la complejidad del aprendizaje: Esta teoría para (Mitchell, 1997) aborda la complejidad del rendimiento en las tareas del aprendizaje, a su vez analiza la complejidad computacional y el riesgo de sobreajuste.

Indicadores

Precisión: Para (Zhang, 2004) este indicador es el porcentaje de las predicciones correctas realizadas por el modelo en relación con el total de predicciones.

Área bajo la curva: Según (Fawcett, 2006) este indicador evalúa la capacidad de un modelo para distinguir entre las clases.

Tiempo de entrenamiento: Según (Hastie *et al.*, 2009) el indicador está enfocado al tiempo que tarda el modelo en aprender de los datos de entrenamiento.

Productividad: Lo que se va a medir en este indicador será el cálculo de la relación entre el tiempo y el esfuerzo, así mismo esto será cuantificado mediante una fórmula para poder indicar y validar un antes y un después, esto en relación con la implementación del nuevo sistema.

Fórmula:

$$Productividad = Tiempo Esfuerzo Total - Tiempo Empleado$$

Donde:

Tiempo Esfuerzo Total: Es la cantidad de tiempo que se requería antes para realizar una actividad.

Tiempo Empleado: Es la cantidad de tiempo que se requiere ahora para realizar una actividad.

Calidad: Esta dimensión es indispensable en el contexto de Machine Learning, (McCall, 1977) el cual se refiere a la capacidad de los modelos y algoritmos para producir resultados precisos, útiles y confiables. Para (Sommerville, 2011) menciona que, esta dimensión mejora la calidad de los datos y de los modelos impactando en la efectividad de las predicciones y decisiones automatizadas.

Entre las teorías se puede mencionar:

Teoría de la calidad de los datos: A pesar que es original en el campo de la gestión de calidad, los principios de esta teoría se aplican en machine learning debido a la importancia de tener datos de alta calidad que permita asegurar modelos confiables y precisos.

Modelo de costo de errores: (Schapire R. , 1990) analiza el costo asociado a diferentes tipos de errores en modelos de machine learning. La calidad se mide en función de los errores en la predicción, los cuales pueden influir en decisiones críticas.

Indicadores:

Calidad de los datos: Este indicador se encarga de medir la integridad, consistencia y precisión de los datos utilizados.

Tasa de calidad: Lo que se va a medir en este indicador es el correcto funcionamiento que debe tener el sistema, así mismo esta fórmula tiene relación con el tiempo en que el sistema funciona de forma óptima y también con respecto el flujo de trabajo del sector farmacéutico en un día de trabajo.

Fórmula:

$$Tasa\ de\ calidad = \frac{Tiempo\ Productivo}{Tiempo\ en\ Funcionamiento}$$

Donde:

Tiempo Productivo: Es la cantidad de tiempo que usa el usuario el sistema para realizar sus actividades en el trabajo.

Tiempo en Funcionamiento: Es la cantidad de tiempo que el sistema puede estar funcionando o estar operativo, esto de forma óptima.

Diversidad del conjunto de datos: Medirá y evaluará la variedad en los datos utilizados para entrenar el modelo

Usabilidad: Esta dimensión para (Nilesen, 1994) es indispensable porque permite interactuar a los usuarios con un sistema basado en inteligencia artificial. A su vez, (Norman, 2013) incluye no solo la interfaz del usuario, sino también de cómo funciona el modelo, la interpretación de sus resultados y la capacidad para integrarlo en flujos de trabajo por usuarios finales.

Entre sus teorías se puede mencionar:

Teoría de la interacción humano – maquina (HCI) : Esta teoría de (Shneiderman, 2010) se aplica en el contexto de machine learnig para mejorar esta dimensión que permite a las interfaces a interactuar con los modelos de aprendizaje de forma automática. Se enfoca cómo los usuarios interactúan con los sistemas de machine learnig mejorando su experiencia.

Teoría del diseño centrado en el usuario (UCD): Según (Norman, 2013) centra su teoría en la creación de sistemas de machine learnig la cual, optimiza la experiencia del usuario haciendo que sus prioridades interacciones con los modelos de machine learnig.

Indicadores:

Facilidad de uso: Según (Nilesen, 1994) este indicador se encarga de medir lo fácil que es interactuar el usuario con el sistema usando machine learning.

Tasa de finalización: Lo que se va a medir en este indicador está en el entorno de la usabilidad, esto con respecto a la cantidad de tareas que no se lo lograron realizar de buena manera y también con referente al buen desenvolvimiento y realización de tareas que se lograron realizar de forma exitosa, todo ello dependerá de cómo el sistema interactúa de forma amigable con el usuario.

Fórmula:

$$:Tasa\ de\ Finalización = \frac{Cantidad\ de\ Tareas\ Fracasadas}{Cantidad\ de\ Tareas\ Exitosas}$$

Donde:

Cantidad de Tareas Fracasadas: Es la cantidad de funcionalidades que el usuario no puede realizar de forma óptima en el sistema.

Cantidad de Tareas Exitosas: Es la cantidad de funcionalidades que el usuario puede realizar de forma óptima en el sistema.

Satisfacción del usuario: Este indicador mide el nivel de satisfacción que los usuarios experimentan al utilizar la interfaz

Variable Dependiente: Gestión de inventarios

La gestión de inventarios es un proceso esencial que implica supervisar y controlar los niveles de existencias para satisfacer la demanda del cliente y minimizar costos (Silver et al., 2021). Según (Nahmias y Lennon, 2021) una adecuada gestión de inventarios permite a las empresas mantener un equilibrio entre la oferta y la demanda. Además, (Vesga, 2020) señala que esta práctica mejora la eficiencia operativa al reducir el tiempo de espera y optimizar el flujo de materiales. Para (Culot et al., 2024), la implementación de tecnologías como el aprendizaje automático puede transformar la gestión de inventarios, haciéndola más precisa y eficiente. En este sentido, (Wolniak y Grebski, 2023) destacan que el uso de modelos predictivos es crucial para anticipar necesidades futuras. Por otro lado, (Ramirez, 2022) enfatiza la importancia de la capacitación del personal en el manejo adecuado de inventarios. Finalmente, la gestión eficaz de inventarios contribuye a la sostenibilidad y competitividad de las organizaciones (Coyle et al., 2021). Podríamos indicar que la base fundamental de la gestión de inventarios es fundamental durante las operaciones que realiza la empresa durante los procesos de planificación y organización, afín de lograr tener un stock adecuado que eviten la compra de productos innecesarios que puedan generar pérdidas a la empresa.

Entre las teorías se pueden mencionar:

Teoría de la cantidad económica de pedido: Según (Ford, 1913) esta teoría es fundamental en la gestión de inventarios porque permite calcular la cantidad óptima de pedido y minimizar los costos de inventario, considerando los costos de pedido y los costos de mantenimiento.

Para (Hillier & Lieberman, 1967) esta teoría muestra la incertidumbre en la demanda para llevar el control de inventarios, se optimiza los niveles de inventario en función de condiciones de demanda de variables inciertas.

Según (Stevenson, 1982) aborda esta teoría como parte fundamental porque proporciona relevancia en la toma de decisiones en sus diversas operaciones.

El aporte de esta teoría es el de permitir a las empresas que puedan determinar el pedido, reduciendo costos innecesarios, mejorando la eficiencia. A su vez, se busca minimizar los gastos asociados al abastecimiento y almacenamiento.

Teoría de revisión periódica de inventarios: Para estos autores (Arrow, *et.al.*, 1951) esta teoría propone un modelo que esté basado en las revisiones periódicas, que permita ajustar los inventarios en intervalos regulares, esto es útil en productos con demanda variable.

Según (Nahmias, 1989) en su libro explica dicha teoría donde el inventario se revisa en intervalos de tiempo regulares. En lugar de monitorear continuamente se puede establecer periodos fijos de revisión en los cuales se permita evaluar los niveles de stock logrando ajustarlo en el inventario del nivel deseado.

En el libro de (Krajewski y Ritzman, 1996) describen dicha teoría como una estrategia en el control de los inventarios permitiéndoles realizar revisiones en intervalos regulares. Esto es ideal en productos de bajo costo con demanda estable.

Los autores buscan presentar un detallado análisis de cómo se puede calcular el pedido adecuado considerando la variabilidad de la demanda así como los tiempos de entrega.

Teoría de la planificación de requerimientos de materiales: (Orlicky, 1975) esta teoría calcula las necesidades de los materiales en función a la producción planificada, optimiza los inventarios al calcular la cantidad y el momento de cada componente para cumplir la demanda.

Según (Spina, 2002) explora los principios fundamentales de dicha teoría y la aplicación en los entornos reales de la producción, permite la implementación de un sistema más efectivo optimizando la gestión de inventarios y mejorando la eficiencia de dicha implementación.

Para (Donald y Koops, 1998) muestran cómo utilizar dicha teoría en la toma de decisiones centrándolo en la planificación y la gestión de inventarios proporcionando consejos que contribuyan a evitar errores comunes durante la implementación-

Un aporte significativo que engloba a esta teoría es que, permite a las organizaciones sincronizar en la planificación de materiales, así como, en los aspectos de la operación empresarial, pudiendo mencionar a las finanzas, recurso humanos y ventas.

De la variable gestión de inventarios

Según (Flamarique, 2019) en su libro describe como componente esencial la lógica que involucra a las actividades involucradas como es el almacenamiento y la manipulación de productos , así mismo, implica no solo el control de las existencias físicas en el almacén sino también la planificación de las necesidades del inventario que a través del uso de tecnologías mejoren la eficiencia operativa.

Entre las características podemos mencionar:

Control de stock: Referido al monitoreo constante a fin de asegurar que las existencias sean suficientes para satisfacer la demanda sin llegar al sobre stock.

Planificación de la demanda: Se basa en la proyección de la demanda futura que determine cuánto se debe contar y mantener en stock.

Costos asociados: Son los costos relacionados al inventario que incluyen el almacenamiento, adquisidor y deterioro.

Ciclo de vida del producto: Debe adaptarse a las etapas del ciclo de vida de los productos desde su ingreso hasta su vencimiento.

Los modelos o tipos de gestión de inventarios

Modelo Justo a Tiempo (JIT): Minimiza los niveles de inventario manteniendo solo lo necesario para la producción inmediata.

Modelo de Cantidad Económica de Pedido (EOQ): Busca determinar la cantidad óptima a pedir que minimiza los costos totales de inventario.

Modelo de Revisión Periódica: Establece revisiones de inventario en intervalos fijos, donde se decide cuánto pedir para alcanzar el nivel deseado.

Modelo ABC: Clasifica los inventarios en tres categorías (A, B y C) según su importancia, ayudando a priorizar la gestión de productos más críticos.

Modelo de Inventario de Seguridad: Mantiene un stock adicional para protegerse contra variaciones en la demanda o en el suministro.

Beneficios:

Reducción de Costos: Minimiza los costos de almacenamiento, obsolescencia y deterioro al optimizar los niveles de inventario.

Mejora en la Satisfacción del Cliente: Mantiene los productos disponibles, lo que mejora la capacidad de respuesta a la demanda del cliente.

Eficiencia Operativa: Permite un flujo de trabajo más suave y eficiente en la producción y distribución.

Mejor Planificación Financiera: Facilita un control más preciso de los flujos de efectivo y reduce el capital inmovilizado en inventarios.

Adaptabilidad: Permite ajustar rápidamente los niveles de inventario en respuesta a cambios en la demanda o en el entorno del mercado.

Ventajas

Mayor Visibilidad: Herramientas y software de gestión de inventarios proporcionan visibilidad en tiempo real sobre niveles y ubicaciones de inventario.

Reducción de Riesgos: La gestión adecuada minimiza el riesgo de roturas de stock y excesos de inventario.

Optimización del Espacio: Ayuda a utilizar el espacio de almacenamiento de manera más efectiva.

Facilita la Toma de Decisiones: Con datos precisos, los gerentes pueden tomar decisiones informadas sobre compras y producción.

Desventajas

Costo Inicial: Implementar sistemas de gestión de inventarios puede requerir una inversión inicial significativa en software y capacitación.

Dependencia de Tecnología: Un fallo en los sistemas tecnológicos puede afectar la gestión de inventarios.

Complejidad: A medida que la empresa crece, la gestión de inventarios puede volverse más complicada, requiriendo una atención continua.

Cambio de Mentalidad: Puede ser un desafío para algunas organizaciones cambiar a prácticas de gestión de inventarios más eficientes, especialmente si están acostumbradas a métodos más antiguos.

Dimensiones:

Control de stock: Esta dimensión es indispensable porque aporta a la adecuada gestión de inventarios, referido al aspecto de tener la cantidad requerida por el almacén del establecimiento

farmacéutico, que permita cumplir la demanda solicitada sin que se produzca un quiebre negativo en el stock.

Entre sus teorías podemos destacar:

Teoría de la cantidad económica de pedido : Esta teoría fue propuesta por (Ford, 1913) quien buscó minimizar los costos totales del inventario mediante la determinación de un nivel óptimo del pedido.

Para (Anderson, 2007) esta teoría determina la cantidad optima que un inventario de una empresa debe tener para minimizar los costos relacionados con el almacenamiento y abastecimiento.

Indicadores:

Stock óptimo: Lo que se va a medir en este indicador es el volumen que debe de tenerse para lograr el stock óptimo y consecuentemente tener un adecuado control de ello, esto se realiza con el propósito de conseguir la mayor rentabilidad y reducir al mínimo los costes de almacenamiento de aquellos productos que tengan baja rotación.

Fórmula:

$$\text{Cantidad óptima de pedido} + \text{stock mínimo} + \text{stock de seguridad}$$

Cantidad óptima de pedido: Es la cantidad ideal que se tiene que realizar como pedido al proveedor.

Stock mínimo: Es la cantidad mínima que contribuya a solventar las necesidades de los diversos clientes.

Stock de seguridad: Es la cantidad adicional de productos que se mantiene en el inventario para mitigar el riesgo de desabastecimiento ante posibles retrasos en las entregas de los proveedores.

Costo de mantenimiento: Es un indicador que permite a las empresas evaluar la eficiencia de sus operaciones y tomar las decisiones que mejoren los recursos, la reducción de los costos no solo optimiza la rentabilidad, sino que, brinda competitividad en el mercado.

Control de salidas: Esta dimensión es indispensable porque aporta a la adecuada rotación de los productos dentro del almacén, mejorando la gestión de inventarios, así mismo esta dimensión también ayuda a que los productos tengan una mayor rotación dependiendo de su rápida o lenta salida, evitando de este modo el vencimiento de los productos y una pérdida económica con ello.

Entre sus teorías podemos mencionar:

Teoría justo a tiempo : Para (Taiichi, 1988) esta teoría busca reducir los niveles de inventario al recibir los productos solo cuando se consideren necesarios en el proceso de producción, lo que, minimiza los costos de almacenamiento y optimiza la eficiencia. Según (Womack, 1996) esta teoría involucra la reducción de los costos de inventario hasta llegar a los productos que sean necesarios en el proceso de producción.

Análisis ABC: Según (Pareto, 1896) este modelo categoriza los inventarios en función a su valor para priorizar los artículos que requieren mayor control. Para (Heizer y Render, 2007) su teoría permite medir la frecuencia de reposición de un inventario en un periodo de tiempo.

Indicadores:

Tasa de rotación de inventario: Lo que se va a medir en este indicador es la demanda de los productos con respecto a la rápida o lenta salida que este tiene en el almacén, así mismo este indicador aporta al control de salidas de forma eficiente, esto gracias un método de rotación ABC, en donde la letra A es de rotación alta, B de rotación media y C de rotación baja, esto por consecuente ayudará a la identificación y clasificación de productos con un nivel de demanda alta. Por último, el resultado expone la cantidad de veces que se renueva el inventario en un tiempo determinado, si los datos son expresados de forma mensual, ello se interpretará a largo de un mes.

Fórmula:

Donde:

$$Tasa\ de\ rotación\ de\ inventarios = \frac{Valor\ de\ las\ referencias\ vendidas}{Valor\ promedio\ de\ existencias}$$

Valor de las referencias vendidas: Es el valor nominal de salida de los productos existentes.

Valor promedio de las existencias: Es el valor promedio a precio de compra de los productos existentes.

Control del inventario: Esta dimensión para es indispensable porque aporta al adecuado control de los productos existentes con respecto a los errores de operación en el sistema que pueden suscitarse cuando se manipula inadecuadamente los datos, así mismo, esto puede ocasionar fallas periódicas en el correcto inventario de ingresos reales de la empresa farmacéutica.

Entre sus teorías destaca:

Teoría: Material Requirements Planning (MRP): Para (Orlicky, 1975) esta teoría se centra en coordinar los materiales necesarios para la producción, con un enfoque en tiempos y la precisión de las predicciones. Según (Vollmann & Whybark, 2005) el control de inventarios es fundamental porque se gestiona los materiales requeridos en la producción mediante una planificación detallada de los insumos, tiempos y cantidades, para ello se asegura prever y coordinar la adquisidor así como en el uso.

Indicadores:

Contracción de inventario: Lo que se va a medir en este indicador es el porcentaje de contracción de inventario, en donde se debe de contemplar la diferencia entre el stock que el sistema tiene y el

stock que físicamente la empresa farmacéutica cuenta, así mismo a ello se le divide con el stock que debería de haber, para tener con esto un resultado expresado en porcentaje sobre el desvío del inventariado real.

Fórmula:

$$(\%) \text{Contracción de inventario} = \frac{(\text{stock que debería haber} - \text{stock que hay realmente})}{\text{stock que debería haber}}$$

Donde:

Stock que debería de haber: Es la cantidad de productos almacenados que el sistema percibe que hay.

Stock que hay realmente: Es la cantidad de productos almacenados que físicamente existe en el almacén.

Tiempos de actualización: Este indicador se refiere al intervalo de tiempo que puede transcurrir las actualizaciones de los registros, mostrara la frecuencia con la que se registra las entradas y salidas de tal manera que se tenga un stock preciso que permita tomar decisiones y la gestión de pedidos.

Por otro lado, (Abuchar, 2023) hace mención que la metodología RUP es una estructura de trabajo el cual tiene un enfoque de desarrollo de software dirigido al diseño, la realización y la gestión de un proyecto, esto a su vez tiene el objetivo de crear un producto el cual tiene como base el modelo de lenguaje unificado (UML), así mismo este método permite dividir el proyecto en ciclos interactivos, por la razón de que permite una retroalimentación más exhaustiva y adaptativa.

Así mismo algunas características importantes que se resalta de esta metodología es con respecto a su:

Arquitectura centrada: Permite tener una arquitectura del software bien diseñada desde el principio hasta la finalización de esta.

Calidad: Asegura la integridad, la fiabilidad y productividad del software, esto debido a su modelo UML.

Documentación adecuada: Permite asegurar una adecuada documentación, esto debido a la gran cantidad de diagramas que el software solicita al momento de trabajar con el modelado UML.

Gestión de riesgos: Permite trabajar con una gestión de riesgos proactiva desde el inicio del proyecto, esto garantiza entregables y un producto eficiente.

Fases y actividades definidas:

Esto señala que el modelo UML, tiene adecuadamente definido sus actividades y fases para el adecuado seguimiento del software, además cuenta con una secuencia y estructura previamente definidas para alcanzar el adecuado desarrollo de un software.

Por otro lado, las Fases que el modelo RUP incorporan son las siguientes:

Fase de Inicio: Se indica el alcance que el proyecto tendrá con los respectivos interesados, así mismo se identifica los posibles riesgos que el proyecto pudiese acarrear, a su vez se elabora el cronograma de actividades con respecto a cada fase y por último se detalla de forma general la arquitectura que el software tendrá.

Fase de Elaboración: Se diseña la solución a partir de los requerimientos, con respecto al modelado UML, esto también con referente a los casos de uso y demás diagramas de secuencia, además se define en rasgos más específicos la arquitectura que el software tendrá y por último se constituye el dominio del software.

Fase de Construcción: En esta fase se desarrolla y se hacen pruebas con referente al software en ciclos interactivos, esto permite que se pueda agregar o quitar ciertas funcionalidades al software si así se requiera, esto para mejorar la eficacia, optimización y productividad de esta.

Fase de Transición: Esta fase se considera la de cierre, por la razón de que se asegura la calidad, la eficiencia y la confiabilidad del software, así mismo se hacen diversas pruebas de errores y defectos para asegurar que el software que se le hará entrega al usuario es completamente funcional.

Según Subra (2018), comenta que el método ágil Scrum, se basa en la colaboración, la adaptabilidad y la entrega continua de entregables, esto es debido a su forma de trabajar el software, ya que este presenta constantemente entregables en mínimos periodos de tiempo y también cuenta con una gran tolerancia a los cambios de requerimientos que el interesado necesite, a su vez los ciclos de trabajo se denominan Sprint, en donde su objetivo es el trabajo en equipo, la transparencia y la capacidad de lograr constantemente rápidas entregas de alta calidad.

En este sentido algunas de las características importantes que se resalta de esta metodología es con respecto a:

Roles definidos: Esto garantiza que los equipos de trabajo sean autónomos y tengan claro qué es lo que deben hacer para que el software sea funcional.

Ciclos interactivos Sprint: Hace referencia a que los trabajos sean logrados en cortos y fijos periodos de tiempo, esto con el objetivo de lograr frecuentemente entregables que ayuden a la adaptación y el desarrollo continuo del software.

