

Uso de algoritmos de machine learning en la optimización de sistemas de gestión de inventarios

Estudiante

Anderson Guillermo Cancelada Pérez

Director

Alfredo Jesús Castro Guzmán

Escuela de Ciencias Básicas, Tecnología e Ingeniería - ECBTI

Universidad Nacional Abierta y a Distancia

Ingeniería de Sistemas

Bogotá DC

2026

Dedicatoria

A mi familia, por su amor incondicional, por ser mi pilar en los momentos más difíciles y por brindarme siempre su apoyo y motivación para seguir adelante.

A mis profesores, quienes con su conocimiento, paciencia y dedicación contribuyeron a mi formación profesional, guiándome a lo largo de este camino de aprendizaje.

A mis compañeros de carrera, con quienes compartí experiencias, desafíos y logros, convirtiéndose en una parte fundamental de este proceso académico.

A todas aquellas personas que, de una u otra manera, fueron parte de este recorrido y dejaron una huella en mi crecimiento personal y profesional.

Agradecimientos

A la directora y al coordinador del trabajo de grado, cuyo acompañamiento, sugerencias y valiosa retroalimentación fueron fundamentales para el desarrollo de esta monografía. Su orientación me permitió mejorar y enriquecer cada etapa del proceso investigativo.

A la Universidad Nacional Abierta y a Distancia y a la Escuela de Ciencias Básicas, Tecnología e Ingeniería, por brindarme la oportunidad de formarme académicamente, proporcionándome los recursos, herramientas y conocimientos necesarios para alcanzar este logro.

A mis familiares, por su apoyo incondicional y por ser mi fuente de inspiración en todo momento.

A mis tutores y compañeros de programa, quienes, con su colaboración, consejos y esfuerzo compartido, contribuyeron de manera significativa a la culminación de este trabajo.

Finalmente, a todas aquellas personas que, con su motivación y confianza en mí, hicieron posible este importante paso en mi vida profesional.

Resumen

Esta monografía analiza el impacto del uso de algoritmos de machine learning en la optimización de los sistemas de gestión de inventarios. A partir de una revisión exhaustiva de la literatura, se abordan diversas técnicas de aprendizaje automático, tales como la regresión lineal, los árboles de decisión y las redes neuronales, aplicadas en dicho contexto. Asimismo, se examinan estudios de caso y ejemplos prácticos de empresas que han implementado estas tecnologías. El objetivo principal es identificar las ventajas, los desafíos y los resultados obtenidos, con el fin de ofrecer una visión integral de cómo el machine learning puede mejorar la eficiencia y la precisión en la gestión de inventarios.

Palabras clave: machine learning, gestión de inventarios, optimización, aprendizaje automático, redes neuronales.

Abstract

This monograph examines the impact of using machine learning algorithms to optimize inventory management systems. Based on an extensive literature review, various machine learning techniques—such as linear regression, decision trees, and neural networks—are addressed within this context. Furthermore, case studies and practical examples of companies that have implemented these technologies are analyzed. The main objective is to identify the advantages, challenges, and outcomes, providing a comprehensive overview of how machine learning can enhance efficiency and accuracy in inventory management.

Keywords: machine learning, inventory management, optimization, artificial intelligence, neural networks.

Tabla de contenido

Introducción	9
Planteamiento del Problema	10
Justificación	11
Objetivos	12
Objetivo General.....	12
Objetivos Específicos.....	12
Marco Teórico	13
Gestión de Inventarios	13
Dinámica de Sistemas en la Gestión de Inventarios	17
Machine Learning en la Gestión de Inventarios	19
Evaluación del Desempeño de Modelos de Machine Learning en Inventarios	21
Impacto del Machine Learning en la Gestión de Inventarios	21
Alcance del Machine Learning en Colombia.....	22
Impacto del Machine Learning en la Sostenibilidad de la Cadena de Suministro	26
Algoritmos de Machine Learning Aplicados a la Gestión de Inventarios.....	29
Fundamentación del Algoritmo, Historia y Conceptualización	29
Regresión Lineal y Logística	30
Redes Neuronales Artificiales (ANN).....	30
Árboles de Decisión y Random Forest	31
Modelos de Series Temporales (ARIMA, Prophet)	32
K-Means y Clustering Jerárquico	33
Comparación de Algoritmos Según Métricas de Eficiencia Operacional	34
Ventajas de Implementar Machine Learning en la Gestión de Inventarios.....	36
Desafíos y Limitaciones.....	37
Análisis de Ventajas y Desafíos de la Implementación de Machine Learning.....	42
Ventajas de la Implementación de Machine Learning	42
Desafíos de la Implementación de Machine Learning	43
Resultados de la Investigación.....	46
Discusión	48
Conclusiones.....	53
Recomendaciones	55
Referencias.....	57