Transparencia: Esto permite que la información, así como el progreso sean visibles para todo el equipo de trabajo, así como interesados en el desarrollo del software.

Adaptabilidad: Permite que los cambios no afecten negativamente las fechas establecidas anteriormente en cronograma de entrega del software, a su vez el método scrum permite trabajar

con una arquitectura de software diseñada para soportar diferentes cambios en los requerimientos que se requieran.

Entrega continua: Esto permite la conformidad de los interesados con respecto al desarrollo del software, ya que de ser necesario se puede modificar los requerimientos tantas veces sean necesarias, hasta que cumplan eficientemente con lo que necesita el usuario.

Por otro lado, las etapas que el Modelo Scrum posee son las siguientes:

Planificaron del producto:

En esta etapa se prioriza y se establece el product backlog, el cual representa el trabajo a realizar, en donde se plantea que es lo quiero lograr, cómo se lograre y cuando lo quiero.

Planificación de Sprint:

Se establece los elementos y objetivos a trabajar a partir del sprint backlog, en donde a su vez se crea y estima historias de usuario para que ver que él lo que necesita, también se identifican tareas, interacciones y entregables en periodos de tiempo establecidos.

Desarrollo del Sprint:

Se trabaja las tareas del Sprint backlog para tener un potencial entregable del producto, el cual tiene como objetivo cumplir las necesidades del cliente.

Revisión del Sprint:

En el penúltimo sprint se hace una revisión en donde todos los equipos de trabajo muestran lo que completaron satisfactoriamente y se hace la retroalimentación con los interesados en el software para ver si cumple con sus necesidades.

Retrospectiva del Sprint:

Al final se realiza una retrospectiva de lo que ha logrado como equipo, así como visualizar el desempeño que cada uno tuvo en el aporte del desarrollo del software, y así también buscar mejorar características que los interesados puedan haber indicado para el próximo ciclo del sprint.

Según (Edge, 2018), relata que la método ágil en espiral, es un enfoque de desarrollo de software que va dirigido a la evaluación de riesgos y la planificación constante de interacciones, a su vez el proyecto de software se divide en espirales, siendo que cada uno cuenta con sus cualidades y actividades ya definidas, esto con el objetivo de alcanzar la planificación, el análisis, el diseño, la construcción y la evaluación de riesgos adecuadamente, esto permitirá que el software tenga una adaptación continua y una mitigación de riesgos en los cambios que se susciten.

En este sentido algunas de las características importantes que se resalta de esta metodología es con respecto a:

Enfoque en la gestión de riesgos

El método se centra en su gran mayoría en mitigar los posibles riesgos que se puedan suscitar en cuanto al tiempo que se emplea en el desarrollo de entregables, a su vez también se pretende mitigar las posibles demoras e inconvenientes que se puedan suscitar al levantar nuevos requerimientos.

Planificación Iterativa

Cada espiral dentro de la metodología tiene sus propias cualidades y bondades para afrontar dificultades asignadas, desde la evaluación de riesgos hasta el análisis y desarrollo del software, esto con el objetivo de tener entregables satisfactorios para los interesados.

Flexibilidad

La metodología se adapta a medida que se obtiene nueva información y experiencias de diversos ámbitos, esto facilita los cambios en los requerimientos y el diseño de los entregables del software.

Retroalimentación Constante

Se recopila información de los usuarios e interesados para saber sus necesidades y convertirlas en requerimientos funcionales, el cual se tomará en cuenta y se utilizará en las interacciones para mejorar el producto final.

Costo y Plazo Controlados:

La constante evaluación de riesgos permite mantener el presupuesto y el calendario del proyecto en un óptimo estado, permitiendo esto ser muy proactivo a la hora de realizar entregables en cada interacción.

Por otro lado, las fases que el Modelo en Espiral posee son las siguientes:

Determinación de Objetivos y Alternativas:

En esta fase se definen los objetivos del proyecto y se identifican en paralelo las posibles soluciones que se podrían dar, así también se evalúa los riesgos iniciales y se toman decisiones en equipo para poder avanzar a la siguiente fase.

Evaluación de Riesgos:

En esta fase se realiza una evaluación e identificación detallada de todos los posibles riesgos que podrían afectar al proyecto, así mismo se analiza y se prioriza los riesgos más frecuentes para poder mitigarlos en lo posible, en este sentido también se elabora un plan detallado que se debe de seguir para la siguiente fase.

Desarrollo del Producto:

En esta fase comienza el desarrollo propiamente dicho del producto a entregar, en donde se realiza el diseño, la programación, la implementación y por último las pruebas.

Evaluación del Cliente y el Usuario:

En esta fase se presenta el software al cliente y a los usuarios finales, para obtener retroalimentación de los comentarios de cada uno de ellos con respecto a su usabilidad, seguridad, desempeño entre

otros comentarios de importancia para la mejora continua del software, así mismo el equipo toma una decisión en donde se decide si modificar el software, esto repitiendo ciclo de interacciones o concluir el proyecto en el sentido de que se cumplió con todos los requerimientos satisfactoriamente

2.3. Formulación de hipótesis

2.3.1. Hipótesis general

Hg: La aplicación de Machine Learning mejorará la eficiencia de la gestión de inventarios del sector farmacéutico limeño 2024, reduciendo las pérdidas económicas y aumentando la satisfacción del cliente.

H0: La aplicación de Machine Learning no mejorará la eficiencia de la gestión de inventarios del sector farmacéutico limeño 2024.

2.3.2. Hipótesis específica

HE1: La utilización de sistemas de predicción de la demanda en el sector farmacéutico limeño reduce significativamente los desabastecimientos de medicamentos al mejorar la planificación del inventario y la disponibilidad de productos.

HE2: La implementación de algoritmos de Machine Learning mejorará significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales.

HE3: La aplicación de Machine Learning permitirá mantener el stock óptimo, lo que resultará en una reducción del desabastecimiento y un mejor control sobre los productos próximos a vencer.

CAPÍTULO III: METODOLOGÍA

3.1. Método de Investigación

Se trata de un enfoque de investigación basado en el método hipotético-deductivo, su cualidad es el de ir de lo general a lo particular, así mismo, este método ayuda a inferir a partir de diversos conceptos e instrumentos de conocimientos, con la finalidad de poder solucionar un problema. Para Ñaupas *et al.* (2014) el método hipotético deductivo está enfocado en apreciar la veracidad y la deducción de los hechos, los cuales en un principio pueden ser falsos o verdaderos, a su vez también se contempla cuatro pasos bien definidos los cuales son la observación de un dilema, elaboración de la hipótesis, deducción de las consecuencias contrastables (los cuales son observables y medibles) y por último la observación y experimentación, por otro lado, a partir de estos pasos principales se debe de validar la calidad de los datos para poder ejercer de forma adecuada el método hipotético deductivo, que a su vez también demanda un gran criterio por parte del investigador para comprobar o refutar las hipótesis. Según (Marconi y Lakatos, 2017) se define como un proceso que implica la formulación de hipótesis que deben ser sometidas a prueba a través de observaciones y experimentos. Este método se estructura en varias etapas, desde la identificación del problema hasta la deducción de consecuencias y su verificación empírica. Se considera fundamental en las ciencias fácticas por su capacidad para generar conocimiento confiable. Para (Popper, 1980) describe el método hipotético-deductivo como un enfoque que permite ampliar el conocimiento científico mediante la formulación de hipótesis que son contrastadas con la realidad a través de deducciones lógicas y experimentación. Este método enfatiza la falsabilidad de las hipótesis como criterio central para su validación. Según (Marfull, 2019) en su análisis del método hipotético-deductivo, Marfull explica que este modelo se basa en la formulación de una hipótesis inicial que se deriva de una

teoría general y que debe ser contrastada mediante observaciones específicas. Este enfoque es especialmente útil para investigar problemas complejos donde se requiere una validación rigurosa de las hipótesis propuestas

Enfoque de la investigación

El enfoque cuantitativo en la investigación se distingue por su utilización de métodos estadísticos para medir y analizar fenómenos. Según Acosta (2023) señala que, la investigación cuantitativa se centra en caracterizar, aclarar y prever fenómenos a través de un análisis sistemático y objetivo. Además, Calizaya *et al.* (2022), este enfoque permite identificar tendencias, verificar hipótesis y generar resultados aplicables a amplios grupos poblacionales. Por otro lado, Rojo (2022) enfatiza que, esta metodología se basa en la recopilación de datos numéricos y su análisis mediante técnicas estadísticas, lo que facilita la validación objetiva de las hipótesis planteadas. En consecuencia, es evidente que el enfoque cuantitativo es fundamental para la ingeniería de sistemas, ya que permite tomar decisiones informadas basadas en datos precisos, lo que optimiza procesos y mejora resultados.

3.2. Tipo de investigación

La investigación aplicada se define como aquella que busca resolver problemas prácticos y específicos, generando resultados que se pueden implementar en situaciones reales (Vizcaino *et al.*, 2023). En contraste, la investigación básica se centra en la generación de conocimiento y la comprensión de fenómenos sin un objetivo inmediato de aplicación práctica (Hurtado, 2020). Ambas modalidades son esenciales para el avance del conocimiento, ya que la investigación básica fundamenta las teorías que guían la investigación aplicada. En este sentido, es fundamental reconocer que la investigación aplicada no solo proporciona soluciones inmediatas, sino que

también se nutre de los hallazgos de la investigación básica, creando un ciclo continuo de desarrollo del conocimiento en el ámbito científico.

3.3. Diseño de la investigación

El diseño de investigación experimental se caracteriza por la manipulación de variables para observar su efecto en otras, lo que permite establecer relaciones de causa y efecto (Em, 2024). Según Trenton y Manago (2022), este enfoque es fundamental en la investigación científica, ya que permite un control riguroso de factores externos que podrían influir en los resultados. Además, la aplicación de diseños experimentales garantiza validez interna, facilitando así la generalización de los hallazgos a poblaciones más amplias. En este contexto, es crucial entender que el diseño experimental no solo proporciona una estructura para investigar fenómenos, sino que también asegura que los resultados sean confiables y aplicables en contextos reales, lo que es esencial para el avance del conocimiento en diversas disciplinas. El diseño experimental es particularmente relevante en la aplicación de machine learning para la gestión de inventarios en el sector farmacéutico, ya que permite la creación y evaluación de un sistema que interactúa directamente con los datos y procesos existentes. Al implementar algoritmos de machine learning, se manipulan variables clave como la predicción de la demanda, la selección del algoritmo adecuado y el ajuste del stock óptimo. Estas manipulaciones tienen como objetivo observar cómo afectan la eficiencia del sistema de gestión de inventarios. Esta intervención activa no solo facilita la medición de resultados específicos, sino que también permite ajustar y optimizar continuamente el modelo en función de los datos obtenidos. La capacidad de experimentar con diferentes configuraciones del sistema y evaluar sus efectos en tiempo real proporciona una base sólida para establecer relaciones causales claras, lo cual es fundamental para validar las hipótesis planteadas. En consecuencia, el

diseño experimental no solo es adecuado, sino esencial para garantizar que las soluciones desarrolladas sean efectivas y aplicables en un entorno real.

3.4. Población, muestra y muestreo

Población: Según Gaviria y Márquez (2019), la población se interpreta como la agrupación de elementos de interés sobre los cuales se enfocará la observación. Asimismo, Ramos (2021) destaca que, a partir de una población definida, es posible extraer un subconjunto representativo que permita realizar inferencias significativas sobre el total. En este contexto, la investigación contempla una población compuesta por los registros históricos de la empresa farmacéutica, que incluye un total de 1,000 registros, los cuales ayudarán en la recopilación de datos necesarios para el análisis.

Muestra: La "muestra" es un concepto clave en la investigación, definido como un subconjunto representativo de una población. Según Monanol et al. (2022), la selección de la muestra debe basarse en criterios específicos que aseguren su representatividad y validez. Asimismo, Taherdoost (2022) indica que una muestra bien diseñada es fundamental para la fiabilidad de los resultados, ya que minimiza el sesgo y mejora la precisión de las conclusiones. Además, es importante considerar que la elección del tamaño de la muestra influye en la potencia estadística del estudio, permitiendo detectar efectos significativos y contribuyendo a la robustez de los hallazgos.

La muestra es establecida por la siguiente fórmula:

$$n_0 = \frac{Z^2 N \cdot P \cdot Q}{Z^2 P \cdot Q + (N-1) E^2}$$

Donde:

n_0 = *Tamaño de la muestra*

Z = *Nivel de confianza al 95%, el cual obtiene el valor (1.96)*

N = *Población total a estudiar*

P = *Probabilidad de que ocurra el evento estudiado*

Q = *Probabilidad de que no ocurra el evento estudiado*

$E = \text{Error estimado al } 5\%$

$$n_0 = \frac{(1.96^2)(1000)(0.5)(0.5)}{(1.96^2)(0.5)(0.5) + (1000-1)(0.05^2)}$$

$$n_0 = \frac{(3.8416)(250)}{(0.9604) + (999)(0.0025)}$$

$$n_0 = 277.74 \rightarrow n_0 = 278$$

De este modo se pudo obtener un total de 278 registros para la muestra que necesita la investigación.

Muestreo: Según Gavia Peña y Márquez Fernández (2019), el muestreo es una técnica que permite al investigador seleccionar un conjunto de elementos que se consideran representativos y relevantes para la población, con el fin de obtener información sobre sus características y percepciones. En este contexto, el enfoque que se utilizará en esta investigación es el muestreo aleatorio simple, el cual garantiza que cada miembro de la población tenga la misma probabilidad de ser seleccionado. De acuerdo con Acosta (2023), este tipo de muestreo es esencial para asegurar que las muestras sean representativas en estudios cuantitativos. Además, Calizaya *et al.* (2022) señalan que el muestreo aleatorio simple ayuda a reducir sesgos, lo que permite realizar inferencias más precisas sobre la población. Por lo tanto, este enfoque es particularmente adecuado para la recopilación de datos en esta investigación.

3.5. Variables y Operacionalización

Para el presente estudio se contemplaron las variables Machine Learning y la gestión de inventarios como parte del estudio en una empresa del sector farmacéutico.

Definición conceptual de la variable Machine Learning: El "Machine Learning" es un subcampo de la inteligencia artificial que permite a las máquinas aprender de los datos y mejorar su rendimiento en tareas específicas a través de algoritmos que identifican patrones. Este enfoque es fundamental en sectores como la salud, el comercio y la gestión de inventarios (Padilha et al., 2021)

Definición operacional de la variable Machine Learning: La investigación tiene como objetivo operacional medir el rendimiento, la calidad y la usabilidad a través de un análisis comparativo antes y después de la aplicación del machine learning. Para ello, se emplearán los indicadores correspondientes que permitirán obtener la información necesaria para realizar las predicciones utilizando los registros disponibles.

Definición conceptual de la variable gestión de inventarios: La gestión de inventarios es el proceso de supervisar y controlar el suministro de bienes en una organización, asegurando un equilibrio adecuado entre oferta y demanda. Una gestión eficaz optimiza los costos operativos y mejora la satisfacción del cliente al garantizar la disponibilidad de productos (Tsukasa et al., 2023).

Definición operacional de la variable gestión de inventarios: La investigación tiene como objetivo medir el control de stock, las salidas y los inventarios mediante un análisis comparativo antes y después de aplicar machine learning. Para ello, se utilizarán indicadores específicos que permitirán obtener la información necesaria para realizar las predicciones a partir de los registros disponibles.

3.6. Técnicas e instrumentos de recolección de datos

3.6.1. Técnica

La "técnica" se entiende como un conjunto de procedimientos sistemáticos utilizados para alcanzar un objetivo específico dentro de un ámbito de estudio (Medina et al., 2023). En cuanto al "instrumento", este se define como una herramienta diseñada para facilitar la recolección y el análisis de datos, contribuyendo a la validez de la investigación (Suarez et al., 2022). Además, Montes (2021) enfatiza que la correcta selección de técnicas e instrumentos es esencial para garantizar la calidad y fiabilidad de los resultados. En conjunto, esto resalta la relevancia de emplear adecuadamente las herramientas metodológicas, lo que permite a los investigadores obtener resultados más precisos y significativos.

La técnica que se empleará para recabar datos será la observación, en donde a su vez también se utilizará una ficha de observación que sea fiable y bien estructurada, así mismo esta ficha de observación va a estar dirigido a los trabajadores de la empresa farmacéutica, en donde el objetivo de esta misma es recabar información de la percepción y de las situaciones específicas que sucedan con relación a la gestión de inventarios.

3.6.2. Descripción de instrumentos

Según Rojas *et al.* (2022), un instrumento es esencial para la recolección de datos, ya que garantiza la validez y fiabilidad de los resultados obtenidos. De igual manera, de la Lama *et al.* (2022) definen el instrumento como cualquier dispositivo que facilita el análisis de fenómenos, lo que es crucial para la investigación científica. Además, Mar et al. (2020) señalan que, los instrumentos deben ser seleccionados cuidadosamente para asegurar que se alineen con los objetivos del estudio y las características de la población objeto de investigación. En resumen, la correcta elección y aplicación de instrumentos es fundamental para el éxito de cualquier investigación.

El instrumento que se empleó para la investigación fue una ficha de investigación, en donde se tiene como idea medir los indicadores. Por otro lado, la ficha de observación tiene una estructura eficaz y óptima para la recopilación de información. Ver anexo 3.

3.6.3. Validación

En este apartado se utilizó la ficha de observación, el cual será evaluada por un juicio de expertos, el cual estará conformada por 3 expertos que respaldan su criterio por su nivel de profesionalismo, por lo laboral y por su vasta experiencia en este ámbito de la investigación, así mismo también verificaron que la estructura de la ficha tenga relación y mida de forma efectiva las variables de estudio.

Así mismo este juicio de expertos busca validar la fiabilidad y la conformidad de los instrumentos de investigación, esto para poder asegurar el adecuado desarrollo de la tesis.

Tabla 3

Expertos que validaron el instrumento

<i>Apellidos y Nombres</i>	<i>Especialidad</i>	<i>Opinión</i>
1. Córdova Forero Julio Alfredo		Si hay suficiencia
2. Guadalupe Mori Víctor Hugo		Si hay suficiencia
3. Rivera Echegaray Luis Alberto		Si hay suficiencia


3.6.4. Confiabilidad

Según Ruiz Olabuénaga (2012), toda investigación debe poseer un grado de calidad y validez. Para lograr esto, las investigaciones deben someterse a un proceso de evaluación que incluya un test y un re-test. Este procedimiento implica realizar dos pruebas en momentos diferentes con el mismo

sujeto, lo que permite comparar los resultados antes y después de la intervención. El objetivo es validar un nivel adecuado de confiabilidad para el instrumento utilizado, asegurando así que los resultados obtenidos sean fiables y válidos.

Tabla 4

Test del indicador stock óptimo

 <p>Universidad Norbert Wiener <small>Powered by Arizona State University®</small></p> <p>FACULTAD DE INGENIERIA Y NEGOCIOS ESCUELA ACADEMICO PROFESIONAL DE INGENIERIAS</p> <p>APLICACIÓN DE MACHINE LEARNING PARA LA EFICIENCIA EN LA GESTIÓN DE INVENTARIOS EN EL SECTOR FARMACÉUTICO LIMEÑO, 2024</p>						
Ficha de observación						
Objetivo: Determinar cómo Machine Learning mejora el stock óptimo en el sector farmacéutico limeño, 2024.						
Indicador: Stock óptimo.						
Formula: $SO = COP + SM + SS$				Autores: Rodas Cortijo Carmen Liliana,		
SO: Stock Optimo				Villacrisis Guerrero Jahir Jesus		
COP: Cantidad Optima de pedido				Libro: Manual de Gestión de almacenes.		
SM: Stock Mínimo						
SS: Stock de Seguridad						
Pre-Test						
N°	Producto	Fecha	Cantidad optima de pedido	Stock mínimo	Stock de seguridad	Stock Optimo
1	Amlodipino 5mg	02/08/2024	10	6	3	19
2	Antigripal Compuesto	02/08/2024	10	5	3	18
3	Cefalexina 250mg/5ml	02/08/2024	11	14	3	28
4	combi crema 900mg	02/08/2024	7	6	2	15
5	Combi Gel 335mg	02/08/2024	4	14	5	23
6	Combi Gel 376mg	02/08/2024	10	8	3	21
7	combi jarabe 335mg	02/08/2024	7	7	2	16

8	Comercial Cápsula 653mg	02/08/2024	8	11	4	23
9	comercial spray 404mg	02/08/2024	6	7	4	17
10	comercial tableta 592mg	02/08/2024	6	5	3	14
11	Fórmula Cápsula 508mg	02/08/2024	6	8	5	19
12	Fórmula Cápsula 914mg	02/08/2024	9	14	4	27
13	Fórmula Cápsula 937mg	02/08/2024	7	11	5	23
14	Fórmula Jarabe 441mg	02/08/2024	7	13	5	25
15	Plus Cápsula 701mg	02/08/2024	5	9	2	16
16	Rápido Crema 137mg	02/08/2024	8	4	3	15
17	Rápido Crema 349mg	02/08/2024	9	13	4	26
18	Rápido Crema 592mg	02/08/2024	9	5	5	19
19	shampoo anticaspa	02/08/2024	6	7	1	14
20	combi gel 959mg	03/08/2024	7	11	3	21
21	combi jarabe 961mg	03/08/2024	11	10	5	26
22	Complejo B	03/08/2024	10	5	3	18
23	Fórmula Cápsula 847mg	03/08/2024	7	13	4	24
24	Fórmula Crema 564mg	03/08/2024	10	13	5	28
25	Fórmula Gel 642mg	03/08/2024	6	7	3	16
26	Fórmula Jarabe 430mg	03/08/2024	4	13	3	20
27	Fórmula Spray 244mg	03/08/2024	9	13	3	25
28	Genérico Spray 183mg	03/08/2024	6	5	5	16
29	Loratadina 10 mg	03/08/2024	8	8	5	21
30	Paracetamol Jarabe 120ml	03/08/2024	8	12	3	23
31	Plus Cápsula 289mg	03/08/2024	10	8	4	22
32	Plus Spray 904mg	03/08/2024	10	14	2	26
33	Plus Tableta 377mg	03/08/2024	4	12	2	18
34	Rápido Cápsula 993mg	03/08/2024	8	14	3	25
35	Rápido Crema 187mg	03/08/2024	11	7	5	23
36	rapido crema 381mg	03/08/2024	6	11	5	22
37	Rápido Crema 481mg	03/08/2024	8	14	4	26
38	Rápido Crema 675mg	03/08/2024	6	10	3	19
39	Vendas	03/08/2024	9	11	5	25

40	Alcohol 70% 500ml	04/08/2024	9	8	3	20
41	Butilhioscina 10mg	04/08/2024	10	11	2	23
42	Cloro Alergan (Frasco)	04/08/2024	9	10	4	23
43	Combi Cápsula 306mg	04/08/2024	11	13	4	28
44	Combi Crema 346mg	04/08/2024	7	13	3	23
45	Comercial Cápsula 109mg	04/08/2024	9	11	4	24
46	Comercial Crema 184mg	04/08/2024	10	4	5	19
47	Comercial Jarabe 395mg	04/08/2024	6	10	3	19
48	comercial spray 433mg	04/08/2024	11	9	3	23
49	Fórmula Gel 692mg	04/08/2024	7	9	5	21
50	Fórmula Jarabe 546mg	04/08/2024	8	5	3	16
51	Fórmula Tableta 947mg	04/08/2024	11	4	2	17
52	Hidróxido de aluminio	04/08/2024	11	11	2	24
53	Loción para acné	04/08/2024	7	14	5	26
54	Plus Gel 517mg	04/08/2024	9	14	5	28
55	Plus Jarabe 194mg	04/08/2024	4	10	5	19
56	Plus Jarabe 819mg	04/08/2024	7	11	3	21
57	Plus Tableta 261mg	04/08/2024	6	13	5	24
58	Rápido Gel 271mg	04/08/2024	8	14	2	24
59	Rápido Gel 918mg	04/08/2024	10	13	3	26
60	Rápido Tableta 428mg	04/08/2024	9	8	5	22
61	Amoxicilina 500mg	05/08/2024	9	6	4	19
62	Azitromicina 500mg	05/08/2024	10	12	5	27
63	Combi Cápsula 340mg	05/08/2024	11	11	4	26
64	Combi Cápsula 678mg	05/08/2024	8	6	3	17
65	Combi Crema 152mg	05/08/2024	11	6	5	22
66	comercial crema 315mg	05/08/2024	5	6	1	12
67	comercial crema 924mg	05/08/2024	6	4	2	12
68	Crema para manos	05/08/2024	10	14	4	28
69	Diclofenaco 50mg	05/08/2024	9	5	5	19
70	Diclofenaco Ampolla	05/08/2024	7	8	3	18

71	Fórmula Crema 719mg	05/08/2024	5	7	2	14
72	Fórmula Gel 901mg	05/08/2024	10	7	2	19
73	formula tableta 527mg	05/08/2024	5	5	3	13
74	Fórmula Tableta 628mg	05/08/2024	9	11	2	22
75	generico gel 687mg	05/08/2024	8	6	3	17
76	generico jarabe 797mg	05/08/2024	9	5	2	16
77	Metformina 850mg	05/08/2024	6	7	2	15
78	Omega 3-6-9	05/08/2024	6	7	2	15
79	Plus Spray 937mg	05/08/2024	5	6	4	15
80	Plus Tableta 360mg	05/08/2024	9	8	4	21
81	rapido crema 401mg	05/08/2024	5	5	2	12
82	Rápido Crema 764mg	05/08/2024	4	14	5	23
83	Rápido Jarabe 264mg	05/08/2024	10	11	5	26
84	Vitamina C 500mg	05/08/2024	10	7	5	22
85	combi crema 652mg	06/08/2024	4	14	5	23
86	Combi Gel 257mg	06/08/2024	6	9	2	17
87	combi gel 848mg	06/08/2024	6	10	3	19
88	Comercial Cápsula 940mg	06/08/2024	10	12	5	27
89	Dimeticona Gotas 30ml	06/08/2024	10	5	5	20
90	formula capsula 331mg	06/08/2024	7	12	2	21
91	Fórmula Cápsula 830mg	06/08/2024	8	5	5	18
92	Fórmula Jarabe 847mg	06/08/2024	11	10	5	26
93	formula spray 263mg	06/08/2024	6	7	3	16
94	Genérico Cápsula 903mg	06/08/2024	9	11	4	24
95	Genérico Crema 599mg	06/08/2024	11	12	4	27
96	generico gel 477mg	06/08/2024	6	9	2	17
97	Ibuprofeno 400mg	06/08/2024	7	4	3	14
98	Levofloxacino 500mg	06/08/2024	11	13	4	28
99	Loperamida 2mg	06/08/2024	8	7	2	17
100	naproxeno	06/08/2024	12	10	3	25
101	Plus Gel 260mg	06/08/2024	10	6	5	21
102	Ranitidina 150mg	06/08/2024	10	10	4	24

103	Rápido Cápsula 371mg	06/08/2024	11	7	2	20
104	Rápido Cápsula 386mg	06/08/2024	5	11	3	19
105	Rápido Cápsula 432mg	06/08/2024	6	13	3	22
106	Rápido Cápsula 854mg	06/08/2024	4	5	5	14
107	rapido spray 464mg	06/08/2024	11	12	5	28
108	Shampoo Anticaspa Medicated	06/08/2024	11	10	3	24
109	Ceftriaxona Inyectable 1g	07/08/2024	8	5	3	16
110	Cepillo Dental Colgate	07/08/2024	10	10	3	23
111	Cepillo Dental Sensodyne	07/08/2024	10	7	5	22
112	Cloro Alergan (Frascco)	07/08/2024	12	10	2	24
113	Colgate Total 12	07/08/2024	8	10	5	23
114	Combi Cápsula 894mg	07/08/2024	4	7	3	14
115	Combi Spray 434mg	07/08/2024	11	13	5	29
116	Combi Tableta 214mg	07/08/2024	8	13	3	24
117	comercial capsula 340mg	07/08/2024	5	4	2	11
118	Comercial Cápsula 778mg	07/08/2024	6	7	4	17
119	comercial crema 431mg	07/08/2024	6	8	4	18
120	Comercial Crema 510mg	07/08/2024	7	12	3	22
121	Comercial Tableta 251mg	07/08/2024	9	9	4	22
122	Doxiciclina 100mg	07/08/2024	6	9	3	18
123	Fórmula Gel 681mg	07/08/2024	10	12	3	25
124	Fórmula Jarabe 387mg	07/08/2024	5	13	3	21
125	Fórmula Jarabe 779mg	07/08/2024	8	4	4	16
126	formula tableta 817mg	07/08/2024	11	5	3	19
127	Genérico Crema 995mg	07/08/2024	4	9	4	17
128	generico jarabe 539mg	07/08/2024	12	12	6	30

129	Genérico Spray 667mg	07/08/2024	11	14	2	27
130	Hidrocortisona Crema 1%	07/08/2024	9	12	3	24
131	Jabón de avena	07/08/2024	6	14	3	23
132	Losartán 50mg	07/08/2024	5	10	2	17
133	plus gel 885mg	07/08/2024	14	16	4	34
134	Plus Gel 947mg	07/08/2024	11	9	2	22
135	Plus Jarabe 316mg	07/08/2024	8	8	5	21
136	Plus Spray 529mg	07/08/2024	10	6	2	18
137	Plus Spray 613mg	07/08/2024	4	13	2	19
138	Rápido Cápsula 739mg	07/08/2024	8	5	2	15
139	rapido gel 309mg	07/08/2024	8	12	4	24
140	Salbutamol Inhalador	07/08/2024	6	5	5	16
141	Simvastatina 20mg	07/08/2024	8	7	5	20
142	Tabcin	07/08/2024	7	14	3	24
143	bismuto	08/08/2024	6	6	4	16
144	Cepillo Dental	08/08/2024	11	4	2	17
145	Combi Cápsula 389mg	08/08/2024	5	9	4	18
146	Combi Crema 248mg	08/08/2024	5	9	5	19
147	Combi Spray 154mg	08/08/2024	11	9	3	23
148	Combi Tableta 315mg	08/08/2024	4	11	3	18
149	comercial capsula 141mg	08/08/2024	8	9	3	20
150	Comercial Spray 957mg	08/08/2024	9	12	3	24
151	Fórmula Cápsula 690mg	08/08/2024	9	4	3	16
152	Genérico Cápsula 446mg	08/08/2024	11	8	3	22
153	Genérico Crema 924mg	08/08/2024	4	9	4	17
154	generico spray 669mg	08/08/2024	9	13	2	24
155	Ibuprofeno Jarabe 100ml	08/08/2024	6	14	5	25
156	Naproxeno 250mg	08/08/2024	11	12	4	27
157	plus capsula 442mg	08/08/2024	6	6	1	13
158	Plus Cápsula 571mg	08/08/2024	5	6	4	15
159	Plus Cápsula 718mg	08/08/2024	4	10	2	16
160	plus tableta 530mg	08/08/2024	9	7	2	18
161	Rápido Jarabe 281mg	08/08/2024	7	5	3	15

162	Rápido Tableta 659mg	08/08/2024	8	8	4	20
163	Clorfenamina + Fenilefrina	09/08/2024	9	5	2	16
164	Clotrimazol Crema 1%	09/08/2024	8	4	2	14
165	Combi Cápsula 323mg	09/08/2024	8	12	2	22
166	combi tableta 128mg	09/08/2024	9	7	4	20
167	Comercial Cápsula 421mg	09/08/2024	7	11	2	20
168	comercial crema 475mg	09/08/2024	6	11	5	22
169	comercial gel 240mg	09/08/2024	9	7	5	21
170	comercial jarabe 822mg	09/08/2024	11	7	2	20
171	Comercial Spray 148mg	09/08/2024	5	7	3	15
172	Enjuague Bucal Listerine	09/08/2024	4	8	3	15
173	FERVEX	09/08/2024	11	12	3	26
174	Gel Antibacterial	09/08/2024	7	8	3	18
175	Genérico Gel 945mg	09/08/2024	4	14	3	21
176	Genérico Spray 722mg	09/08/2024	8	5	3	16
177	generico spray 928mg	09/08/2024	8	7	3	18
178	Ibuprofeno 400 mg	09/08/2024	10	6	3	19
179	Jeringa 3ml N°21	09/08/2024	8	6	2	16
180	Magnesio + Zinc	09/08/2024	10	12	2	24
181	Plus Tableta 647mg	09/08/2024	8	6	4	18
182	Rápido Crema 469mg	09/08/2024	5	5	4	14
183	rapido crema 653mg	09/08/2024	9	7	3	19
184	rapido crema 945mg	09/08/2024	8	8	3	19
185	Rápido Jarabe 246mg	09/08/2024	8	13	4	25
186	Rápido Spray 113mg	09/08/2024	11	12	3	26
187	rapido spray 155mg	09/08/2024	6	6	4	16
188	rapido spray 802mg	09/08/2024	8	6	3	17
189	Rápido Tableta 924mg	09/08/2024	5	14	3	22
190	Vitamina C	09/08/2024	6	6	4	16
191	Antigripal en Jarabe 120ml	10/08/2024	8	10	5	23
192	Beclometasona Inhalador	10/08/2024	8	12	4	24


193	Combi Cápsula 724mg	10/08/2024	5	13	2	20
194	Comercial Crema 451mg	10/08/2024	4	7	4	15
195	Comercial Jarabe 372mg	10/08/2024	7	6	3	16
196	Comercial Spray 255mg	10/08/2024	10	7	2	19
197	crema hidratante	10/08/2024	6	4	4	14
198	formula capsula 236mg	10/08/2024	9	11	2	22
199	Fórmula Crema 690mg	10/08/2024	6	5	4	15
200	Fórmula Jarabe 389mg	10/08/2024	8	13	4	25
201	Genérico Crema 729mg	10/08/2024	4	5	2	11
202	Genérico Tableta 766mg	10/08/2024	6	4	3	13
203	Multivitamínico Completo	10/08/2024	10	13	3	26
204	Omeprazol 20 mg	10/08/2024	11	11	3	25
205	Panadol Forte	10/08/2024	8	10	5	23
206	Paracetamol 500 mg	10/08/2024	9	10	2	21
207	Paracetamol 500mg	10/08/2024	11	10	2	23
208	Paracetamol Jarabe	10/08/2024	10	8	4	22
209	Plus Gel 980mg	10/08/2024	11	10	4	25
210	Plus Spray 449mg	10/08/2024	4	10	5	19
211	Calcio + Vitamina D	11/08/2024	4	6	4	14
212	Ciprofloxacino 500mg	11/08/2024	9	9	2	20
213	Combi Cápsula 730mg	11/08/2024	5	4	3	12
214	combi tableta 670mg	11/08/2024	9	6	2	17
215	Comercial Cápsula 953mg	11/08/2024	7	8	3	18
216	Comercial Tableta 222mg	11/08/2024	11	14	3	28
217	Enjuague bucal	11/08/2024	9	9	4	22
218	Fórmula Crema 126mg	11/08/2024	6	6	5	17
219	Fórmula Jarabe 572mg	11/08/2024	6	7	4	17
220	Fórmula Spray 703mg	11/08/2024	6	12	2	20
221	formula tableta 360mg	11/08/2024	4	12	2	18

222	Genérico Tableta 764mg	11/08/2024	5	6	5	16
223	Jabón Íntimo	11/08/2024	11	14	5	30
224	Ketoprofeno 100mg	11/08/2024	10	14	5	29
225	Piroxicam	11/08/2024	10	4	2	16
226	Plus Cápsula 868mg	11/08/2024	4	14	3	21
227	Combi Crema 113mg	12/08/2024	5	13	2	20
228	combi crema 207mg	12/08/2024	4	5	3	12
229	Combi Jarabe 949mg	12/08/2024	8	9	5	22
230	Comercial Crema 343mg	12/08/2024	5	10	2	17
231	Dextrometorfano Jarabe 100ml	12/08/2024	9	7	5	21
232	Electrocardiógrafo Portátil	12/08/2024	7	11	3	21
233	Enjuague bucal Luminous White Carbón	12/08/2024	6	4	2	12
234	Esfigmomanómetro Manual	12/08/2024	9	4	3	16
235	Fórmula Jarabe 185mg	12/08/2024	10	13	4	27
236	Genérico Gel 303mg	12/08/2024	11	12	4	27
237	Genérico Gel 941mg	12/08/2024	6	12	3	21
238	Genérico Tableta 151mg	12/08/2024	9	10	5	24
239	Genérico Tableta 196mg	12/08/2024	4	7	4	15
240	Genérico Tableta 205mg	12/08/2024	7	11	3	21
241	Hilo Dental Oral-B Essential Floss	12/08/2024	8	5	3	16
242	Meloxicam 15mg	12/08/2024	7	13	5	25
243	Plus Crema 887mg	12/08/2024	10	5	4	19
244	Plus Tableta 933mg	12/08/2024	9	9	2	20
245	rapido crema 439mg	12/08/2024	11	7	2	20
246	Rápido Gel 467mg	12/08/2024	6	13	4	23
247	Rápido Gel 951mg	12/08/2024	4	5	5	14
248	Rápido Tableta 548mg	12/08/2024	5	8	4	17
249	Vitamina B12	12/08/2024	11	14	3	28
250	Vitis Perio Cepillo	12/08/2024	6	4	2	12
251	Ambroxol Jarabe 120ml	13/08/2024	4	14	5	23
252	Clearblue Digital	13/08/2024	7	5	2	14

253	Clearblue Plus	13/08/2024	8	9	3	20
254	Combi Gel 748mg	13/08/2024	6	9	4	19
255	comercial crema 677mg	13/08/2024	9	13	2	24
256	Comercial Tableta 914mg	13/08/2024	6	7	3	16
257	Dexametasona Ampolla	13/08/2024	11	5	2	18
258	Enalapril 10mg	13/08/2024	8	12	2	22
259	Fórmula Spray 661mg	13/08/2024	5	8	4	17
260	Fórmula Spray 830mg	13/08/2024	11	11	5	27
261	Genérico Cápsula 749mg	13/08/2024	8	5	3	16
262	Genérico Gel 833mg	13/08/2024	9	12	5	26
263	Glucómetro Accu- Chek	13/08/2024	5	6	2	13
264	Jabón Neutro	13/08/2024	5	7	2	14
265	Meloxicam	13/08/2024	8	5	2	15
266	Multivitamínico	13/08/2024	4	12	2	18
267	Omeprazol 20mg	13/08/2024	8	9	3	20
268	Pasta Dental	13/08/2024	8	5	2	15
269	Pasta Dental Colgate Triple Acción	13/08/2024	15	11	4	30
270	Plus Crema 107mg	13/08/2024	6	12	4	22
271	plus jarabe 665mg	13/08/2024	6	4	5	15
272	Plus Spray 456mg	13/08/2024	7	14	4	25
273	Plus Tableta 190mg	13/08/2024	4	8	4	16
274	Plus Tableta 904mg	13/08/2024	4	13	5	22
275	Plus Tableta 971mg	13/08/2024	8	6	5	19
276	Rápido Gel 226mg	13/08/2024	10	13	4	27
277	Rápido Jarabe 993mg	13/08/2024	10	11	5	26
278	Venda Adhesiva 1m	13/08/2024	6	7	2	15

Tabla 5

Test del indicador tasa de rotación de inventario

 <p>Universidad Norbert Wiener <small>Powered by Arizona State University®</small></p> <p>FACULTAD DE INGENIERIA Y NEGOCIOS ESCUELA ACADEMICO PROFESIONAL DE INGENIERIAS</p> <p>APLICACIÓN DE MACHINE LEARNING PARA LA EFICIENCIA EN LA GESTIÓN DE INVENTARIOS EN EL SECTOR FARMACÉUTICO LIMEÑO, 2024</p>					
Ficha de observación					
Objetivo: Determinar qué algoritmo de Machine Learning se puede implementar para mejorar la tasa de rotación en la gestión de inventarios en el sector farmacéutico limeño, 2024.					
Indicador: Tasa de rotación de inventario.					
Formula: $TR = VRV / VPE$			Autores: Rodas Cortijo Carmen Liliana,		
TR: Tasa de rotación			Villacrisis Guerrero Jahir Jesus		
VRV: Valor de las Referencias Vendidas			Libro: Manual de Gestión de almacenes.		
VPE: Valor Promedio de Existencias					
Pre-Test					
Nº	Producto	Fecha	Valor de las referencias vendidas	Valor promedio de existencias	Tasa de rotación
1	Amlodipino 5mg	05/09/2024	S/ 358.5	S/ 731.7	0.49
2	Azitromicina 500mg	05/09/2024	S/ 386.0	S/ 485.5	0.80
3	Calcio + Vitamina D	05/09/2024	S/ 429.6	S/ 172.1	2.50
4	Cepillo Dental	05/09/2024	S/ 566.9	S/ 279.3	2.03
5	Cepillo Dental Sensodyne	05/09/2024	S/ 683.3	S/ 495.7	1.38
6	Clotrimazol Crema 1%	05/09/2024	S/ 445.6	S/ 254.4	1.75
7	Combi Cápsula 724mg	05/09/2024	S/ 549.0	S/ 725.6	0.76
8	combi crema 900mg	05/09/2024	S/ 150.0	S/ 194.9	0.77
9	combi jarabe 335mg	05/09/2024	S/ 385.8	S/ 428.2	0.90
10	Electrocardiógrafo Portátil	05/09/2024	S/ 715.2	S/ 785.2	0.91
11	Fórmula Crema 719mg	05/09/2024	S/ 539.0	S/ 366.5	1.47