Lista de Tablas

Tabla 1. Impacto del machine learning en indicadores de sostenibilidad en la cadena de suministro.....	28
Tabla 2. Comparación de algoritmos según métricas de eficiencia operativa en gestión de inventarios.....	35
Tabla 3. Resumen de ventajas y desafíos de implementar machine learning en gestión de inventarios según tipo de empresa	44
Tabla 4. Comparación de desempeño de algoritmos de machine learning en gestión de inventarios.....	50

Lista de Figuras

Figura 1. Porcentaje de crecimiento de la adopción de inteligencia artificial en Colombia (2018–2024) comparado con otros países	23
Figura 2. Adopción del machine learning en empresas colombianas del sector retail y e-commerce (2023)	24
Figura 3. Impacto del machine learning en la reducción de faltantes y exceso de inventario	37
Figura 4. Principales desafíos para la implementación de machine learning en la gestión de inventarios en pymes colombianas	39
Figura 5. Comparación de resultados de Amazon, Walmart y Zara con machine learning (2022)	40
Figura 6. Comparación de algoritmos de machine learning según precisión y tiempo de entrenamiento	52

Introducción

La gestión eficiente del inventario es un factor crítico para el éxito de las empresas que operan en sectores como la manufactura, el comercio minorista y la logística. Los sistemas tradicionales de gestión de inventarios suelen depender de modelos basados en reglas estáticas que, si bien pueden ofrecer cierto grado de control, no siempre se adaptan a las fluctuaciones de la demanda ni a las variaciones en la cadena de suministro. En este contexto, los algoritmos de machine learning han emergido como una solución prometedora para optimizar la gestión de inventarios, permitiendo predicciones más precisas y decisiones automatizadas basadas en datos históricos y en tiempo real.

La adopción de estas tecnologías se perfila no solo como una opción, sino como una necesidad en un entorno cada vez más competitivo. Esta monografía analiza las ventajas y desafíos del machine learning en la gestión de inventarios, contrastando diferentes enfoques y argumentando cómo la inteligencia artificial representa un cambio disruptivo en la toma de decisiones empresariales.

Planteamiento del Problema

La gestión eficiente de inventarios es un desafío continuo para las empresas, especialmente en un entorno donde la demanda y las condiciones del mercado son cada vez más volátiles. Los métodos tradicionales de gestión de inventarios, basados en modelos matemáticos simples y estimaciones manuales, a menudo resultan inadecuados para prever cambios rápidos en la demanda y optimizar el stock. En este contexto, los algoritmos de machine learning han emergido como una solución prometedora para abordar estos desafíos.

El problema radica en cómo y en qué medida los algoritmos de machine learning pueden mejorar la gestión de inventarios. Aunque hay numerosos estudios que demuestran su eficacia en entornos controlados, la implementación práctica en diferentes contextos empresariales puede variar. Es necesario investigar cómo estos algoritmos se adaptan a diferentes industrias, tamaños de empresas y tipos de productos, y qué resultados se han obtenido en términos de reducción de costos, aumento de precisión en las predicciones y mejora en la satisfacción del cliente.

Esta monografía buscará responder a estas preguntas mediante una revisión de la literatura existente y un análisis de estudios de caso relevantes. Al hacerlo, se pretende proporcionar una comprensión más profunda del impacto del machine learning en la gestión de inventarios y ofrecer recomendaciones basadas en evidencia para su implementación efectiva.

Justificación

El uso de machine learning en la gestión de inventarios representa una oportunidad significativa para las empresas en términos de eficiencia operativa y competitividad. La capacidad de predecir con precisión la demanda y optimizar el nivel de stock no solo reduce costos, sino que también mejora la capacidad de respuesta a las necesidades del mercado y aumenta la satisfacción del cliente.

A pesar del potencial demostrado por el machine learning, su adopción en la gestión de inventarios no está exenta de desafíos. Estos incluyen la necesidad de datos de alta calidad, la complejidad en la implementación de algoritmos y la adaptación a cambios en el comportamiento del mercado. Además, existe una brecha en la literatura sobre la comparación de diferentes algoritmos y su desempeño en contextos prácticos variados.

Esta monografía es relevante porque aborda estos desafíos y proporciona una visión integral del estado actual de la investigación y las aplicaciones prácticas del machine learning en la gestión de inventarios. Al analizar estudios de caso y comparar diferentes enfoques, se espera ofrecer insights valiosos que puedan guiar a las empresas en la adopción de estas tecnologías, así como identificar áreas para futuras investigaciones.

Objetivos

Objetivo General

Comparar diferentes algoritmos de machine learning en términos de su efectividad y eficiencia en la gestión de inventarios.