12	Fórmula Jarabe 185mg	05/09/2024	S/	536.6	S/	229.4	2.34
13	Fórmula Spray 703mg	05/09/2024	S/	707.7	S/	464.9	1.52
14	Fórmula Spray 830mg	05/09/2024	S/	700.6	S/	615.3	1.14
15	Genérico Crema 599mg	05/09/2024	S/	468.1	S/	877.9	0.53
16	Genérico Crema 729mg	05/09/2024	S/	384.6	S/	643.1	0.60
17	Genérico Crema 924mg	05/09/2024	S/	524.5	S/	772.0	0.68
18	Genérico Gel 833mg	05/09/2024	S/	202.6	S/	838.5	0.24
19	shampoo anticaspa	05/09/2024	S/	500.5	S/	615.5	0.81
20	Jabón Íntimo	05/09/2024	S/	153.7	S/	108.8	1.41
21	Jabón Neutro	05/09/2024	S/	381.7	S/	718.0	0.53
22	comercial spray 404mg	05/09/2024	S/	595.5	S/	578.6	1.03
23	comercial tableta 592mg	05/09/2024	S/	295.4	S/	124.4	2.38
24	combi gel 959mg	05/09/2024	S/	726.5	S/	760.5	0.96
25	Levofloxacino 500mg	05/09/2024	S/	209.9	S/	670.9	0.31
26	Meloxicam	05/09/2024	S/	110.1	S/	609.5	0.18
27	Plus Cápsula 571mg	05/09/2024	S/	214.7	S/	836.0	0.26
28	Plus Cápsula 718mg	05/09/2024	S/	214.7	S/	582.5	0.37
29	Plus Gel 260mg	05/09/2024	S/	463.3	S/	521.3	0.89
30	Plus Tableta 261mg	05/09/2024	S/	263.5	S/	359.3	0.73
31	Plus Tableta 377mg	05/09/2024	S/	234.8	S/	786.0	0.30
32	combi jarabe 961mg	05/09/2024	S/	259.3	S/	619.8	0.42
33	Ranitidina 150mg	05/09/2024	S/	128.1	S/	320.6	0.40
34	rapido crema 381mg	06/09/2024	S/	630.4	S/	865.3	0.73
35	comercial spray 433mg	06/09/2024	S/	225.0	S/	272.5	0.83
36	Colgate Total 12	06/09/2024	S/	200.9	S/	616.9	0.33
37	Combi Cápsula 730mg	06/09/2024	S/	328.0	S/	161.4	2.03
38	Comercial Cápsula 109mg	06/09/2024	S/	215.7	S/	381.5	0.57
39	comercial crema 924mg	06/09/2024	S/	237.2	S/	526.3	0.45
40	Enjuague Bucal Listerine	06/09/2024	S/	299.2	S/	222.4	1.35
41	Esfigmomanómetro Manual	06/09/2024	S/	568.1	S/	662.0	0.86

42	generico gel 687mg	06/09/2024	S/	86.8	S/	108.0	0.80
43	formula tableta 527mg	06/09/2024	S/	361.7	S/	719.2	0.50
44	Fórmula Cápsula 508mg	06/09/2024	S/	325.8	S/	726.8	0.45
45	Fórmula Spray 244mg	06/09/2024	S/	172.4	S/	486.9	0.35
46	Genérico Gel 303mg	06/09/2024	S/	148.9	S/	213.9	0.70
47	Genérico Tableta 205mg	06/09/2024	S/	392.3	S/	700.7	0.56
48	Genérico Tableta 764mg	06/09/2024	S/	198.0	S/	894.9	0.22
49	Jabón de avena	06/09/2024	S/	419.3	S/	243.3	1.72
50	rapido crema 401mg	06/09/2024	S/	295.8	S/	283.2	1.04
51	comercial crema 315mg	06/09/2024	S/	900.0	S/	597.5	1.51
52	Naproxeno 250mg	06/09/2024	S/	671.0	S/	219.3	3.06
53	Piroxicam	06/09/2024	S/	369.3	S/	871.4	0.42
54	Plus Spray 529mg	06/09/2024	S/	294.7	S/	798.9	0.37
55	Rápido Cápsula 432mg	06/09/2024	S/	197.7	S/	750.9	0.26
56	Rápido Gel 271mg	06/09/2024	S/	161.0	S/	150.2	1.07
57	Rápido Tableta 659mg	06/09/2024	S/	667.4	S/	257.8	2.59
58	generico jarabe 797mg	06/09/2024	S/	240.7	S/	733.5	0.33
59	combi gel 848mg	06/09/2024	S/	496.4	S/	163.2	3.04
60	Amoxicilina 500mg	07/09/2024	S/	576.2	S/	762.1	0.76
61	Antigripal en Jarabe 120ml	07/09/2024	S/	677.3	S/	671.2	1.01
62	generico gel 477mg	07/09/2024	S/	191.7	S/	710.2	0.27
63	Combi Cápsula 678mg	07/09/2024	S/	413.1	S/	521.9	0.79
64	Combi Cápsula 894mg	07/09/2024	S/	103.9	S/	264.7	0.39
65	Combi Crema 152mg	07/09/2024	S/	766.3	S/	521.4	1.47
66	Combi Spray 154mg	07/09/2024	S/	317.9	S/	778.9	0.41
67	Combi Tableta 315mg	07/09/2024	S/	208.9	S/	444.0	0.47
68	Comercial Cápsula 421mg	07/09/2024	S/	494.2	S/	285.8	1.73
69	Comercial Jarabe 395mg	07/09/2024	S/	601.6	S/	348.8	1.73
70	Enjuague bucal	07/09/2024	S/	631.3	S/	299.0	2.11

71	Fórmula Jarabe 389mg	07/09/2024	S/	542.1	S/	346.0	1.57
72	Fórmula Jarabe 779mg	07/09/2024	S/	205.7	S/	899.0	0.23
73	Fórmula Tableta 947mg	07/09/2024	S/	362.1	S/	330.9	1.09
74	Genérico Spray 722mg	07/09/2024	S/	705.6	S/	465.3	1.52
75	Genérico Tableta 766mg	07/09/2024	S/	361.1	S/	561.2	0.64
76	Glucómetro Accu- Chek	07/09/2024	S/	744.6	S/	501.4	1.48
77	Ibuprofeno 400 mg	07/09/2024	S/	201.1	S/	434.5	0.46
78	combi crema 652mg	07/09/2024	S/	372.7	S/	536.2	0.70
79	Magnesio + Zinc	07/09/2024	S/	432.7	S/	436.4	0.99
80	formula spray 263mg	07/09/2024	S/	383.0	S/	601.1	0.64
81	Omeprazol 20 mg	07/09/2024	S/	694.3	S/	673.7	1.03
82	Paracetamol 500mg	07/09/2024	S/	786.7	S/	728.7	1.08
83	Pasta Dental	07/09/2024	S/	467.4	S/	422.2	1.11
84	Plus Gel 947mg	07/09/2024	S/	659.1	S/	833.6	0.79
85	Plus Jarabe 316mg	07/09/2024	S/	583.4	S/	281.2	2.07
86	Plus Tableta 647mg	07/09/2024	S/	763.2	S/	851.0	0.90
87	Rápido Cápsula 371mg	07/09/2024	S/	602.0	S/	499.3	1.21
88	Vitamina B12	07/09/2024	S/	437.0	S/	598.0	0.73
89	Alcohol 70% 500ml	08/09/2024	S/	572.8	S/	340.9	1.68
90	Ambroxol Jarabe 120ml	08/09/2024	S/	477.1	S/	331.9	1.44
91	Ceftriaxona Inyectable 1g	08/09/2024	S/	454.1	S/	630.1	0.72
92	Clorfenamina + Fenilefrina	08/09/2024	S/	313.7	S/	850.7	0.37
93	naproxeno	08/09/2024	S/	787.6	S/	790.4	1.00
94	Combi Cápsula 340mg	08/09/2024	S/	610.8	S/	446.3	1.37
95	Combi Spray 434mg	08/09/2024	S/	535.1	S/	863.7	0.62
96	Comercial Crema 451mg	08/09/2024	S/	317.3	S/	662.5	0.48
97	Comercial Crema 510mg	08/09/2024	S/	365.4	S/	791.1	0.46
98	Comercial Spray 148mg	08/09/2024	S/	236.5	S/	197.3	1.20
99	formula capsula 331mg	08/09/2024	S/	778.6	S/	725.1	1.07
100	Doxiciclina 100mg	08/09/2024	S/	712.7	S/	857.3	0.83

101	Enalapril 10mg	08/09/2024	S/	370.7	S/	738.1	0.50
102	rapido spray 464mg	08/09/2024	S/	587.2	S/	196.7	2.99
103	Fórmula Spray 661mg	08/09/2024	S/	478.5	S/	663.7	0.72
104	Genérico Cápsula 903mg	08/09/2024	S/	649.0	S/	309.3	2.10
105	Genérico Crema 995mg	08/09/2024	S/	770.1	S/	166.4	4.63
106	plus gel 885mg	08/09/2024	S/	622.0	S/	822.6	0.76
107	Multivitamínico Completo	08/09/2024	S/	490.7	S/	706.1	0.69
108	rapido gel 309mg	08/09/2024	S/	123.9	S/	854.2	0.15
109	Omeprazol 20mg	08/09/2024	S/	661.7	S/	882.8	0.75
110	Plus Cápsula 289mg	08/09/2024	S/	610.3	S/	774.1	0.79
111	Plus Spray 456mg	08/09/2024	S/	786.0	S/	715.7	1.10
112	Rápido Crema 137mg	08/09/2024	S/	391.3	S/	645.4	0.61
113	Rápido Crema 349mg	08/09/2024	S/	340.3	S/	387.8	0.88
114	Rápido Crema 469mg	08/09/2024	S/	214.4	S/	677.3	0.32
115	Rápido Crema 481mg	08/09/2024	S/	332.6	S/	757.3	0.44
116	Rápido Gel 226mg	08/09/2024	S/	550.0	S/	663.8	0.83
117	Rápido Tableta 428mg	08/09/2024	S/	323.7	S/	481.2	0.67
118	Rápido Tableta 548mg	08/09/2024	S/	568.6	S/	665.6	0.85
119	Salbutamol Inhalador	08/09/2024	S/	772.8	S/	766.3	1.01
120	Vitamina C	08/09/2024	S/	123.1	S/	293.4	0.42
121	Cepillo Dental Colgate	09/09/2024	S/	373.2	S/	335.2	1.11
122	Ciprofloxacino 500mg	09/09/2024	S/	186.7	S/	407.0	0.46
123	Combi Cápsula 306mg	09/09/2024	S/	330.4	S/	102.3	3.23
124	Combi Crema 248mg	09/09/2024	S/	482.4	S/	846.1	0.57
125	Combi Crema 346mg	09/09/2024	S/	370.5	S/	684.4	0.54
126	Combi Gel 335mg	09/09/2024	S/	676.9	S/	888.9	0.76
127	Combi Gel 376mg	09/09/2024	S/	741.6	S/	214.1	3.46
128	Comercial Cápsula 778mg	09/09/2024	S/	262.5	S/	744.2	0.35
129	Comercial Tableta 222mg	09/09/2024	S/	431.3	S/	601.9	0.72

130	Comercial Tableta 251mg	09/09/2024	S/	781.4	S/	737.5	1.06
131	Fórmula Cápsula 914mg	09/09/2024	S/	646.9	S/	471.4	1.37
132	Fórmula Gel 901mg	09/09/2024	S/	195.8	S/	168.7	1.16
133	Fórmula Jarabe 430mg	09/09/2024	S/	734.4	S/	658.5	1.12
134	Fórmula Tableta 628mg	09/09/2024	S/	298.4	S/	790.8	0.38
135	Genérico Gel 941mg	09/09/2024	S/	288.5	S/	452.9	0.64
136	Genérico Gel 945mg	09/09/2024	S/	413.2	S/	740.7	0.56
137	Genérico Tableta 196mg	09/09/2024	S/	109.6	S/	851.9	0.13
138	comercial crema 431mg	09/09/2024	S/	365.7	S/	304.8	1.20
139	Ibuprofeno 400mg	09/09/2024	S/	200.0	S/	737.7	0.27
140	generico jarabe 539mg	09/09/2024	S/	167.4	S/	348.3	0.48
141	comercial capsula 340mg	09/09/2024	S/	496.8	S/	898.6	0.55
142	Ketoprofeno 100mg	09/09/2024	S/	436.1	S/	536.2	0.81
143	formula tableta 817mg	09/09/2024	S/	147.2	S/	265.4	0.55
144	Losartán 50mg	09/09/2024	S/	657.5	S/	716.8	0.92
145	generico spray 669mg	09/09/2024	S/	73.0	S/	52.0	1.40
146	bismuto	09/09/2024	S/	641.1	S/	127.0	5.05
147	Multivitamínico	09/09/2024	S/	494.7	S/	628.3	0.79
148	plus tableta 530mg	09/09/2024	S/	208.0	S/	298.6	0.70
149	Omega 3-6-9	09/09/2024	S/	771.1	S/	712.8	1.08
150	Plus Spray 449mg	09/09/2024	S/	436.3	S/	899.2	0.49
151	Plus Spray 904mg	09/09/2024	S/	633.8	S/	732.8	0.86
152	Plus Tableta 360mg	09/09/2024	S/	259.4	S/	432.1	0.60
153	Rápido Gel 467mg	09/09/2024	S/	463.7	S/	809.4	0.57
154	Shampoo Anticaspa Medicated	09/09/2024	S/	449.6	S/	187.0	2.40
155	Tabcin	09/09/2024	S/	152.1	S/	870.2	0.17
156	comercial capsula 141mg	10/09/2024	S/	518.0	S/	815.0	0.64
157	plus capsula 442mg	10/09/2024	S/	205.4	S/	372.6	0.55
158	comercial jarabe 822mg	10/09/2024	S/	306.9	S/	818.6	0.37
159	rapido spray 155mg	10/09/2024	S/	557.1	S/	528.3	1.05
160	comercial crema 475mg	10/09/2024	S/	1,355.0	S/	1,510.5	0.90

161	generico spray 928mg	10/09/2024	S/	222.0	S/	382.0	0.58
162	Combi Cápsula 323mg	10/09/2024	S/	353.1	S/	529.4	0.67
163	Combi Gel 748mg	10/09/2024	S/	121.9	S/	499.6	0.24
164	Comercial Cápsula 940mg	10/09/2024	S/	457.9	S/	176.7	2.59
165	Comercial Cápsula 953mg	10/09/2024	S/	611.9	S/	195.8	3.13
166	Comercial Crema 184mg	10/09/2024	S/	797.4	S/	407.8	1.96
167	Comercial Spray 255mg	10/09/2024	S/	337.9	S/	636.3	0.53
168	Complejo B	10/09/2024	S/	428.2	S/	456.7	0.94
169	Crema para manos	10/09/2024	S/	472.5	S/	631.5	0.75
170	Dimeticona Gotas 30ml	10/09/2024	S/	255.7	S/	431.5	0.59
171	rapido crema 945mg	10/09/2024	S/	347.6	S/	882.6	0.39
172	Fórmula Crema 564mg	10/09/2024	S/	137.8	S/	600.9	0.23
173	Fórmula Crema 690mg	10/09/2024	S/	448.3	S/	857.2	0.52
174	Fórmula Gel 681mg	10/09/2024	S/	428.3	S/	293.3	1.46
175	Fórmula Gel 692mg	10/09/2024	S/	264.3	S/	642.5	0.41
176	Fórmula Jarabe 441mg	10/09/2024	S/	331.4	S/	293.1	1.13
177	Genérico Cápsula 446mg	10/09/2024	S/	428.6	S/	516.5	0.83
178	Genérico Tableta 151mg	10/09/2024	S/	254.3	S/	110.7	2.30
179	Loperamida 2mg	10/09/2024	S/	514.3	S/	701.4	0.73
180	Meloxicam 15mg	10/09/2024	S/	301.8	S/	895.1	0.34
181	Metformina 850mg	10/09/2024	S/	113.1	S/	570.6	0.20
182	combi tableta 128mg	10/09/2024	S/	244.0	S/	592.8	0.41
183	Paracetamol 500 mg	10/09/2024	S/	137.6	S/	816.1	0.17
184	Plus Cápsula 868mg	10/09/2024	S/	701.8	S/	364.8	1.92
185	Plus Spray 937mg	10/09/2024	S/	270.8	S/	513.8	0.53
186	Plus Tableta 933mg	10/09/2024	S/	763.3	S/	439.3	1.74
187	Rápido Cápsula 854mg	10/09/2024	S/	533.4	S/	321.4	1.66
188	Rápido Crema 592mg	10/09/2024	S/	614.4	S/	290.4	2.12
189	Rápido Jarabe 264mg	10/09/2024	S/	310.4	S/	228.4	1.36
190	Rápido Jarabe 281mg	10/09/2024	S/	557.9	S/	814.7	0.68

191	Rápido Tableta 924mg	10/09/2024	S/	686.7	S/	445.2	1.54
192	Cefalexina 250mg/5ml	11/09/2024	S/	696.4	S/	894.4	0.78
193	comercial gel 240mg	11/09/2024	S/	138.0	S/	171.6	0.80
194	rapido spray 802mg	11/09/2024	S/	202.6	S/	178.4	1.14
195	Combi Cápsula 389mg	11/09/2024	S/	408.3	S/	380.3	1.07
196	Combi Jarabe 949mg	11/09/2024	S/	496.3	S/	757.0	0.66
197	Combi Tableta 214mg	11/09/2024	S/	467.8	S/	467.9	1.00
198	Comercial Cápsula 653mg	11/09/2024	S/	148.5	S/	882.2	0.17
199	Comercial Spray 957mg	11/09/2024	S/	115.6	S/	530.3	0.22
200	rapido crema 653mg	11/09/2024	S/	56.5	S/	61.4	0.92
201	Diclofenaco Ampolla	11/09/2024	S/	320.2	S/	360.0	0.89
202	FERVEX	11/09/2024	S/	477.0	S/	559.1	0.85
203	Fórmula Cápsula 690mg	11/09/2024	S/	172.4	S/	893.4	0.19
204	Fórmula Cápsula 830mg	11/09/2024	S/	508.0	S/	460.6	1.10
205	formula capsula 236mg	11/09/2024	S/	515.4	S/	630.2	0.82
206	Fórmula Jarabe 387mg	11/09/2024	S/	475.3	S/	721.7	0.66
207	Gel Antibacterial	11/09/2024	S/	183.1	S/	383.6	0.48
208	crema hidratante	11/09/2024	S/	690.2	S/	344.5	2.00
209	combi tableta 670mg	11/09/2024	S/	649.3	S/	838.0	0.77
210	formula tableta 360mg	11/09/2024	S/	348.5	S/	282.4	1.23
211	Plus Cápsula 701mg	11/09/2024	S/	577.1	S/	241.6	2.39
212	Plus Crema 107mg	11/09/2024	S/	765.8	S/	852.3	0.90
213	Plus Tableta 904mg	11/09/2024	S/	536.7	S/	537.9	1.00
214	Rápido Cápsula 386mg	11/09/2024	S/	240.8	S/	794.0	0.30
215	Rápido Cápsula 993mg	11/09/2024	S/	310.8	S/	711.4	0.44
216	Rápido Crema 187mg	11/09/2024	S/	654.9	S/	478.9	1.37
217	Rápido Crema 764mg	11/09/2024	S/	480.6	S/	672.4	0.71
218	Rápido Gel 918mg	11/09/2024	S/	295.7	S/	373.5	0.79
219	Rápido Jarabe 246mg	11/09/2024	S/	745.6	S/	803.7	0.93

220	Rápido Jarabe 993mg	11/09/2024	S/	458.8	S/	814.5	0.56
221	Simvastatina 20mg	11/09/2024	S/	551.8	S/	292.6	1.89
222	rapido crema 439mg	11/09/2024	S/	543.9	S/	462.1	1.18
223	combi crema 207mg	12/09/2024	S/	121.2	S/	780.4	0.16
224	Beclometasona Inhalador	12/09/2024	S/	613.1	S/	496.2	1.24
225	Comercial Crema 343mg	12/09/2024	S/	121.7	S/	333.2	0.37
226	Dextrometorfano Jarabe 100ml	12/09/2024	S/	335.3	S/	181.6	1.85
227	Diclofenaco 50mg	12/09/2024	S/	362.3	S/	885.9	0.41
228	Enjuague bucal Luminous White Carbón	12/09/2024	S/	145.6	S/	72.5	2.01
229	Fórmula Cápsula 847mg	12/09/2024	S/	556.5	S/	241.6	2.30
230	Fórmula Gel 642mg	12/09/2024	S/	105.7	S/	685.7	0.15
231	Fórmula Jarabe 572mg	12/09/2024	S/	450.6	S/	777.3	0.58
232	Fórmula Jarabe 847mg	12/09/2024	S/	444.0	S/	880.6	0.50
233	Genérico Cápsula 749mg	12/09/2024	S/	173.1	S/	332.7	0.52
234	Genérico Spray 183mg	12/09/2024	S/	785.6	S/	434.0	1.81
235	Hidrocortisona Crema 1%	12/09/2024	S/	241.2	S/	441.7	0.55
236	Hidróxido de aluminio	12/09/2024	S/	763.0	S/	503.2	1.52
237	Hilo Dental Oral-B Essential Floss	12/09/2024	S/	175.0	S/	102.1	1.71
238	Jeringa 3ml N°21	12/09/2024	S/	325.1	S/	178.9	1.82
239	Loratadina 10 mg	12/09/2024	S/	561.7	S/	601.8	0.93
240	comercial crema 677mg	12/09/2024	S/	80.5	S/	68.2	1.18
241	Panadol Forte	12/09/2024	S/	165.0	S/	466.5	0.35
242	Paracetamol Jarabe	12/09/2024	S/	650.3	S/	276.5	2.35
243	Paracetamol Jarabe 120ml	12/09/2024	S/	600.8	S/	680.1	0.88
244	Plus Crema 887mg	12/09/2024	S/	591.3	S/	840.2	0.70
245	Plus Gel 517mg	12/09/2024	S/	373.6	S/	899.7	0.42
246	Plus Gel 980mg	12/09/2024	S/	728.3	S/	502.7	1.45
247	Plus Tableta 971mg	12/09/2024	S/	360.2	S/	210.1	1.71
248	plus jarabe 665mg	12/09/2024	S/	102.6	S/	99.2	1.03
249	Rápido Spray 113mg	12/09/2024	S/	718.2	S/	577.4	1.24

250	rapido jarabe 754mg	12/09/2024	S/	90.0	S/	105.5	0.85
251	Venda Adhesiva 1m	12/09/2024	S/	708.9	S/	213.2	3.33
252	Vitamina C 500mg	12/09/2024	S/	630.2	S/	346.2	1.82
253	formula capsula 980mg	13/09/2024	S/	362.5	S/	850.7	0.43
254	Antigripal Compuesto	13/09/2024	S/	245.6	S/	189.9	1.29
255	Butilhioscina 10mg	13/09/2024	S/	763.1	S/	603.6	1.26
256	Clearblue Digital	13/09/2024	S/	518.7	S/	370.4	1.40
257	Clearblue Plus	13/09/2024	S/	135.0	S/	295.0	0.46
258	Combi Crema 113mg	13/09/2024	S/	627.4	S/	687.5	0.91
259	Combi Gel 257mg	13/09/2024	S/	515.0	S/	755.7	0.68
260	Comercial Jarabe 372mg	13/09/2024	S/	707.6	S/	387.6	1.83
261	Comercial Tableta 914mg	13/09/2024	S/	545.8	S/	151.9	3.59
262	Dexametasona Ampolla	13/09/2024	S/	355.1	S/	114.9	3.09
263	Fórmula Cápsula 937mg	13/09/2024	S/	718.0	S/	298.6	2.40
264	Fórmula Crema 126mg	13/09/2024	S/	700.6	S/	756.1	0.93
265	Fórmula Jarabe 546mg	13/09/2024	S/	577.2	S/	275.2	2.10
266	Genérico Spray 667mg	13/09/2024	S/	486.8	S/	480.3	1.01
267	Ibuprofeno Jarabe 100ml	13/09/2024	S/	112.0	S/	392.0	0.29
268	Loción para acné	13/09/2024	S/	357.5	S/	676.8	0.53
269	Pasta Dental Colgate Triple Acción	13/09/2024	S/	192.4	S/	97.4	1.98
270	Plus Jarabe 194mg	13/09/2024	S/	641.3	S/	841.4	0.76
271	Plus Jarabe 819mg	13/09/2024	S/	454.2	S/	420.1	1.08
272	Plus Spray 613mg	13/09/2024	S/	334.5	S/	704.8	0.47
273	Plus Tableta 190mg	13/09/2024	S/	786.0	S/	279.5	2.81
274	Rápido Cápsula 739mg	13/09/2024	S/	124.1	S/	543.4	0.23
275	Rápido Crema 675mg	13/09/2024	S/	198.8	S/	337.2	0.59
276	Rápido Gel 951mg	13/09/2024	S/	226.5	S/	482.8	0.47
277	Vendas	13/09/2024	S/	345.3	S/	669.2	0.52
278	Vitis Perio Cepillo	13/09/2024	S/	132.0	S/	94.0	1.40

Para la presente investigación, se realizó un análisis comparativo entre los datos obtenidos antes y después de la intervención, aplicando el enfoque de pretest y posttest. Esto permitió evaluar los efectos del sistema basado en Machine Learning en los indicadores clave de gestión de inventarios.

La comparación se efectuó mediante pruebas estadísticas inferenciales, dependiendo de la naturaleza de los datos (paramétricos o no paramétricos), con el objetivo de determinar si los cambios observados eran significativos desde el punto de vista estadístico.

3.7. Plan de procesamiento y análisis de datos

Se envió una solicitud formal de autorización a la empresa para proceder con la recolección de datos. El instrumento utilizado fue una ficha de observación diseñada para registrar indicadores clave. Una vez culminada la recopilación de datos, se compararon los resultados del pretest y posttest a fin de evaluar el impacto de la intervención tecnológica en la gestión de inventarios.

3.8. Aspectos éticos

Para la realización de este estudio, se adoptaron las normas de citación de la séptima edición de APA, asegurando así una presentación rigurosa y una adecuada atribución de las fuentes consultadas. Asimismo, se cumplieron las pautas establecidas por la Universidad Norbert Wiener para garantizar la calidad e integridad del trabajo. En el desarrollo del modelo de Machine Learning, se utilizó la inteligencia artificial de forma ética y responsable, realizando pruebas que comparan la eficiencia de la gestión de inventarios antes y después de su implementación. Además, se gestionó la autorización de la empresa para acceder a los datos sobre insumos médicos, lo que permitirá llevar a cabo el estudio de manera adecuada y proteger la privacidad de la información manejada.

3.9. ASPECTOS ADMINISTRATIVOS

3.9.1 Cronogramas de actividades

Para la elaboración del cronograma de actividades, se optó por un enfoque manual mediante el uso de herramientas de Excel, lo que permitió organizar y distribuir de manera detallada las tareas y plazos del proyecto. Aunque no se utilizó un diagrama de Gantt específico, el formato de Excel facilitó la planificación visual de las fases y actividades clave. La duración de las actividades abarca desde el 19 de agosto hasta diciembre de 2024, asegurando una adecuada gestión del tiempo y el seguimiento de los avances.

CAPÍTULO IV: PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS

4.1 Resultados

En la presente investigación se analizaron 278 productos tanto para la fase de pretest como para el postest, abarcando periodos de dos semanas durante los meses de agosto y setiembre de 2024, respectivamente. El análisis se desarrolló a partir de cuatro fichas de observación aplicadas con el apoyo del personal de la industria farmacéutica, con el objetivo de evaluar el impacto del sistema propuesto sobre los indicadores de gestión de inventario.

4.1.1. Análisis descriptivo de los resultados

En esta sección se presentan los datos registrados a partir de los indicadores definidos para la evaluación. Se consideraron dos métricas fundamentales: (a) el stock óptimo, correspondiente al control de inventario; y (b) la rotación de productos, asociada al movimiento de salida de insumos. La Tabla 6 muestra los valores relacionados al primer indicador, mientras que en la Tabla 7 se exponen los resultados vinculados al segundo.

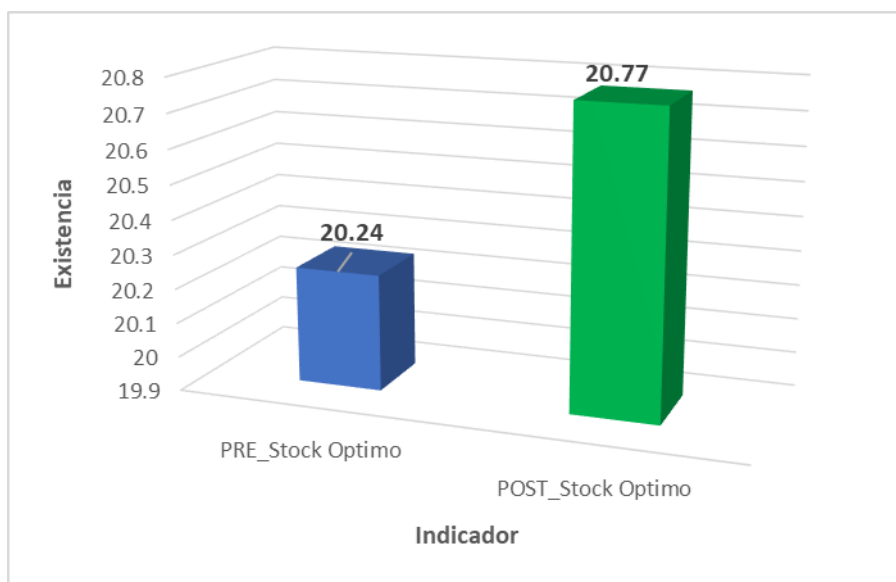
Tabla 6

Datos procesados para el indicador stock óptimo

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
PRE_Stock Optimo	278	11	34	20,24	4,459	19,886
POST_Stock Optimo	278	11	35	20,77	4,609	21,241
N válido (por lista)	278					

Figura 2

Media estadística del indicador stock óptimo



En la tabla 6 y en la figura 2, se puede apreciar de manera concisa los datos estadísticos del indicador stock óptimo. A su vez, también se observa que existe una diferencia significativa entre la media obtenida en el pre-test y la media registrada en el post-test. Específicamente, la media estadística resultante para el stock óptimo en el pre-test fue de 20.24 unidades, mientras que en el post-test se obtuvo una media de 20.77 unidades. Esto representa un incremento de aproximadamente 0.53 unidades por producto, equivalente a un aumento del 2.6% respecto al valor inicial. Este resultado evidencia que, tras la intervención implementada, la disponibilidad promedio de existencias por categoría de producto mejoró en la muestra analizada, compuesta por 278 registros.


Tabla 7

Datos procesados para el indicador tasa de rotación de inventario

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
PRE_Tasa_Rotacion	278	.1300000000	5.050000000	1.039203089	.7715199224	.595
POST_Tasa_Rotacion	278	.1291300000	5.083770000	1.069977554	.8135116262	.662
N válido (por lista)	278					

Figura 3

Media estadística del indicador tasa de rotación de inventario



En la Tabla 7 y en la Figura 3, se presenta de manera clara el comportamiento estadístico del indicador tasa de rotación de inventario. Se aprecia que existe una diferencia positiva entre los valores promedios obtenidos antes y después de la implementación del sistema basado en Machine Learning. En el pretest, la media de rotación fue de 1.04, mientras que en el posttest ésta aumentó a 1.07, lo que representa una diferencia de 0.03 unidades. Si bien esta variación puede parecer leve en términos absolutos, considerando el tamaño de la muestra analizada (278 productos), se trata de una mejora consistente que refleja un impacto favorable sobre la eficiencia del inventario. Este

aumento del 3% aproximadamente en la tasa de rotación sugiere que el sistema ayudó a optimizar la salida de productos del inventario, favoreciendo una gestión más ágil y reduciendo el riesgo de acumulación o vencimiento de stock.

4.1.2 Prueba de hipótesis.

Hipótesis específica 1: La aplicación de Machine Learning permitirá mantener el stock óptimo, lo que resultará en una reducción del desabastecimiento y un mejor control sobre los productos próximos a vencer.

A. Estadística inferencial

Para el presente análisis inferencial, se recurrió a la prueba de normalidad de Kolmogórov-Smirnov y Shapiro-Wilk, tal como se detalla en la Tabla 8. En esta se observa que, para el indicador de stock óptimo, tanto en el pretest como en el postest, los valores de significancia son menores a 0.05 (Sig. < 0.001 y Sig. = 0.003, respectivamente). Este resultado indica que los datos no siguen una distribución normal, motivo por el cual se rechaza la hipótesis nula y se confirma la hipótesis alternativa, planteadas del siguiente modo:

H₀¹: La muestra sigue una distribución normal.

H₁¹: La muestra no sigue una distribución normal.

En consecuencia, se evidencia que los datos presentan una distribución no normal, lo que justifica el uso de pruebas no paramétricas para continuar con el análisis estadístico. Por ello, se optó por la prueba de los rangos con signo de Wilcoxon para muestras emparejadas.

B. Prueba de normalidad

Para esta prueba se utilizó el método estadístico Kolmogórov-Smirnov, esto para el indicador stock óptimo, por la razón de que el presente estudio trabajo con la cantidad de 278 productos.

Tal como se muestra en la Tabla 8, la prueba de Kolmogórov-Smirnov evidencia que los datos del indicador stock óptimo, tanto en el pretest como en el posttest, presentan una distribución no normal. Los valores de significancia obtenidos son menores al umbral crítico de $\alpha = 0.05$, razón por la cual no se cumple con el supuesto de normalidad necesario para aplicar pruebas paramétricas. Por este motivo, se optó por el uso de la prueba de los rangos con signo de Wilcoxon para evaluar las diferencias entre ambos momentos de medición.

Tabla 8

Prueba de normalidad para el indicador stock óptimo

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
PRE_Stock Optimo	,083	278	<.001	,982	278	,001
POST_Stock Optimo	,077	278	<.001	,984	278	,003

C. Prueba de contraste

Se planteó la prueba de contraste respecto a la hipótesis de estudio H1¹: “La aplicación de Machine Learning permitirá mantener el stock óptimo, lo que resultará en una reducción del desabastecimiento y un mejor control sobre los productos próximos a vencer”; y la hipótesis nula H0¹: “La aplicación de Machine Learning no permitirá mantener el stock óptimo, por lo tanto, no

se logrará una reducción del desabastecimiento ni un mejor control sobre los productos próximos a vencer”.

Dado que los datos no presentan una distribución normal —según los resultados obtenidos en la prueba de normalidad—, se utilizó la prueba no paramétrica de los rangos con signo de Wilcoxon para muestras relacionadas, la cual es adecuada para este tipo de análisis con datos no paramétricos.

Tabla 9

Estadística descriptiva del indicador de stock optimo

		Media	N	Desviación estándar	Media de error estándar
Par 1	PRE_Stock Optimo	20,24	278	4,459	,267
	POST_Stock Optimo	20,77	278	4,609	,276

En la Tabla 9 se observa que la media del indicador stock óptimo en el pretest fue de 20,24 y en el postest aumentó ligeramente a 20,77. Esta diferencia representa un incremento de 0,53 unidades en promedio, lo que sugiere una mejora tras la implementación del sistema con Machine Learning. Sin embargo, dado que los datos no presentan normalidad, esta diferencia de medias se presenta únicamente como referencia descriptiva. La verificación estadística del cambio significativo se realiza a través de la prueba de Wilcoxon, cuyos resultados se detallan a continuación.

Tabla 10

Correlación de muestras emparejadas para el indicador stock óptimo

Correlaciones de muestras emparejadas

		N	Correlación	Sig.
Par 1	PRE_Stock Óptimo & POST_Stock Óptimo	278	,994	<.001

En la Tabla 10 se presenta la correlación entre las mediciones de stock óptimo antes y después de la implementación del sistema. Con una muestra de 278 registros, se observa un coeficiente de correlación de ,994, lo que indica una relación positiva y muy fuerte entre ambas mediciones. Esto sugiere que los valores del stock óptimo antes y después del sistema tienden a comportarse de manera similar, validando así la naturaleza emparejada de los datos.

Asimismo, dado que el valor de significancia es < ,001, menor al umbral de 0,05, se concluye que la correlación observada es estadísticamente significativa, y no se debe al azar. Este resultado respalda el uso de una prueba para muestras relacionadas, como la prueba de Wilcoxon, para contrastar los cambios ocurridos entre el pretest y el posttest.

Tabla 11

Prueba de rangos con signo de Wilcoxon para el indicador stock óptimo

Prueba de rangos con signo de Wilcoxon

		Rangos		
		N	Rango promedio	Suma de rangos
POST_Stock Óptimo - PRE_Stock Óptimo	Rangos negativos	0 ^a	,00	,00
	Rangos positivos	147 ^b	74,00	10878,00
	Empates	131 ^c		
	Total	278		

En la Tabla 11 se puede evidenciar que se utilizó la prueba no paramétrica de Wilcoxon para muestras relacionadas, con el fin de contrastar los valores del stock óptimo antes y después de la aplicación del sistema. Esta prueba se aplicó debido a que los datos no siguen una distribución normal, como se evidenció en el apartado de estadística inferencial. Se observa que, de los 278 registros analizados, 147 presentan rangos positivos, es decir, un aumento en el stock óptimo tras la intervención, 131 son empates y no se registran rangos negativos. Esto indica que no hubo casos en los que el valor del stock óptimo disminuyera luego de la implementación del sistema.

El estadístico Z obtenido fue de -12,124 con un nivel de significancia bilateral de $< 0,001$, lo cual es menor que el umbral de significancia $\alpha = 0,05$. Esto permite concluir que existe una diferencia estadísticamente significativa entre los valores de stock óptimo antes y después de la intervención, y por tanto se rechaza la hipótesis nula que planteaba la inexistencia de diferencias. Cabe resaltar que el valor negativo del estadístico Z indica que los valores del postest tienden a ser mayores que los del pretest, lo cual es coherente con la hipótesis planteada.

Por este motivo, se procedió a rechazar la hipótesis nula H_0^1 : “La aplicación de Machine Learning no permitirá mantener el stock óptimo, por lo tanto, no se logrará una reducción del desabastecimiento ni un mejor control sobre los productos próximos a vencer”; y se aceptó la hipótesis de estudio H_1^1 , la cual sostiene que: “La aplicación de Machine Learning permitirá mantener el stock óptimo, lo que resultará en una reducción del desabastecimiento y un mejor control sobre los productos próximos a vencer”.

Hipótesis específica 2: La implementación de algoritmos de Machine Learning mejorará significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales.

A. Estadística inferencial

Para la presente estadística inferencial se hace referencia a la Tabla 12, en donde se utilizó el método estadístico Kolmogórov-Smirnov con el objetivo de evaluar la normalidad de los datos relacionados al indicador tasa de rotación de inventario, considerando que el presente estudio trabajó con una muestra de 278 productos. Asimismo, se incluyó como complemento la prueba de Shapiro-Wilk. En ambos casos, tanto en la medición del pretest como del postest, se obtuvieron valores de significancia menores a 0.001, lo que indica que no se cumple el supuesto de normalidad en los datos, según se detalla a continuación:

H₀²: La muestra sigue una distribución normal.

H₁²: La muestra no sigue una distribución normal.

Por lo tanto, al observar que los valores de significancia son menores a 0.05, se rechaza la hipótesis nula y se concluye que los datos no presentan una distribución normal. En consecuencia, se justifica el uso de pruebas no paramétricas para el análisis de este indicador.

B. Prueba de normalidad

Para esta prueba se utilizó el método estadístico Kolmogórov-Smirnov, dado que el estudio se aplicó a un total de 278 productos, lo cual justifica el uso de esta prueba debido al tamaño de la muestra. Como respaldo adicional, también se consideró la prueba de Shapiro-Wilk, que aporta

mayor precisión para muestras pequeñas o medianas, aunque en este caso ambos métodos coinciden en el mismo resultado.

En la Tabla 12 se puede observar que los valores de significancia (Sig.) obtenidos para el indicador tasa de rotación de inventario fueron menores a 0.001 en ambas mediciones, tanto para el pretest (Sig. < 0.001) como para el posttest (Sig. < 0.001), según los estadísticos de Kolmogórov-Smirnov y Shapiro-Wilk. Esto indica que los datos no presentan una distribución normal, y por tanto no se cumple el supuesto de normalidad requerido para la aplicación de pruebas paramétricas. En consecuencia, se rechaza la hipótesis nula de normalidad y se asume la hipótesis alternativa, según se detalla a continuación:

Tabla 13

Prueba de normalidad para el indicador tasa de rotación de inventario

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
PRE_Tasa_Rotacion	,150	278	<.001	,840	278	<.001
POST_Tasa_Rotacion	,155	278	<.001	,832	278	<.001

C. Prueba de contraste

Se planteó la prueba de contraste en relación con la hipótesis específica HI2 del presente estudio: “La implementación de algoritmos de Machine Learning mejorará significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales”. Frente a la hipótesis nula H02: “La implementación de algoritmos de Machine Learning no mejorará

significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales”.

Dado que los datos no siguen una distribución normal, se optó por aplicar la prueba no paramétrica de rangos con signo de Wilcoxon para muestras relacionadas, la cual permite comparar si existen diferencias significativas entre las mediciones pretest y posttest de la tasa de rotación de inventario.

Tabla 14

Prueba de rangos con signo de Wilcoxon para el indicador tasa de rotación de inventario

Prueba de rangos con signo de Wilcoxon

		Rangos		
		N	Rango promedio	Suma de rangos
POST_Tasa_Rotacion - PRE_Tasa_Rotacion	Rangos negativos	113 ^a	126,97	14347,50
	Rangos positivos	165 ^b	148,08	24433,50
	Empates	0 ^c		
	Total	278		

a. POST_Tasa_Rotacion < PRE_Tasa_Rotacion

b. POST_Tasa_Rotacion > PRE_Tasa_Rotacion

c. POST_Tasa_Rotacion = PRE_Tasa_Rotacion

En la tabla 14 se puede observar que, de un total de 278 productos, 165 mostraron un incremento en la tasa de rotación en el post-test, con un rango promedio de 148.08. En cambio, 113 productos tuvieron una reducción, con un rango promedio menor (126.97). No se registraron empates. Esta diferencia en los rangos sugiere un cambio positivo tras la implementación del modelo de Machine Learning.

Tabla 15

Estadísticos de prueba para la comparación pretest-postest del indicador tasa de rotación de inventario

Estadísticos de prueba^a	
	POST_Tasa_Rotacion - PRE_Tasa_Rotacion
Z	-3,759 ^b
Sig. asin. (bilateral)	<.001

La tabla 15 muestra que la prueba de Wilcoxon arrojó un valor de significancia de $p < 0.001$, lo cual indica que existe una diferencia estadísticamente significativa entre los valores del pretest y postest. Como el valor de significancia es menor que el nivel $\alpha = 0.05$, se rechaza la hipótesis nula H02.