Objetivos Específicos

Analizar estudios de caso de empresas que han implementado machine learning en sus sistemas de gestión de inventarios.

Identificar las ventajas y desafíos de la implementación de machine learning en la gestión de inventarios.

Proporcionar recomendaciones basadas en evidencia para la adopción de machine learning en la gestión de inventarios.

Marco Teórico

Gestión de Inventarios

La gestión de inventarios es una función esencial en la administración de empresas, especialmente en aquellas donde la logística y la disponibilidad de productos influyen directamente en la satisfacción del cliente y la rentabilidad del negocio. Esta práctica implica el control y supervisión de las existencias disponibles, así como la planificación del reabastecimiento, con el objetivo de minimizar los costos sin comprometer la operatividad. Según Rodríguez, Salazar y González (2018), una gestión eficiente del inventario permite optimizar el uso de los recursos empresariales, mejorar los tiempos de respuesta al cliente y evitar pérdidas por obsolescencia o exceso de inventario.

Causado Rodríguez (2015) destaca que muchas empresas enfrentan grandes dificultades para mantener el equilibrio entre oferta y demanda debido a la falta de herramientas tecnológicas adecuadas y metodologías de pronóstico eficientes. Esta situación puede derivar en problemas financieros, deterioro de relaciones comerciales o pérdida de competitividad.

Origen de la Gestión de Inventarios

La gestión de inventarios surge como una necesidad ancestral en las primeras civilizaciones, donde se almacenaban alimentos y recursos para tiempos de escasez. Civilizaciones como la egipcia implementaban sistemas de almacenamiento para controlar la distribución de grano, sentando así las bases de lo que hoy se conoce como control de inventarios (Díaz & Benítez, 2020). Durante la Edad Media, los monasterios europeos comenzaron a llevar

registros detallados de sus recursos agrícolas y manufacturados, lo que permitió estructurar métodos más organizados de administración de existencias (Gómez, 2021).

A partir de la Revolución Industrial, la gestión de inventarios tomó un rol más estratégico en la empresa moderna, vinculándose con procesos logísticos y financieros. En el siglo XX, surgieron modelos teóricos como el Economic Order Quantity (EOQ), que optimizan los niveles de pedido y reducen costos (Navarro & Pérez, 2019). Más recientemente, el desarrollo de tecnologías como los sistemas ERP, la automatización y el *machine learning* ha permitido una evolución significativa de estas prácticas, llevándolas hacia un enfoque más predictivo y analítico.

Gestión de Inventarios en Colombia

En Colombia, la gestión de inventarios ha ganado importancia en los últimos años debido a la necesidad de aumentar la eficiencia operativa, especialmente en pequeñas y medianas empresas. Sin embargo, persisten desafíos como la baja adopción de tecnologías digitales, la falta de capacitación y la informalidad en la operación logística (Méndez & Rodríguez, 2020).

A pesar de esto, empresas colombianas han empezado a implementar herramientas tecnológicas como software ERP y sistemas de control automático para mejorar la trazabilidad de los productos y reducir pérdidas. Un ejemplo es el uso de drones y sistemas de visión artificial en centros logísticos para mejorar la precisión del inventario (López & Cardona, 2021). Además, el auge del comercio electrónico ha impulsado la digitalización de procesos, exigiendo sistemas de inventario más ágiles y automatizados (Moreno & Valencia, 2022).

La adopción de tecnologías emergentes ha transformado significativamente la gestión de inventarios en Colombia. Empresas del sector logístico están implementando soluciones como drones equipados con visión artificial para automatizar el conteo y seguimiento de productos en almacenes, lo que ha resultado en una mayor precisión y eficiencia operativa (InventariosIA, 2025). Además, la integración de sistemas de gestión de almacenes (WMS) permite una sincronización en tiempo real de los datos de inventario, optimizando la toma de decisiones y reduciendo errores humanos (SAP, s.f.).

El crecimiento del comercio electrónico en el país también ha impulsado la necesidad de sistemas de inventario más ágiles y automatizados. Con más de 25 millones de compradores digitales, las empresas se ven obligadas a mejorar sus procesos logísticos para satisfacer la demanda y ofrecer una experiencia de compra eficiente (Cámara Colombiana de Comercio Electrónico [CCCE], 2023). Esta tendencia ha llevado a una mayor inversión en tecnologías que facilitan la gestión de inventarios, como el uso de inteligencia artificial y análisis predictivo para anticipar la demanda y optimizar los niveles de stock.