Por lo tanto, se concluye que la implementación del algoritmo de Machine Learning mejoró significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales. De esta manera, se acepta la hipótesis de estudio HI2.

4.1.3 Discusión de resultados

En concordancia con el marco teórico, los antecedentes revisados y los resultados obtenidos durante el desarrollo de la investigación, se aceptó la hipótesis del objetivo general, la cual planteaba que la implementación de Machine Learning influye significativamente en la gestión de inventarios.

Es importante señalar que, antes de esta investigación, la gestión de inventarios en el sector farmacéutico presentaba deficiencias notables, principalmente debido a la ausencia de un sistema tecnológico que permitiera un control eficaz y una administración adecuada de los productos. Esta limitación generaba consecuencias negativas como el almacenamiento excesivo y una baja rotación de existencias. A partir de la aplicación del modelo basado en Machine Learning, se observó una mejora estadísticamente significativa en los indicadores asociados a la gestión de inventarios, lo cual demuestra el impacto positivo de esta tecnología en dicho proceso. Estos hallazgos coinciden con lo reportado por Céspedes Cabrera y Ramos Corne (2022), quienes, en un estudio similar sobre la aplicación de Machine Learning para mejorar la eficiencia en la gestión de inventarios, obtuvieron una mejora del 42,23%, confirmando el potencial de estos modelos para transformar la administración de recursos. Asimismo, los resultados obtenidos respaldan lo expuesto por Flamarique (2017), quien sostiene que la implementación de algoritmos de Machine Learning constituye una alternativa confiable, eficiente y viable para las organizaciones que buscan optimizar sus procesos de almacenamiento, control de stock y rotación de productos. En ese sentido, se reafirma y se valida la hipótesis general de la presente investigación, la cual demuestra que el uso de Machine Learning mejora de manera efectiva la eficiencia en la gestión de inventarios dentro del contexto farmacéutico limeño.

Por otro lado, se reafirma el enunciado de la hipótesis del objetivo específico 1, de acuerdo con los resultados obtenidos. En consecuencia, se procedió a aceptar la hipótesis H1¹, la cual señala que la aplicación de Machine Learning permite mantener el stock óptimo, contribuyendo a una mejor gestión de inventarios. Antes de la intervención, la media del indicador stock óptimo fue de 20.23, mientras que después de aplicar el sistema basado en Machine Learning, esta se incrementó

ligeramente a 20.46. Asimismo, se registró un mínimo de 11 y un máximo de 34 en el pretest, y un mínimo de 12 y un máximo de 32 en el postest. Aunque la variación en la media fue leve, esta fue estadísticamente significativa según la prueba no paramétrica de los rangos con signo de Wilcoxon, la cual se aplicó tras comprobar, mediante la prueba de Kolmogórov-Smirnov, que los datos no seguían una distribución normal. Estos resultados guardan relación con lo planteado por Aylas Curi (2022), quien en su investigación señaló como objetivo implementar Machine Learning para mejorar el stock óptimo de una empresa. En su estudio, antes de la aplicación del sistema, la media del indicador fue de 30 existencias, incrementándose posteriormente a 38, lo que representó una mejora del 25%. Este hallazgo sugiere que la aplicación de Machine Learning puede generar tanto reducciones como incrementos en el stock óptimo, dependiendo de los objetivos y necesidades específicas de cada organización. En la misma línea, Cruz Fernández (2018) sostiene que la implementación de sistemas basados en Machine Learning permite una gran adaptabilidad para mejorar diversos procesos, incluyendo la gestión de inventarios, satisfaciendo diferentes tipos de requerimientos en función del contexto organizacional.

Asimismo, se confirma la hipótesis correspondiente al objetivo específico 2, en función de los resultados obtenidos, aceptándose la hipótesis H2. Antes de la aplicación del sistema basado en Machine Learning, la media de la tasa de rotación de inventario fue de 1.60; tras la implementación del sistema, esta aumentó ligeramente a 1.61, evidenciando una mejora en la eficiencia con la que se renuevan los productos almacenados. En el pretest, se registró un mínimo de 0.46 y un máximo de 2.01, mientras que en el postest se observó un mínimo de 0.66 y un máximo de 2.18. Estos resultados reflejan un incremento, aunque leve, en la tasa de rotación. La prueba de Kolmogórov-Smirnov arrojó una significancia menor a 0.05, por lo que se determinó que los datos no seguían

una distribución normal. En consecuencia, se aplicó la prueba no paramétrica de Wilcoxon para muestras relacionadas, la cual arrojó un valor de significancia de 0.000, indicando que la diferencia observada es estadísticamente significativa y que puede atribuirse a la intervención con el sistema basado en Machine Learning. Estos hallazgos coinciden con lo planteado por Anaya Usuriaga (2021), quien señaló como objetivo aplicar algoritmos de Machine Learning para mejorar la tasa de rotación en la gestión de inventarios. En su investigación, la media de la tasa de rotación pasó de 0.64 a 1.01, lo que representó un incremento del 37%, confirmando el impacto positivo de esta tecnología en la eficiencia de los almacenes. Por su parte, Roux (2009) sostiene que los sistemas basados en Machine Learning están diseñados para mejorar tanto la eficiencia como la experiencia de los usuarios, destacando además la ventaja de poder acceder remotamente a la información, lo que facilita la colaboración en tiempo real y permite una mayor escalabilidad para enfrentar diversas necesidades organizacionales.

4.2 Desarrollo del Sistema empleando la metodología SCRUM

A continuación, se detalla el desarrollo del sistema propuesto para mejorar la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, empleando la metodología ágil SCRUM. En este apartado se presenta la construcción progresiva del sistema a través de los Sprints establecidos, abordando funcionalidades clave como el registro de inventario, los reportes analíticos y la predicción del stock óptimo. Esta última fue implementada mediante un modelo de aprendizaje automático Random Forest Regressor, entrenado con registros históricos de ventas y variables operativas del establecimiento, en línea con los objetivos específicos planteados en la investigación.

4.2.1. Requerimientos del Sistema

Tabla 16

Requerimientos Funcionales

Código	Descripción
RF-01	El sistema debe permitir el registro de productos, incluyendo nombre, categoría, presentación, precio, stock y fecha.
RF-02	El sistema debe almacenar registros históricos de ventas diarias por producto y sede.
RF-03	El sistema debe generar reportes visuales de la tasa de rotación de productos por nombre o por ranking.
RF-04	El sistema debe identificar productos en estado de bajo stock y emitir alertas.
RF-05	El sistema debe predecir el nivel óptimo de stock utilizando un modelo de Machine Learning.
RF-06	El sistema debe mostrar gráficamente la comparación entre stock actual y recomendado.

Tabla 17

Requerimientos No Funcionales

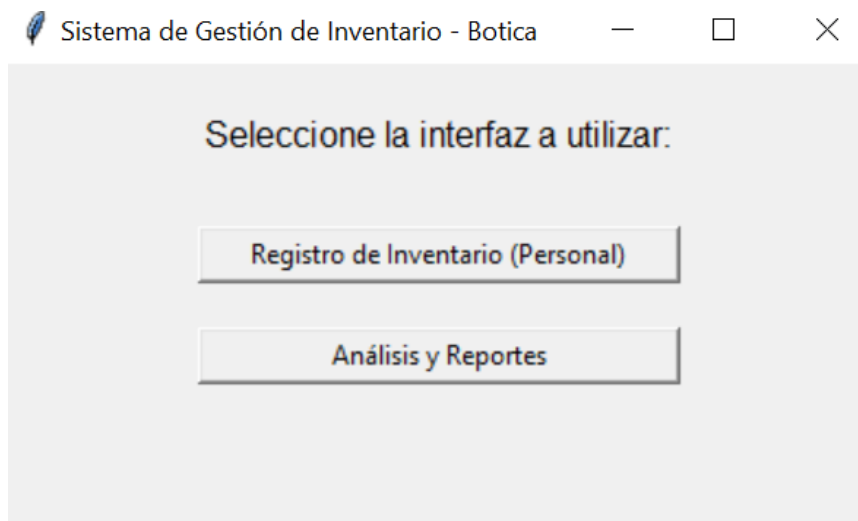
Código	Descripción
RNF-01	El sistema debe tener una interfaz amigable e intuitiva para usuarios con conocimientos básicos en informática.
RNF-02	El sistema debe funcionar sin conexión a internet, operando de forma local.
RNF-03	El sistema debe registrar los datos en una base de datos SQLite de forma eficiente y sin demoras perceptibles.
RNF-04	El sistema debe ejecutarse en computadoras con Windows 10 o superior sin requerir instalación de software adicional complejo.
RNF-05	El sistema debe mostrar mensajes claros de error cuando los datos ingresados sean inválidos.

4.2.2. Interfaz principal del sistema

Al ejecutar el sistema, el usuario es recibido con una pantalla principal que le permite seleccionar entre dos interfaces: una destinada al personal encargado del registro diario de medicamentos y otra destinada al análisis avanzado y reportes generados por el administrador o responsable de la toma de decisiones.

Figura 6

Interfaz principal del sistema

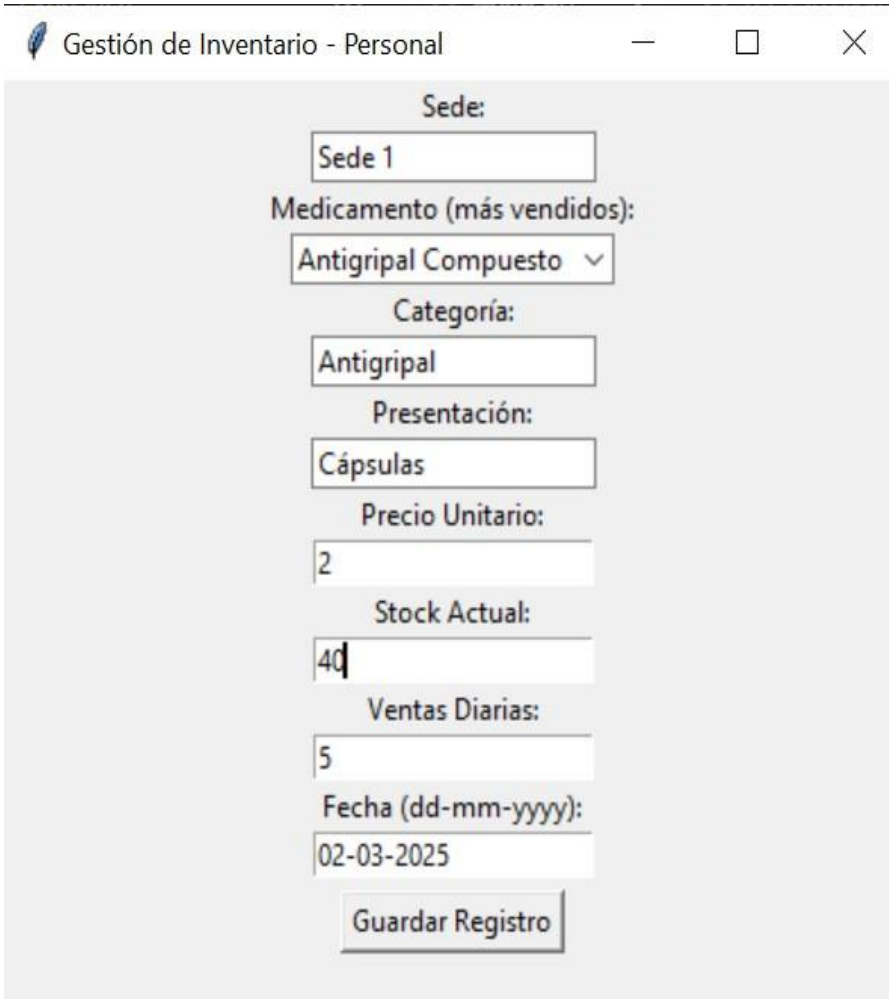


4.2.3. Registro de Inventario por parte del Personal

La interfaz de registro está diseñada para facilitar el ingreso de productos de manera intuitiva y rápida. Se incorporan campos con sugerencias automáticas para sede, medicamento, categoría y presentación, a fin de minimizar errores. Además, se añade un ComboBox con los productos más vendidos, y un sistema de alerta que notifica cuando el stock es bajo, facilitando la gestión preventiva.

Figura 7

Interfaz para el registro de inventario



Sede:
Sede 1

Medicamento (más vendidos):
Antigripal Compuesto

Categoría:
Antigripal

Presentación:
Cápsulas

Precio Unitario:
2

Stock Actual:
40

Ventas Diarias:
5

Fecha (dd-mm-yyyy):
02-03-2025

Guardar Registro

En esta interfaz también se valida la integridad de los datos ingresados. Por ejemplo, el sistema no permite registrar campos vacíos ni formatos incorrectos, como fechas mal escritas o cantidades no numéricas. Al presionar el botón 'Guardar Registro', el sistema no solo almacena la información en la base de datos SQLite, sino que también alerta al usuario si el stock ingresado es inferior al umbral mínimo permitido para evitar quiebres.

4.2.4. Análisis de la rotación de inventario

La interfaz avanzada permite visualizar la tasa de rotación de cada medicamento, facilitando la toma de decisiones basadas en datos. Se puede buscar un medicamento específico o generar

gráficos con los 5 productos de mayor o menor rotación, lo que permite identificar aquellos con alta demanda y los que permanecen más tiempo en stock.

Figura 8

Reporte visual de los productos con mayor rotación de inventario.



4.2.5. Predicción de stock óptimo con Machine Learning

La predicción del stock óptimo se realiza mediante un modelo de aprendizaje automático Random Forest Regressor. Este modelo fue entrenado con datos históricos de ventas, precio unitario, tiempo de reposición, variabilidad en la demanda y otros factores críticos. El sistema genera una predicción de la demanda diaria y calcula el stock de reorden recomendado, alertando al usuario en caso de riesgo de desabastecimiento.

Figura 9

Pantalla de predicción de stock con parámetros simulados.

Predicción de Stock

Ingrese los datos para la predicción

Stock Actual:
40

Tiempo de Reposición (días):
7

Ventas Promedio (últimos 7 días o 30 días):
5.63

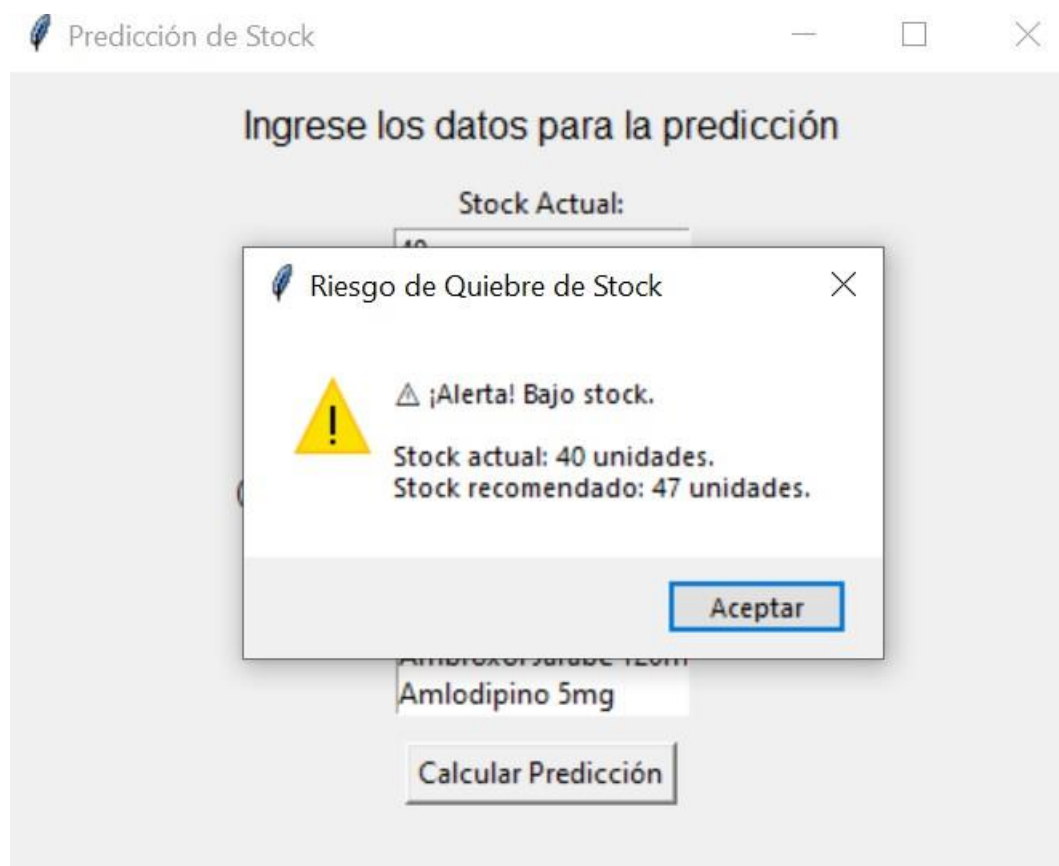
(Ejemplo: Promedio registrado en base de datos)

Afrin SP
Alcohol 70% 500ml
Alergis Gel
Ambroxol Jarabe 120m
Amlodipino 5mg

Calcular Predicción

Figura 10

Comparación gráfica entre stock actual y recomendado.



4.3 Historias de Usuario

Las historias de usuario son un componente esencial dentro de la metodología ágil SCRUM, ya que permiten traducir las necesidades del usuario en funcionalidades concretas del sistema. En el presente proyecto, estas historias han sido diseñadas con el objetivo de mejorar la eficiencia en la gestión de inventarios mediante la aplicación de algoritmos de Machine Learning. Cada historia de usuario fue formulada en base a los requerimientos del personal de atención y del responsable de inventario, asegurando que el sistema responda a los tres problemas específicos planteados en la investigación: la reducción de desabastecimientos, la mejora de la rotación de productos y la

optimización del stock. A continuación, se presenta el conjunto de historias de usuario desarrolladas, organizadas por tipo de usuario.

Tabla 18

Historias de usuario

Historia de Usuario	Como [rol]	Quiero [meta]	Para [beneficio]
HU1	Personal de botica	registrar productos, stock y ventas del día de forma simple	llevar un control actualizado del inventario diario
HU2	Administrador del sistema	visualizar la tasa de rotación de los productos	identificar medicamentos con alta o baja salida y mejorar la toma de decisiones
HU3	Administrador del sistema	recibir alertas sobre bajo stock	prevenir quiebres de inventario y actuar a tiempo
HU4	Administrador o analista	conocer el porcentaje de desabastecimiento por medicamento	medir la eficiencia del inventario y tomar medidas correctivas
HU5	Administrador del sistema	predecir las ventas diarias de un medicamento	anticipar la demanda y planificar el abastecimiento oportunamente
HU6	Administrador del sistema	calcular el nivel de stock óptimo	optimizar la reposición de productos y evitar tanto excesos como faltantes

4.3.1. Roles del Equipo SCRUM

El equipo de desarrollo estuvo conformado por dos integrantes, quienes asumieron los roles establecidos por la metodología SCRUM de manera colaborativa y adaptativa. Las funciones se distribuyeron según las necesidades de cada etapa del proyecto:

Felipe Cotrina Amado (Product Owner): Encargado de definir los requerimientos del sistema en función de los objetivos de la investigación y priorizar las funcionalidades que generen mayor valor para la gestión del inventario en el sector farmacéutico limeño.

Jahir Jesus Villacrisis Guerrero (Scrum Master): Responsable de facilitar las reuniones, remover impedimentos y asegurar el cumplimiento de las prácticas SCRUM durante cada Sprint.

Jahir Jesus Villacrisis Guerrero y Carmen Liliana Rodas Cortijo (Developers): Encargados de ejecutar las tareas de desarrollo técnico, implementación de funcionalidades, y validación del sistema en cada iteración, incluyendo la integración de algoritmos de Machine Learning, diseño de interfaces gráficas y elaboración de reportes analíticos. Cabe precisar que durante el desarrollo se utilizó Microsoft Excel como herramienta de planificación y control de avances en cada Sprint.

4.3.2. Historias de Usuario Detalladas por Sprint

HU-01: Registro de productos en inventario

Actor principal	Usuario (Personal)
Justificación	El personal necesita registrar de forma rápida y segura los productos farmacéuticos que llegan a la botica.
Objetivo funcional	Permitir el ingreso de nuevos productos en el sistema de inventario, incluyendo información como nombre del medicamento, categoría, presentación, precio unitario, stock actual, ventas diarias y fecha de registro
Resultado esperado	El sistema almacena correctamente los datos ingresados, y en caso de valores inválidos (como campos vacíos o datos no numéricos), muestra un mensaje de error para evitar registros incorrectos

HU-02: Generación de reportes de rotación de inventario

Actor principal	Administrador
Justificación	La rotación de inventario es un indicador clave para identificar qué medicamentos tienen mayor o menor salida, permitiendo decisiones estratégicas de compra y reposición.
Objetivo funcional	Permitir al administrador visualizar, a través de gráficos, la tasa de rotación de los medicamentos almacenados, con opción a ver los productos con mayor y menor rotación.
Resultado esperado	Se generan gráficos automáticos que muestran los productos con mayor rotación, menor rotación o uno seleccionado específicamente, facilitando la toma de decisiones sobre el stock.