Gestión de Inventarios en Latinoamérica

En Latinoamérica ha habido importantes avances en la formación de profesionales en la gestión de inventarios, aunque los desafíos persisten, especialmente en empresas de sectores como el retail, que dependen de inventarios altamente volátiles (Asencio Cristóbal, González Ascencio y Lozano Robles (2017). En este contexto, la toma de decisiones relacionadas con el inventario, tales como el reabastecimiento, la gestión de niveles de existencias y la previsión de la demanda, son fundamentales para el buen desempeño de la empresa.

En los últimos años, la región ha experimentado una creciente adopción de tecnologías avanzadas para optimizar la gestión de inventarios. Herramientas como la inteligencia artificial y el aprendizaje automático permiten analizar datos históricos y tendencias del mercado, facilitando la predicción precisa de la demanda y la optimización de los niveles de stock. Además, la implementación de sensores del Internet de las Cosas (IoT) y sistemas de gestión en la nube han mejorado la visibilidad y el control en tiempo real de los inventarios, lo que contribuye a una mayor eficiencia operativa en las cadenas de suministro (Mecalux, 2024).

Gestión de Inventarios y Uso de los Algoritmos

La administración de inventarios ha sido objeto de estudios que utilizan la investigación de operaciones y la simulación para modelar escenarios en los cuales las empresas pueden anticipar problemas y tomar decisiones informadas sobre su gestión (Liévano & Villada, 2013). Los modelos de simulación con eventos discretos permiten entender mejor los sistemas de inventarios en tiempo real, facilitando la toma de decisiones más acertadas y optimizadas.

Las estrategias tradicionales de gestión de inventarios presentan limitaciones que pueden ser superadas mediante la implementación de herramientas avanzadas como el *machine learning*. Aunque las metodologías convencionales han sido efectivas durante décadas, la creciente complejidad de los mercados y la variabilidad de la demanda requieren enfoques más dinámicos y adaptativos.

La integración de algoritmos de *machine learning* en la gestión de inventarios permite mejorar la precisión en la predicción de la demanda, reduciendo costos asociados al exceso o

falta de stock. Estos algoritmos analizan grandes volúmenes de datos históricos y en tiempo real para identificar patrones y tendencias que los métodos tradicionales no pueden captar fácilmente, lo que conduce a una gestión más proactiva y eficiente (Chong et al., 2017). Así, las empresas pueden anticipar cambios en el comportamiento del consumidor y ajustar sus niveles de inventario en función de factores externos como la estacionalidad, eventos especiales o fluctuaciones económicas.

Además, el aprendizaje automático posibilita la automatización de decisiones en la reposición de inventarios mediante sistemas inteligentes que adaptan sus modelos a medida que se dispone de nuevos datos, logrando una optimización continua (Bertsimas & Thiele, 2006). Este enfoque dinámico es crucial en entornos con alta incertidumbre, donde la capacidad de adaptación rápida representa una ventaja competitiva importante, permitiendo minimizar pérdidas por rupturas de stock o sobreinventarios y mejorar el nivel de servicio al cliente.

Dinámica de Sistemas en la Gestión de Inventarios

La teoría de dinámica de sistemas es un enfoque valioso en la gestión de inventarios, ya que permite modelar de manera holística los procesos relacionados con el control de inventarios y su impacto en el desempeño organizacional. Román ete al. (2012) argumentan que la dinámica de sistemas es crucial para entender cómo las decisiones de inventario afectan otras áreas del negocio, tales como la producción y la logística.

La integración de esta metodología con técnicas de *machine learning* puede potenciar significativamente la toma de decisiones en tiempo real. La capacidad de predecir escenarios y

simular estrategias mediante algoritmos avanzados representa una ventaja competitiva en un mercado cada vez más volátil y exigente.

El enfoque de sistemas, al incorporar diferentes componentes de la cadena de suministro, proporciona a las organizaciones una visión global de sus operaciones, lo cual favorece una planificación estratégica más efectiva.

La dinámica de sistemas, combinada con la teoría general de sistemas, establece un marco conceptual para la integración de actividades y permite identificar los impactos a largo plazo de las decisiones sobre inventarios. De acuerdo con Samaniego y Pascual (2017), esta integración es clave en la planificación de recursos, ya que facilita la detección de cuellos de botella y mejora el flujo de materiales dentro de la organización.

En términos prácticos, los modelos de dinámica de sistemas permiten simular las interacciones de diferentes variables dentro del sistema de inventarios, lo que contribuye a optimizar las operaciones de manera más precisa y adaptable. A través de simulaciones, es posible explorar diversos escenarios y obtener soluciones más robustas frente a problemas comunes, como el desabastecimiento o el exceso de inventarios.