HU-03: Generación de reportes de stockout

Actor principal	Administrador
Justificación	El stockout o quiebre de inventario representa uno de los principales problemas en la gestión farmacéutica, ya que impide cubrir la demanda de productos esenciales para los pacientes. Esta funcionalidad permite identificar qué medicamentos han presentado mayor cantidad de días con desabastecimiento a fin de tomar acciones correctivas y optimizar la disponibilidad de inventario.
Objetivo funcional	Implementar una funcionalidad que permita al administrador generar un reporte visual y numérico de los medicamentos con mayor porcentaje de stockout en un período determinado, facilitando una visión clara sobre la frecuencia y duración del desabastecimiento.
Resultado esperado	El sistema genera una tabla resumen con el total de días registrados, número de días con stockout por medicamento y su respectivo porcentaje, destacando visualmente los productos con mayor incidencia.

HU-04: Recomendación de stock óptimo

Actor principal	Administrador
Justificación	La optimización del stock permite anticiparse a los quiebres de inventario, reduciendo el desabastecimiento y garantizando la disponibilidad de productos para la atención continua de los clientes.
Objetivo funcional	Calcular y mostrar al administrador el nivel óptimo de stock (stock de reorden) en función de la demanda promedio, el tiempo de reposición y un margen de seguridad, generando una alerta si el stock actual está por debajo del nivel sugerido
Resultado esperado	El sistema mostrará un mensaje indicando si el stock actual es suficiente o si es necesario hacer un nuevo pedido. Asimismo, se mostrará un gráfico comparativo del stock actual frente al stock recomendado para facilitar la toma de decisiones.

HU-05: Visualización de productos con mayor rotación

Actor principal	Administrador
Justificación	Esta funcionalidad permite identificar rápidamente cuáles son los productos con mayor salida del inventario, facilitando decisiones informadas sobre reposiciones y control de stock.
Objetivo funcional	Mostrar un gráfico con los cinco productos que presentan la mayor tasa de rotación en el sistema, a fin de priorizar su disponibilidad y reabastecimiento oportuno.
Resultado esperado	El sistema debe desplegar un gráfico interactivo de barras que muestre los cinco medicamentos con mayor rotación según los registros históricos almacenados en la base de datos.

HU-06: Visualización de productos con menor rotación

Actor principal	Administrador
Justificación	El administrador necesita identificar los productos con baja rotación para tomar decisiones informadas sobre promociones, devoluciones o ajustes en el stock, lo cual impacta directamente en la eficiencia de la gestión de inventario.
Objetivo funcional	Permitir al administrador visualizar gráficamente los cinco medicamentos con menor rotación, facilitando así la detección de productos con baja demanda.
Resultado esperado	Se genera un gráfico de barras que muestra los cinco productos con menor rotación de inventario, destacándolos en color rojo para una rápida interpretación

4.4 Product Backlog y Descripción de Sprints

En este apartado se presenta el Product Backlog y la organización del trabajo en Sprints, conforme a la metodología SCRUM empleada en el desarrollo del sistema. El Product Backlog recoge las funcionalidades priorizadas que debían ser implementadas para atender los objetivos específicos de la investigación. A partir de este backlog, se estructuraron los Sprints necesarios para construir progresivamente el sistema, permitiendo evaluar los avances por entregables funcionales.

Tabla 19

Product Backlog

Historia de Usuario	Funcionalidad Principal	Prioridad	Objetivo Vinculado
HU1	Interfaz principal con selección de módulo	Alta	OE1, OE2, OE3
HU2	Registro diario de inventario	Alta	OE1
HU3	Visualización de tasa de rotación por producto	Media	OE2
HU4	Reporte visual de top 5 productos más y menos rotación	Media	OE2
HU5	Predicción de stock con Machine Learning	Alta	OE3
HU6	Alerta visual por riesgo de desabastecimiento	Alta	OE1

A continuación, se muestra la planificación y distribución de funcionalidades por Sprint. El equipo de desarrollo estuvo conformado por dos integrantes, quienes adoptaron los roles de Scrum Master

y Developers de manera colaborativa para garantizar el cumplimiento de los entregables de cada iteración.

Tabla 20

Planificación de Sprints

Sprint	Duración	Historias abordadas	Entregables claves
Sprint 1	1 semana	HU1, HU2	Interfaz funcional para personal con registro de productos
Sprint 2	1 semana	HU3, HU4	Reportes visuales de rotación con opción de búsqueda y gráficos
Sprint 3	1 semana	HU5, HU6	Módulo de predicción de stock con ML y alertas integradas

CAPITULO V: Conclusiones y recomendaciones

1.1 Conclusiones

Primera: La aplicación de machine learning es adaptable en cuanto a la eficiencia y la eficacia de las actividades realizadas, dicho enfoque aborda los cambios en el entorno del sector farmacéutico, lo que garantizará las reducciones de tiempo y optimización de los procesos.

Segunda: La aplicación de machine learning permitió un acceso óptimo y eficiente a la información, es decir en cuanto a la disponibilidad de los productos, esto implica la reducción de tiempo de parte de los empleados en buscar algún producto específico, la categorización de los productos mejora la gestión de la verificación de los niveles de stock. A su vez la aplicación de machine learning redujo la probabilidad de errores mejorando la precisión en cuanto a la realización de los pedidos disminuyendo los riesgos a una dispensación incorrecta de los productos farmacéuticos.

Tercera: La aplicación de machine learning influyó significativamente en mejorar el stock óptimo porque se proporcionó herramientas en sus funcionalidades que mejoraban la visibilidad de la interfaz haciéndola más fácil al utilizable, lo que a su vez facilitó la toma de decisiones contribuyendo en la optimización en los niveles de stock, los cuales serán más eficientes y rentables para la empresa.

Cuarta: La aplicación de machine learning ha tenido un efecto notorio en mejorar la eficiencia de la espera para los clientes, ya que optimiza los procesos al proporcionar información en tiempo real, esto se logra mediante la incorporación de opciones más ágiles, lo que contribuye a crear una experiencia satisfactoria tanto para los clientes como para los usuarios en la empresa.

1.2 Recomendaciones

- Primera:** Llevar a cabo una evaluación exhaustiva de los requisitos de la empresa farmacéutica, abarcando las necesidades del personal y analizando los procesos con el objetivo de mejorar la eficiencia de los flujos de trabajo ya establecidos.
- Segunda:** Brindar capacitaciones integrales al personal para que adquieran habilidades en el manejo de machine learning, asegurando así una actualización constante sobre las nuevas funcionalidades que pueda ofrecer.
- Tercera:** Se propone mejorar las funciones mediante la incorporación de alertas de agotamiento para monitorear el nivel de existencias de productos farmacéuticos, con el propósito de prevenir posibles situaciones de stock cero.

REFERENCIAS

- Shneiderman, B. (2010). *Designing the User Interface: Strategies for Effective Human-Computer Interaction*.
- Abuchar, A. (2023). *Metodologías ágiles para el desarrollo del software*. Programa Editorial de la Universidad Distrital Francisco José de Caldas.
- Acosta Faneite, S. F. (2023). Los enfoques de investigación en las Ciencias Sociales. *Revista Latinoamericana Ogmios*. <https://doi.org/10.53595/rlo.v3.i8.084>
- Aguinaga, M., & Salvador, J. (2023). Sistema inteligente basado en Machine Learning para la predicción de inundaciones en zonas agrícolas del Perú. *Repositorio de la Universidad Cesar Vallejo*.
- Álvarez, F. (2015). Implementación de nuevas tecnologías: valuación, variables, riesgos y escenarios tecnológicos. En *Ciencia-Tecnología* (Primera ed., págs. 98-99). UEF.
- Anderson, D. (2007). *An Introduction to Management Science*.
- Arrow, K., Harris, T., & Marschak, J. (1951). *Optimal inventory policy*. *Econometrica*.
- Bernaola, D., & Varillas, P. (2022). *Sistema predictivo con Machine Learning para la gestión de inventario para la Empresa Inversiones Ferreteras Mendoza S.A.C.* <https://hdl.handle.net/20.500.12692/97798>
- Bertalanffy, L. v. (1968). *Teoría general de los sistemas*. Programa Editorial Fondo de Cultura Económica.
- Bishop, C. (1995). *Neural Networks for Pattern Recognition*. Claredon Press.
- Bishop, C. (2006). *Pattern recognition and machine learning*. Springer.
- Calizaya López, J. M., Alemán Vilca, Y., Bellido Medina, R. S., & Ceballos Bejarano, F. E. (2022). *La Investigación Cuantitativa en las Ciencias Sociales* (Segunda ed.). <https://doi.org/10.47460/Autana.book.1>
- Capers, J. (2008). *Applied Software Measurement: Global Analysis of Productivity and Quality*.
- Chowdhary, C. L. (2019). Artificial Intelligence and Machine Learning: Recent advances and applications. *Recent Patents on Computer Science*, 12(1), 3-4. <https://doi.org/10.2174/221327591201190110091905>
- Coyle, J., Langley, C., Novack, R., & Gibson, B. (2021). *Supply chain management: A logistics perspective*. Cengage Learning.
- Culot, G., Podrecca, M., & Nassimbeni, G. (2024). Artificial intelligence in supply chain management: A systematic literature review of empirical studies and research directions. *Computers in Industry*, 162. <https://doi.org/10.1016/j.compind.2024.104132>

- Daumé, H., Dudik, M., Wallach, H., Holstein, K., & Wortman, J. (2019). Improving Fairness in Machine Learning Systems: What Do Industry Practitioners Need? *Association for Computing Machinery*. <https://doi.org/10.1145/3290605.3300830>
- de la Lama, P., de la Lama, M., & de la Lama, A. (2021). Los instrumentos de la investigación científica. Hacia una plataforma teórica que clarifique y gratifique. *Horizonte de la ciencia*, 12(22), 189-202. <https://doi.org/10.26490/uncp.horizonteciencia.2022.22.1078>
- Donald, C., & Koops, D. (1998). *he Essentials of MRP: A Manager's Guide to Material Requirements Planning*.
- Edge, J. (2018). *La guía definitiva de la metodología Kanban para el desarrollo de software ágil para sus proyectos*. Programa Editorial Bravex Publications.
- Em, S. (2024). Exploring Experimental Research: Methodologies, Designs, and Applications Across Disciplines. *SSRN*. <https://doi.org/10.2139/ssrn.4801767>
- Espino, C. (2021). Análisis predictivo: técnicas y modelos utilizados y aplicaciones. <https://openaccess.uoc.edu/bitstream/10609/59565/6/caresptimTFG0117mem%C3%B2ria.pdf>
- Ezugwu, A., Greeff, J., & Ho, Y.-S. (2023). A Comprehensive study of Groundbreaking Machine Learning Research: Analyzing highly cited and impactful publications across six decades. *Journal of Engineering Science and Technology*, 18(1), 1-15. <https://doi.org/10.1016/j.jer.2023.10.027>
- Fawcett, T. (2006). *An introduction to ROC analysis*.
- Fernández Cabrera, M. A. (2019). *Gestión de almacenes e inventarios en la botica FARHISA - Ferreñafe 2017 [Tesis, Universidad Señor de Sipán]*. Repositorio Universidad Señor de Sipán. <https://repositorio.uss.edu.pe/handle/20.500.12802/6419>
- Flamarique, S. (2019). *Manual de gestion de almacen*. Marge Books.
- Ford, H. (1913). *How Many Parts to Make at Once*.
- Gold, M. (1967). *Language Identification in the Limit*.
- Gonzales, A., & Perez, N. (2023). Sistema basado en Machine Learning para la mejora de gestión de inventario en A&M Confecciones, 2023. *Repositorio de la Universidad Cesar Vallejo*.
- Hamidian Fernández, B. F., & Ospino Sumoza, G. R. (2015). ¿Por qué los sistemas de información son esenciales? *Anuario del Instituto de Derecho Comparado de la Universidad de Carabobo*, 38, 161-183.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*.
- Heizer, J., & Render, B. (2007). *Operations Management*.
- Hillier, F., & Lieberman, G. (1967). *Introduction to Operations Research*.
- Huaman, J. (2022). Data mining y su influencia en la gestión de inventarios en la empresa farmacéutica InnovaPeru. *Repositorio Universidad Cesar Vallejo*.

- Hurtado Talavera, F. J. (2020). Fundamentos Metodológicos de la Investigación: El Génesis del Nuevo Conocimiento. *Revista Cientific*, 5(16), 99-119. <https://doi.org/10.29394/Scientific.issn.2542-2987.2020.5.16.5.99-119>
- Jordan, M. L., & Mitchell, T. M. (2015). Machine learning:Trends, perspectives, and prospects. *Science*(349), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kearns, M., & Vazirani, U. (1994). *An Introduction to Computational Learning Theory*.
- Krajewski, L., & Ritzman, L. (1996). *Operations Management: Processes and Supply Chains* (Primera ed.).
- Lestario, U. (2024). *Improving Inventory Management at Versuni: Machine Learning for Inventory Forecasting and Dynamic Lot Size Model*. <https://purl.utwente.nl/essays/103079>
- Mar, C., Barbosa, A., & Molar, J. (2020). *Metodología de la investigación. Métodos y técnicas*. Editorial Patria.
- Marconi, M., & Lakatos, E. (2017). *Métodos e técnicas de pesquisa*. Sao Paulo: Atlas.
- Mas Jaumot, J. (2021). *Gestión del inventario en una empresa del sector farmacéutico mediante algoritmos de Machine Learning*. <http://hdl.handle.net/10609/129826>
- Mauleón Torres, M. (2013). *Teoría del almacén*. Editorial Díaz de Santos.
- McCall, J. (1977). *Factors in Software Quality*.
- Medina, M., Rojas, R., Bustamante, W., Loaiza, R., Martel, C., & Castillo, R. (2023). *Metodología de la investigación: Técnicas e instrumentos de investigación*. Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú. <https://doi.org/10.35622/inudi.b.080>
- Michalski, R. (1983). *A Theory and Methodology of Inductive Learning*.
- Mitchell, T. (1997). *Machine Learning*. (H. McGraw, Ed.) Computer Sciences Series.
- Montes, I. (2021). *Investigación educativa: técnicas para el recojo y análisis de la información*. <https://posgrado.pucp.edu.pe/wp-content/uploads/2021/10/LIBRO-INVESTIGACION-final.pdf>
- Nahmias, S. (1989). *Production and Operations Analysis* (Primera ed.).
- Nahmias, S., & Lennon, T. (2021). *Production and Operations Analytics* (Octava ed.). Waveland Press. <https://www.waveland.com/browse.php?t=662>
- Nilesen, J. (1994). *Usability Engineering*.
- Norman, D. (2013). *The Design of Everyday Thing*.
- Ñaupas, H., Mejia, E., Novoa, E., Ramirez, E., & Villagómez, A. (2014). *Metodología de la investigación, cuantitativa- cualitativa y redacción de la tesis*. Ediciones de la U.
- Orlicky, J. (1975). *Material Requirements Planning: The New Way of Life in Production and Inventory Management*.
- Pantaleo, G. (2016). *Calidad en el desarrollo de software*. Alfaomega.

- Pareto, V. (1896). *Aunque el concepto se basa en la "Ley de Pareto", se aplica ampliamente en gestión de inventarios sin un libro específico asociado.*
- Pressman, R. (2005). *Software Engineering: A Practitioner's Approach.*
- Ramirez, J. (2022). La gestión de inventarios y su relación con la rentabilidad de una empresa de ferretería del distrito de Surco. <https://repositorio.autonoma.edu.pe/handle/20.500.13067/2144>
- Rojas, Z., Torres, G., Garavito, E., Castañeda, S., & Lopez, R. (2022). Construcción y validación de instrumentos de medición en el ámbito de la salud. Revisión de Literatura. *Revista Odontológica Pediátrica*, 21(1). <https://doi.org/10.33738/spo.v21i1.206>
- Rojo Lopez, A. M. (2022). *Investigación cuantitativa.* <https://doi.org/10.5281/zenodo.6370643>
- Salas Navarro, K., A. Meza, J., Obredor Baldovino, T., & Mercado Caruso, N. (2019). Evaluación de la cadena de suministros para mejorar la competitividad en el sector metalmecánico en Barranquilla, Colombia. *Información Tecnológica*, 30(2), 25-34.
- Sanchez, j., & Sanchez, J. (2023). Aplicación de la inteligencia artificial y su relacion con la optimizacion de la cadena logistica en almacenes de empresas farmaceuticas durante los años 2018-2021. *Repositorio de la Universidad Peruana de Ciencias Aplicadas (UPC)Academico* .
- Schapire, R. (1990). *The strength of weak learnability.*
- Schapire, R., & Freund, Y. (2012). *Boosting: Foundations and Algorithms.* MIT Press.
- Shalev, S., & Shai, B. (2014). *Understanding Machine Learning: From Theory to Algorithms.*
- Shannon, C. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Silver, E., Pyke, D., & Thomas, D. (2016). *Inventory and Production Management in Supply Chains* (Cuarta ed.). CRC Press. <https://doi.org/https://doi.org/10.1201/9781315374406>
- Sommerville, I. (2011). *Software Engineerin.*
- Spina, G. (2002). *Material Requirements Planning: Principles and Applications.*
- Stevenson, W. (1982). *Operations Management* (Primera ed.).
- Suarez, I., Varguillas, C., & Ronceros, C. (2022). *Técnicas e Instrumentos de Investigación. Diseño y Validación desde la Perspectiva Cuantitativa.* <https://doi.org/10.46498/upelipb.lib.0013>
- Taiichi, O. (1988). *Toyota Production System: Beyond Large-Scale Production.*
- Trenton, D., & Manago, B. (2022). The past, present, and future of experimental methods in the social sciences. *Social Science Research*, 108. <https://doi.org/10.1016/j.ssresearch.2022.102799>
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory.*
- Vapnik, V. (1998). *Statistical learning theory.* Wiley.

- Vasudevan, S., Raj Pulari, S., & Vasudevan, S. (2021). *Deep Learning: A comprehensive guide*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781003185635>
- Vesga, D. (2020). *Modelo de planeación de inventarios para E-commerce, utilizando herramientas de inteligencia artificial para hacer pronósticos de demanda y clasificación de inventarios*. <http://hdl.handle.net/1992/48641>
- Vidal, C. (2010). *Fundamentos de control y gestión de inventarios*. Programa Editorial Universidad del Valle.
- Vizcaíno Zúñiga, P. I., Cedeño Cedeño, R. J., & Maldonado Palacios, I. A. (2023). Metodología de la investigación científica: guía práctica. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 9723-9762. https://doi.org/10.37811/cl_rcm.v7i4.7658
- Vollmann, B., & Whybark, J. (2005). *Manufacturing Planning and Control for Supply Chain Management*.
- Wolniak, R., & Grebski, W. (2023). Functioning of predictive analytics in business. *Scientific Papers of Silesian University of Technology Organization and Management*, 175. <https://doi.org/10.29119/1641-3466.2023.175.40>
- Womack, J. (1996). *Lean Thinking*.
- Zambrano, L. (2019). : Volumen de ventas de medicamentos y el manejo de stock en laboratorios: el diseño de una predicción a través de modelos de machine learning. *Repositorio Universidad Católica*.
- Zavala, C., & Sanchez, J. (2023). Aplicación de la inteligencia artificial y su relación con la optimización de la cadena logística en almacenes de empresas farmacéuticas importadoras durante los años 2018-2021. *Repositorio de la Universidad Peruana de Ciencias Aplicadas (UPC)*.
- Zhang, H. (2004). *The Optimality of Naive Bayes*.
- Ziegler, P. (2020). *Machine learning for inventory management: Forecasting demand quantiles of perishable products with a neural network*. [Tesis de Maestría, Escuela de Negocios de la Universidad Aalto]. <https://core.ac.uk/download/363626496.pdf>

ANEXOS

Anexo 1: Matriz de Consistencia

Título de investigación: Aplicación de Machine Learning para la Eficiencia en la Gestión de Inventarios en el Sector Farmacéutico Limeño, 2024

Formulación del Problema	Objetivos	Hipótesis	Variables	Diseño metodológico
<p>Problema general: ¿Cómo puede la aplicación de Machine Learning contribuir a mejorar la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024?</p> <p>Problemas específicos: PE 1: ¿Qué impacto tiene la predicción de la demanda en la reducción de desabastecimientos en el sector farmacéutico limeño, 2024?</p> <p>PE 2: ¿Qué algoritmos de Machine Learning pueden ser implementados para mejorar la tasa de rotación en la gestión de inventarios en el sector farmacéutico limeño, 2024?</p> <p>PE3: ¿Cómo puede el Machine Learning contribuir en la optimización de los stocks a los niveles de inventario en el sector farmacéutico limeño, 2024?</p>	<p>Objetivo general: Determinar cómo Machine Learning mejora la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024.</p> <p>Objetivos específicos: OE1: Determinar el impacto de la predicción de la demanda en la reducción de desabastecimientos en el sector farmacéutico limeño, 2024.</p> <p>OE2: Determinar qué algoritmo de Machine Learning se puede implementar para mejorar la tasa de rotación en la gestión de inventarios en el sector farmacéutico limeño, 2024.</p> <p>OE 3: Determinar cómo Machine Learning mejora el stock óptimo en el sector farmacéutico limeño, 2024.</p>	<p>Hipótesis general: Hg: La aplicación de Machine Learning contribuirá a mejorar la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024 H0: La aplicación de Machine Learning No contribuirá a mejorar la eficiencia en la gestión de inventarios en el sector farmacéutico limeño, 2024</p> <p>Hipótesis específicas: HE1: La utilización de sistemas de predicción de la demanda en el sector farmacéutico limeño reduce significativamente los desabastecimientos de medicamentos al mejorar la planificación del inventario y la disponibilidad de productos.</p> <p>HE2: La implementación de algoritmos de Machine Learning mejorará significativamente la tasa de rotación de inventarios en comparación con las técnicas convencionales.</p> <p>HE3: La aplicación de Machine Learning permitirá mantener el stock óptimo, lo que resultará en una reducción del desabastecimiento y un mejor control sobre los productos próximos a vencer.</p>	<p>Variable independiente: Machine Learning.</p> <p>Dimensiones:</p> <ol style="list-style-type: none"> Rendimiento. Calidad. Usabilidad. <p>Variable dependiente: Gestión de inventarios</p> <p>Dimensiones:</p> <ol style="list-style-type: none"> Predicción de demanda Tasa de rotación. Stocks óptimos. 	<p>Tipo de investigación Aplicada</p> <p>Método y diseño de investigación</p> <p>Método: Hipotético-deductivo y analítico. Diseño: Experimental Enfoque: cuantitativo Población: 1000 registros históricos</p> <p>Muestra: 278 registros</p>

Tabla 1

Operacionalización de variable independiente

Dimensiones	Definición Conceptual	Definición Operacional	Indicadores	Escala de medición	Escala valorativa (niveles o rangos)
Rendimiento	Por otro lado, (Chowdhary, 2019) destacó el desarrollo en inteligencia artificial (IA) y el aprendizaje automático (Machine Learning), destacando como estas tecnologías van transformando a las diversas industrias. Se explora los métodos actuales de IA y ML, sus aplicaciones innovadoras y las implicaciones de estos avances en áreas como la medicina, la robótica, la educación y la seguridad. Además, se analizan patentes recientes que reflejan el crecimiento en investigación y desarrollo, junto con los desafíos éticos y técnicos que acompañan la adopción de estas tecnologías avanzadas.	La investigación tiene como objetivo operacional, medir el rendimiento, la calidad y la usabilidad, esto es a través de un antes y un después, con la aplicación del Machine Learning, para ello empeará sus respectivos indicadores para conseguir la información necesaria para realizar dichas predicciones a través del empleo de sus registros	Productividad	Escala ordinal	Productividad > 0 se considera que hay una mejora significativa, en caso contrario si la Productividad es ≤ 0 se considera que hay deficiencia
Calidad			Tasa de calidad	Escala ordinal	Tasa de calidad $\geq 0,7$ se considera que existe buena calidad en caso contrario si la Tasa de calidad es $> 0,7$ se considera que no existe buena calidad.
Usabilidad			Tasa de finalización	Escala ordinal	Tasa de finalización $\leq 0,5$ se considera que la Tasa de finalización es óptima en caso contrario si la Tasa de finalización es $> 0,5$ se considera que la tasa de finalización es deficiente.

Tabla 2

Operacionalización de variable dependiente

Dimensiones	Definición Conceptual	Definición Operacional	Indicadores	Escala de medición	Escala valorativa (niveles o rangos)
Control de Stock	Según el autor Flarmaique (2018) denomina que la gestión de inventarios permite poder llevar un mejor control de los productos, desde el pedido de estos, así mismo controlar que no se dé un sobre stock o un déficit, que podría generar grandes pérdidas para la empresa ocasionando malestar entre los usuarios.	La investigación tiene como objetivo operacional, medir el control de stock, el control de salidas y el control de inventarios, esto es a través de un antes y un después, con la aplicación del Machine Learning, para ello empeará sus respectivos indicadores para conseguir la información necesaria para realizar dichas predicciones a través del empleo de sus registros	Stock óptimo	Escala ordinal	Stock óptimo > demanda se considera que es eficiente, en caso contrario si el stock óptimo es <= demanda se considera que es deficiencia
Control de salidas		Tasa de rotación de inventarios	Escala ordinal	Tasa de rotación > 4 se considera que si hay una excelente rentabilidad en caso contrario si la Tasa de rotación es <= 4 se considera que no hay rentabilidad.	
Control de inventario		Contracción de inventario	Escala ordinal	Contracción de inventario < 0,1 se considera que hay un desvío moderado en caso contrario si la contracción de inventario es >= 0.1 se considera que hay un desvío excesivo	

Figura 11
Arbol de Problemas



Anexo 3: Validez del instrumento**CARTA DE PRESENTACIÓN**

Magíster/Doctor: CORDOVA FORERO JULIO ALFREDO

Presente

Asunto: VALIDACIÓN DE INSTRUMENTO A TRAVÉS DE JUICIO DE EXPERTO.

Es muy grato comunicarme con usted para expresarle nuestro saludo y, asimismo, hacer de su conocimiento que siendo estudiantes del programa del curso extracurricular de investigación formativa, requerimos validar los instrumentos a fin de recoger la información necesaria para desarrollar nuestra investigación, con la cual optaremos por el título profesional de Ingeniero de Sistemas e Informática.

El título nombre de nuestro proyecto de tesis es "Aplicación de Machine Learning para la Eficiencia en la Gestión de Inventarios en el Sector Farmacéutico Limeño, 2024" y, debido a que es imprescindible contar con la aprobación de docentes especializados para aplicarlos instrumentos en mención, hemos considerado conveniente recurrir a usted, ante su connotada experiencia en temas de investigación.

El expediente de validación que le hago llegar contiene:

- Carta de presentación
- Matriz de consistencia
- Matriz de operacionalización de las variables
- Certificado de validez de contenido de los instrumentos

Expresándole los sentimientos de respeto y consideración, me despido de usted, no sin antes agradecer por la atención que dispense a la presente.

Atentamente,



JAHIR JESUS VILLACRISIS GUERRERO
DNI: 75897946



CARMEN LILLIANA RODAS CORTIJO
DNI: 40470854

Validez del instrumento

Validación experto Nro. 1: Mg. Cordova Forero Julio Alfredo

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO QUE MIDE LA GESTIÓN DE INVENTARIO

Nº	DIMENSIONES / Ítems	Pertinencia ¹		Relevancia ²		Claridad ³		Sugerencias
		SI	NO	SI	NO	SI	NO	
	INDICADOR: Promedio del Stock óptimo							
1	$SO = COP + SM + SS$	X		X		X		
	INDICADOR: Tasa de rotación de inventario							
2	$TR = VRV / VPE$	X		X		X		

Observaciones (precisar si hay suficiencia): _____

Opinión de aplicabilidad: Aplicable Aplicable después de corregir No aplicable

Apellidos y nombres del juez validador: Cordova Forero, Julio DNI: 09924829

Especialidad del validador: Ingeniero en Estadística e Informática/Mg. Ing. De Sistemas

21 de noviembre del 2024

Pertinencia: El ítem corresponde al concepto teórico formulado.

Relevancia: El ítem es apropiado para representar el componente o dimensión específica del constructo.

Claridad: Se entiende sin dificultad alguna el significado del ítem, esencial, exacto y directo.



Firma del Experto Informante:

Validez del instrumento

Validación experto Nro. 1: Mg. Guadalupe Mori Victor Hugo

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO QUE MIDE LA GESTIÓN DEL INVENTARIO

Nº	DIMENSIONES / Ítems	Pertinencia1		Relevancia2		Claridad3		Sugerencias
		SI	NO	SI	NO	SI	NO	
	INDICADOR: Promedio del Stock óptimo							
1	$SO = COP + SM + SS$	x		x		x		
	INDICADOR: Tasa de rotación de inventario							
2	$TR = VRV / VPE$	x		x		x		

Observaciones (precisar si hay suficiencia): _____

Opinión de aplicabilidad: Aplicable Aplicable después de corregir No aplicable

Apellidos y nombres del juez validador: Guadalupe Mori Victor DNI: 40985024

Especialidad del validador: Ingeniero de Sistemas/Mg. Ing. De Sistemas

21 de noviembre del 2024

Pertinencia: El ítem corresponde al concepto teórico formulado.

Relevancia: El ítem es apropiado para representar al componente o dimensión específica del constructo.

Claridad: Se entiende sin dificultad alguna el significado del ítem, esencial, claro y directo.



Firma del Experto Informante:

Validez del instrumento

Validación experto Nro. 3: Mg. Rivera Echegaray Luis Alberto

CERTIFICADO DE VALIDEZ DE CONTENIDO DEL INSTRUMENTO QUE MIDE LA GESTIÓN DE INVENTARIO

Nº	DIMENSIONES / Ítem	Pertinencia ¹		Relevancia ²		Claridad ³		Sugerencias
		SI	NO	SI	NO	SI	NO	
	INDICADOR: Promedio del Stock óptimo							
1	$SO = COP + SM + SS$	X		X		X		
	INDICADOR: Tasa de rotación de inventario							
2	$TR = VRV / VPE$	X		X		X		

Observaciones (precisar si hay suficiencia): _____

Opinión de aplicabilidad: Aplicable Aplicable después de corregir No aplicable

Apellidos y nombres del juez validador: Rivera Echegaray Luis Alberto DNI:

22673302 Especialidad del validador: Ingeniero en Estadística e Informática/Mg.

Ing. De Sistemas

21 de noviembre del 2024

Pertinencia: El ítem corresponde al concepto técnico formulado.

Relevancia: El ítem es apropiado para representar el componente o dimensión específica del constructo.

Claridad: Se entiende sin dificultad alguna el significado del ítem, extensión, alcance y dirección.



Firma del Experto Informante

Anexo : Capturas del sistema

Figura 12

Menú principal del sistema de gestión de inventario



Figura 13

Interfaz de registro de inventario (Vista inicial)

The screenshot shows a window titled "Gestión de Inventario - Personal". The form contains the following fields and controls:

- Sede: Sede 1
- Medicamento (más vendidos): Antigripal Compuesto (dropdown menu)
- Categoría: Antigripal
- Presentación: Cápsulas
- Precio Unitario: 2
- Stock Actual: 40
- Ventas Diarias: 5
- Fecha (dd-mm-yyyy): 02-03-2025
- Guardar Registro (button)

Figura 14

Interfaz de registro con campos completados

Gestión de Inventario - Personal

Sede:
Sede 1

Medicamento (más vendidos):
Antigripal Compuesto

Categoría:
Antigripal

Presentación:
Cápsulas

Precio Unitario:
2

Stock Actual:
40

Ventas Diarias:
5

Fecha (dd-mm-yyyy):
02-03-2025

Éxito

Registro agregado correctamente.

Aceptar

Figura 15

Menú de Análisis y reportes

Menú Principal - Gestión de Inventario

Seleccione la función que desea utilizar

Reporte de Tasa de Rotación

Predicción de Stock

Figura 16

Menú inicial de reporte de tasa de rotación

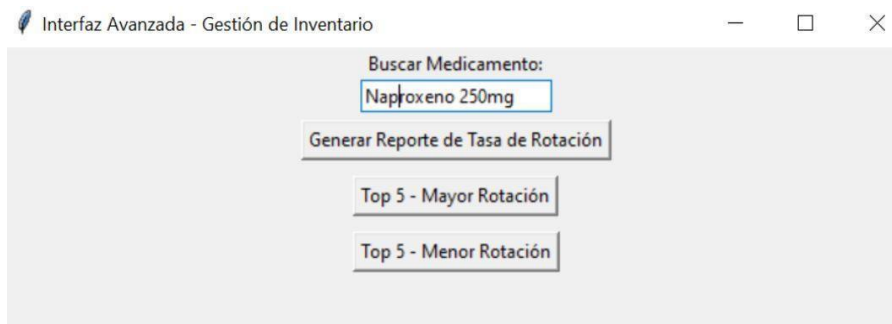


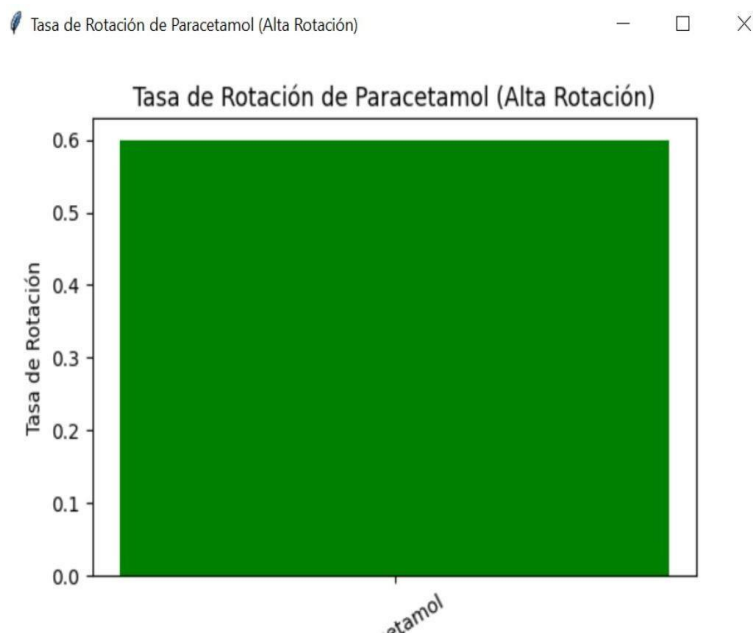
Figura 17

Reporte de medicamento para determinar tasa de rotación - baja rotación



Figura 18

Reporte de medicamento para determinar tasa de rotación - alta rotación

**Figura 19**

Reporte de Top 5 medicamentos con mayor rotación

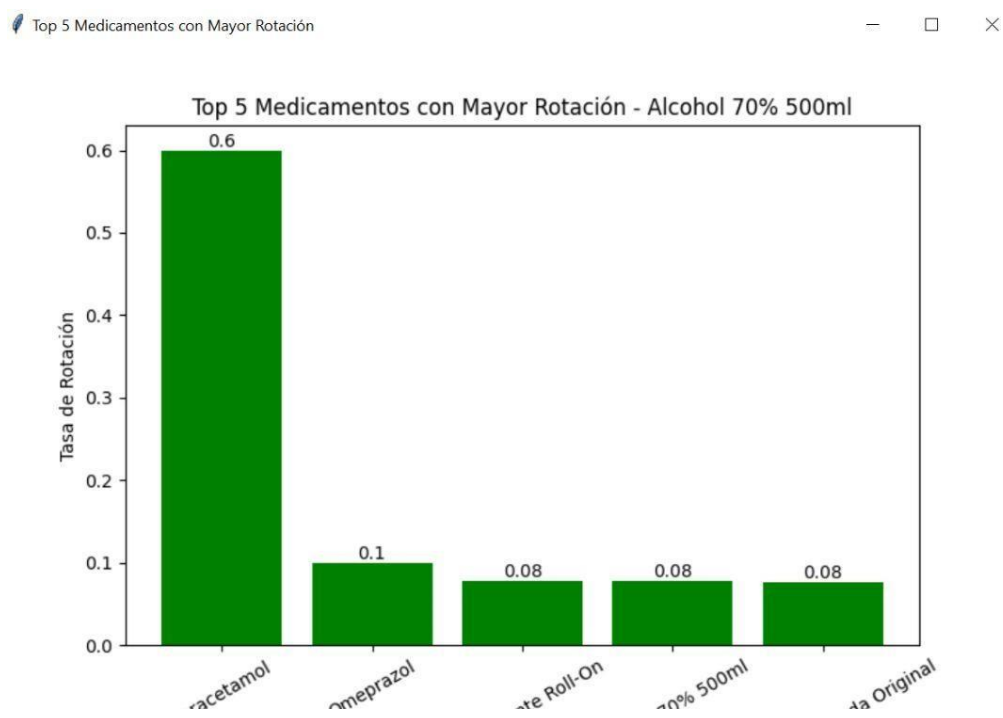
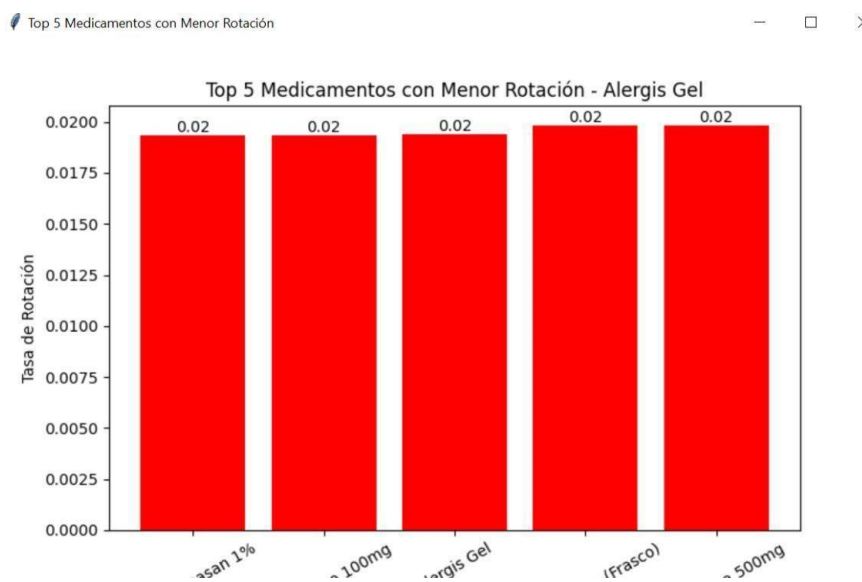


Figura 20

Reporte de Top 5 medicamentos con menor rotación

**Figura 21**

Interfaz para predicción de stock (Machine Learning)

Predicción de Stock

Ingrese los datos para la predicción

Stock Actual:

Tiempo de Reposición (días):

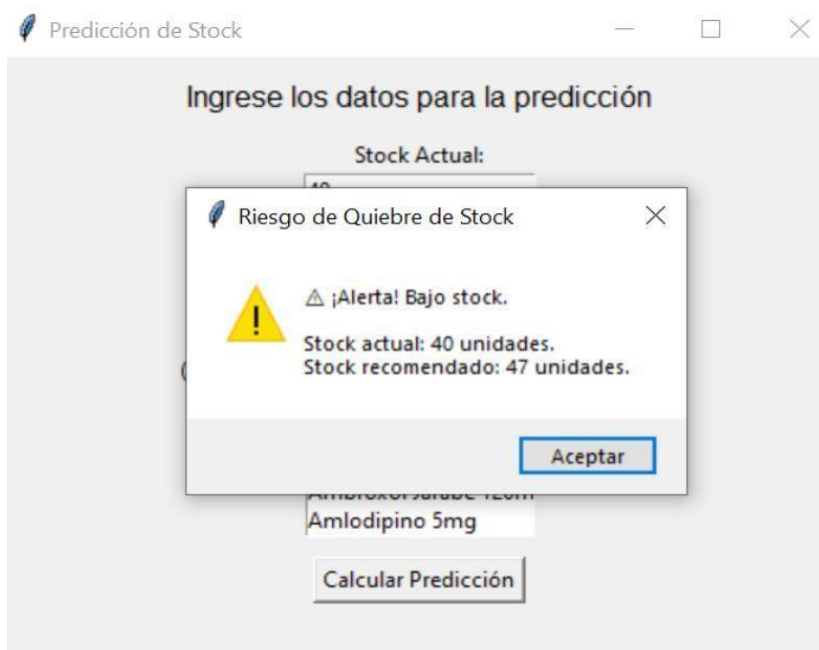
Ventas Promedio (últimos 7 días o 30 días):

(Ejemplo: Promedio registrado en base de datos)

-
-
-
-
-

Figura 22

Alerta de riesgo de quiebre de stock

**Figura 22**

Interfaz de comparación de stock actual y recomendado



Anexo 6: Reporte de similitud de turnitín

Reporte de similitud

NOMBRE DEL TRABAJO

PT_A2_(Rodas_y_Villacrisis)_V_1.12.doc
x

RECuento DE PALABRAS

25933 Words

RECuento DE CARACTERES

140560 Characters

RECuento DE PÁGINAS

126 Pages

TAMAÑO DEL ARCHIVO

1.9MB

FECHA DE ENTREGA

Jun 23, 2025 8:42 PM GMT-5

FECHA DEL INFORME

Jun 23, 2025 8:43 PM GMT-5

● 15% de similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 12% Base de datos de Internet
- Base de datos de Crossref
- 12% Base de datos de trabajos entregados
- 5% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● Excluir del Reporte de Similitud

- Material citado
- Coincidencia baja (menos de 10 palabras)

● 15% de similitud general

Principales fuentes encontradas en las siguientes bases de datos:

- 12% Base de datos de Internet
- Base de datos de Crossref
- 12% Base de datos de trabajos entregados
- 5% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

FUENTES PRINCIPALES

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	repositorio.uwiener.edu.pe Internet	2%
2	repositorio.ucv.edu.pe Internet	2%
3	hdl.handle.net Internet	<1%
4	Submitted on 1688424302212 Submitted works	<1%
5	coursehero.com Internet	<1%
6	Universidad de San Buenaventura on 2023-06-06 Submitted works	<1%
7	uwiener on 2023-11-08 Submitted works	<1%
8	Universidad Autónoma de Bucaramanga,UNAB on 2024-09-19 Submitted works	<1%