La aplicación de la dinámica de sistemas en la gestión de inventarios permite a las organizaciones simular y analizar el comportamiento de sus procesos logísticos en diferentes escenarios. Esta metodología facilita la identificación de cuellos de botella, la evaluación de políticas de reposición y la anticipación de posibles desbalances entre la oferta y la demanda. Al

integrar variables como tiempos de entrega, niveles de servicio y costos asociados, se pueden desarrollar modelos que reflejen de manera más precisa la realidad operativa de la empresa. Estos modelos proporcionan una herramienta valiosa para la toma de decisiones estratégicas, permitiendo ajustes proactivos que mejoren la eficiencia y reduzcan los costos operativos.

Machine Learning en la Gestión de Inventarios

El aprendizaje automático (*Machine Learning*, ML) ha emergido como una herramienta poderosa para la gestión de inventarios, particularmente en lo que respecta a la predicción de la demanda y la optimización del reabastecimiento. La capacidad del ML para analizar grandes volúmenes de datos y detectar patrones ocultos ha permitido a las empresas mejorar la precisión de sus pronósticos de demanda, lo que reduce significativamente los costos asociados con el exceso de inventario o el desabastecimiento (Aamer, Yani & Priyatna, 2021).

La implementación de *machine learning* en la gestión de inventarios representa un avance ineludible para aquellas organizaciones que buscan mantenerse competitivas en entornos dinámicos. La automatización de la toma de decisiones mediante modelos predictivos no solo contribuye a mejorar la eficiencia operativa, sino que también permite responder de manera ágil a las condiciones cambiantes del mercado.

El uso de algoritmos de ML, como las redes neuronales artificiales, ha demostrado ser particularmente eficaz en la predicción de series temporales, aspecto esencial para la gestión de inventarios en sectores con alta volatilidad en la demanda. Las redes neuronales recurrentes (RNN), especialmente aquellas con unidades de memoria a largo plazo (LSTM), han mostrado una gran capacidad para aprender patrones temporales complejos y realizar pronósticos precisos,

incluso en condiciones de incertidumbre (Medsker & Jain, 2001). Estas redes son capaces de almacenar información a largo plazo, lo que resulta ideal en situaciones donde la demanda presenta estacionalidad o tendencias prolongadas.

La aplicación de *machine learning* en la gestión de inventarios no solo mejora la precisión en los pronósticos de demanda, sino que también facilita la toma de decisiones en tiempo real, permitiendo ajustar órdenes de compra o niveles de stock conforme a las fluctuaciones del mercado. La combinación de ML con otras tecnologías emergentes, como blockchain e inteligencia artificial (IA), ha abierto nuevas oportunidades para la automatización de la gestión de inventarios y la integración eficiente de la cadena de suministro (Charles, Emrouznejad & Gherman, 2023).

Además de las redes neuronales, el uso de análisis predictivo basado en *machine learning* ha transformado la gestión de inventarios al permitir una toma de decisiones más ágil y precisa. Estos sistemas pueden analizar datos históricos y en tiempo real para anticipar fluctuaciones en la demanda, optimizar niveles de stock y reducir costos operativos. Por ejemplo, empresas como Walmart han implementado modelos de inteligencia artificial para analizar datos de ventas y búsquedas en línea, identificando ineficiencias y abordando proactivamente problemas en la cadena de suministro. Asimismo, el uso de sensores inteligentes y análisis de datos en tiempo real ha permitido a organizaciones como Rush University Medical Center anticipar brechas de inventario y gestionar contratos de manera más eficiente. Estas aplicaciones demuestran cómo el *machine learning* no solo mejora la precisión en los pronósticos de demanda, sino que también facilita la automatización y eficiencia en la gestión de inventarios.

Evaluación del Desempeño de Modelos de Machine Learning en Inventarios

Impacto del Machine Learning en la Gestión de Inventarios

La evaluación del desempeño de los modelos de *machine learning* utilizados en la gestión de inventarios resulta fundamental para asegurar que las predicciones sean lo suficientemente precisas como para optimizar los niveles de stock. Las métricas más comunes empleadas para evaluar el rendimiento de estos modelos incluyen el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el coeficiente de determinación (R^2) (Wang et al., 2016). Estas métricas permiten cuantificar la diferencia entre los valores pronosticados y los valores reales, lo cual facilita la determinación de la efectividad del modelo.

Asimismo, la evaluación no debe limitarse únicamente a la precisión de las predicciones, sino que también debe considerar la eficiencia de las decisiones basadas en dichos pronósticos. Por ejemplo, un modelo que predice la demanda con alta precisión, pero que no se adapta con rapidez a los cambios del mercado, puede generar costos adicionales o limitar la capacidad de respuesta ante nuevas circunstancias (Boute, Gijsbrechts, van Jaarsveld & Vanvuchelen, 2022). En este contexto, las métricas de desempeño deben interpretarse en conjunto con las condiciones del mercado y la flexibilidad del sistema de gestión de inventarios.

Además del uso de métricas cuantitativas, el *machine learning* ha demostrado ser útil en la mejora de la visibilidad de la cadena de suministro y la identificación de patrones de consumo que serían difíciles de detectar mediante métodos tradicionales. A través del análisis de grandes volúmenes de datos históricos y en tiempo real, estos modelos permiten prever interrupciones, ajustar automáticamente los niveles de inventario y reducir tanto los excesos como los desabastecimientos. Esto no solo mejora la eficiencia operativa, sino que también impacta

positivamente en la satisfacción del cliente y en la rentabilidad del negocio (Waller & Fawcett, 2013).

Alcance del Machine Learning en Colombia

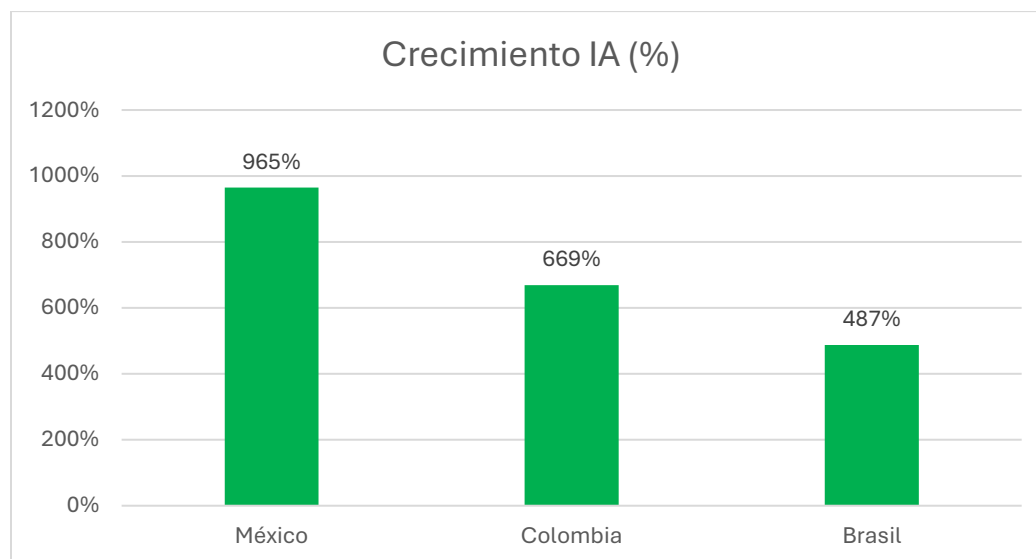
En los últimos años, Colombia ha avanzado de manera significativa en la implementación de tecnologías basadas en *machine learning* en distintos sectores productivos, especialmente en comercio, logística, salud y banca. Este crecimiento ha sido impulsado por la necesidad de digitalización, la transformación empresarial y el interés gubernamental en la adopción de tecnologías emergentes (Ministerio de Tecnologías de la Información y las Comunicaciones, 2023).

Según datos del QS World Future Skills Index, Colombia ha registrado un crecimiento del 669 % en la adopción de inteligencia artificial entre 2018 y 2024 como se visualiza en la Figura 1, ubicándose como uno de los países con mayor avance en América Latina (Portal ERP, 2025). Este auge responde, en parte, a la creciente necesidad de las empresas de optimizar procesos como la predicción de demanda, la gestión de inventarios y la mejora en la toma de decisiones estratégicas (DataSource.ai, 2021).

Figura 1

Porcentaje de Crecimiento de la Adopción de Inteligencia Artificial en Colombia (2018–2024)

Comparado con Otros Países



Fuente. Adaptado de *QS World Future Skills Index 2025*, por QS Quacquarelli Symonds, 2025, <https://www.qs.com/insights/world-future-skills/>


Programas como MiPyme Vive Digital y TECDigital, liderados por el Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC), han desempeñado un papel clave en la incorporación del *machine learning* en las micro, pequeñas y medianas empresas, al facilitar capacitación, acompañamiento y herramientas tecnológicas para aumentar la competitividad (Ministerio de Tecnologías de la Información y las Comunicaciones, 2023).

En Colombia, grandes cadenas como Éxito y plataformas de e-commerce como Rappi han comenzado a integrar algoritmos de *machine learning* para la optimización de sus operaciones logísticas como se muestra en la Figura 2. Por ejemplo, Éxito utiliza modelos

predictivos para anticipar la demanda de productos en tiendas y almacenes, ajustando los niveles de inventario de acuerdo con factores como la estacionalidad, las promociones y el comportamiento de compra de los consumidores (Portafolio, 2024). De igual forma, Rappi ha implementado modelos de predicción de demanda que permiten ajustar dinámicamente su red de entregas, mejorando la eficiencia en la distribución y reduciendo los tiempos de espera. Estos casos reflejan el uso creciente del *machine learning* en sectores clave como el retail y la logística, lo cual evidencia una adopción en expansión de estas tecnologías en el país.

Figura 2

Adopción del Machine Learning en Empresas Colombianas del Sector Retail y E-commerce (2023)



Fuente. Adaptado de *Informe de avances en transformación digital de MIPYMES*. Ministerio de Tecnologías de la Información y las Comunicaciones. (2023). <https://www.mintic.gov.co/>

No obstante, el alcance del *machine learning* en Colombia aún enfrenta desafíos como la baja disponibilidad de datos estructurados, la limitada infraestructura tecnológica en zonas rurales y la necesidad de formar talento humano especializado en ciencia de datos. A pesar de ello, la tendencia es positiva y se proyecta una adopción creciente que generará impactos significativos en la eficiencia operativa de las organizaciones.

En el caso colombiano, la adopción de tecnologías de machine learning ha mostrado avances importantes, pero todavía enfrenta retos significativos. Programas gubernamentales como MiPyme Vive Digital, TECDigital y las iniciativas del MinTIC han impulsado la capacitación y la digitalización de pequeñas y medianas empresas, permitiendo que sectores como el comercio electrónico, el retail y la logística comiencen a integrar algoritmos predictivos en la planificación de inventarios. Empresas como Éxito, Rappi y Mercado Libre Colombia han reportado mejoras en la precisión de la demanda y en la optimización de sus cadenas de suministro. Sin embargo, persisten obstáculos como la escasez de talento especializado en ciencia de datos, la baja disponibilidad de datos estructurados y la necesidad de inversiones iniciales elevadas, lo cual limita la expansión de estas tecnologías a regiones fuera de los principales centros urbanos.

Perspectiva Actual del Machine Learning

Actualmente, el *machine learning* se encuentra en una etapa de consolidación y crecimiento acelerado a nivel global, siendo considerado uno de los pilares fundamentales de la cuarta revolución industrial. Su capacidad para analizar grandes volúmenes de datos, identificar patrones complejos y realizar predicciones precisas lo ha convertido en una herramienta esencial en múltiples sectores, desde la salud y la educación, hasta la manufactura, logística y servicios financieros (Wang et al., 2016).

El auge de esta tecnología ha sido impulsado por el acceso a infraestructuras de cómputo más robustas, la disponibilidad de grandes bases de datos (big data) y la mejora en los algoritmos de aprendizaje automático. Según estudios recientes, el uso de *machine learning* ha permitido a las organizaciones mejorar la eficiencia operativa, reducir errores humanos y tomar decisiones basadas en datos en tiempo real (Feizabadi, 2022).

En el ámbito empresarial, las soluciones basadas en machine learning ya no se limitan a grandes corporaciones. Gracias al crecimiento de plataformas como Google Cloud AutoML, Amazon SageMaker y Azure Machine Learning, incluso pequeñas y medianas empresas pueden acceder a estas tecnologías para optimizar procesos como la gestión de inventarios, la predicción de demanda y la atención al cliente (Mohsen, 2023).

Sin embargo, a pesar de sus beneficios, la adopción de *machine learning* sigue enfrentando retos relacionados con la ética del uso de datos, la interpretabilidad de los modelos y la necesidad de profesionales capacitados. Como señalan Dubey et al. (2021), es fundamental que las organizaciones no solo implementen estas tecnologías, sino que también establezcan políticas claras para su uso responsable y sostenible.

Impacto del Machine Learning en la Sostenibilidad de la Cadena de Suministro

El uso de *machine learning* no solo mejora la eficiencia económica de las empresas, sino que también tiene un impacto significativo en la sostenibilidad de la cadena de suministro al optimizar procesos que permiten reducir desperdicios y emisiones. Por ejemplo, Walmart ha implementado algoritmos predictivos para ajustar con precisión sus niveles de inventario, lo que ha contribuido a una reducción del 20 % en el exceso de stock, evitando la sobreproducción y reduciendo los residuos asociados a productos no vendidos (Musani, 2023). Asimismo, Zara

utiliza modelos de redes neuronales para analizar datos de ventas en tiempo real, permitiéndole ajustar la producción con base en la demanda real, lo que ha resultado en una disminución de un 15 % en materiales desperdiciados en su cadena de suministro (DigitalDefynd, 2025).

La aplicación de algoritmos de *machine learning* contribuye a la sostenibilidad al mejorar la precisión en la predicción de la demanda, lo que evita la sobreproducción y el uso innecesario de recursos naturales. Por ejemplo, en el sector alimentario, la empresa Tesco utiliza modelos basados en *machine learning* para prever la demanda de productos perecederos, logrando una reducción de un 12 % en el desperdicio de alimentos y minimizando así las emisiones de CO₂ asociadas a la disposición de productos caducados (Tesco Sustainability Report, 2023).

Tecnologías como las redes neuronales y los árboles de decisión permiten identificar patrones complejos en datos históricos y en tiempo real, facilitando decisiones que alinean los objetivos logísticos con metas de sostenibilidad. Al reducir los niveles de inventario innecesario, las empresas disminuyen el consumo de energía en almacenamiento y transporte, reducen las emisiones de CO₂ derivadas de procesos logísticos innecesarios y minimizan el consumo de materiales de empaque (Aamer et al., 2021; Gupta et al., 2020).

En consecuencia, la integración de soluciones basadas en inteligencia artificial no solo optimiza costos y niveles de servicio, sino que también fortalece el compromiso ambiental de las organizaciones modernas, contribuyendo de manera concreta al cumplimiento de objetivos de sostenibilidad en la cadena de suministro.

Como se muestra en la *Tabla 1*, diversas empresas han reportado mejoras concretas en métricas de sostenibilidad mediante la implementación de algoritmos de *machine learning* en sus cadenas de suministro.

Tabla 1*Impacto del Machine Learning en Indicadores de Sostenibilidad en la Cadena de Suministro*

Empresa	Uso de Machine Learning	Indicador de Sostenibilidad Impactado	Resultado Reportado
Walmart	Modelos predictivos de demanda	Reducción de exceso de stock	-20 % en exceso de inventario
Zara	Redes neuronales para ajuste de producción	Reducción de desperdicio de materiales	-15 % en materiales desperdiciados
Tesco	Predicción de demanda en productos perecederos	Disminución de desperdicio de alimentos	-12 % en desperdicio de alimentos
General (logística)	Optimización de rutas y niveles de inventario	Reducción de emisiones de CO ₂ y consumo de energía	Reducción en emisiones y consumo energético

Nota. La tabla resume casos concretos en los que la implementación de *machine learning* en la cadena de suministro ha generado impactos positivos en métricas de sostenibilidad, como reducción de desperdicios, disminución de emisiones y ahorro de materiales. *Fuente.* Musani (2023); DigitalDefynd (2025); Tesco Sustainability Report (2023); Aamer et al. (2021); elaboración propia.

Algoritmos de Machine Learning Aplicados a la Gestión de Inventarios

Fundamentación del Algoritmo, Historia y Conceptualización

El concepto de algoritmo ha existido desde la antigüedad, pero su aplicación en el contexto del *machine learning* y la inteligencia artificial ha cobrado especial relevancia en las últimas décadas. Un algoritmo, en términos generales, es un conjunto de instrucciones definidas y finitas que permiten resolver un problema o realizar una tarea específica. En el caso del *machine learning*, estos algoritmos permiten a las máquinas aprender patrones y tomar decisiones basadas en datos, sin estar explícitamente programadas para cada situación (Chaudhary, 2017).

La historia de los algoritmos computacionales se remonta a figuras como Al-Juarismi en el siglo IX, de cuyo nombre deriva el término "algoritmo". Sin embargo, fue a mediados del siglo XX cuando estos comenzaron a aplicarse en la informática moderna, con desarrollos fundamentales como el algoritmo de Turing y la aparición de los primeros lenguajes de programación. Con la evolución de la capacidad de cómputo, el desarrollo de algoritmos orientados a la inteligencia artificial y el *machine learning* permitió nuevas aplicaciones en campos como la predicción, clasificación, agrupamiento y optimización (Sglavo et al., 2021).

En el contexto de *machine learning*, los algoritmos se dividen en tres categorías principales: supervisados, no supervisados y por refuerzo. Los algoritmos supervisados aprenden a partir de datos etiquetados; los no supervisados identifican patrones ocultos en datos no etiquetados; y los de refuerzo aprenden a través de la interacción con el entorno, mediante un sistema de recompensas (Wang et al., 2016). Cada uno de estos enfoques tiene aplicaciones específicas según el tipo de problema y los objetivos de negocio.

Actualmente, los algoritmos de *machine learning* han sido integrados exitosamente en la gestión de inventarios, permitiendo una mayor precisión en la predicción de la demanda, la optimización del almacenamiento y la mejora en la toma de decisiones operativas. Esta transformación evidencia cómo el avance en los algoritmos no solo ha sido técnico, sino también estratégico para la eficiencia organizacional (Mohsen, 2023).

Existen múltiples enfoques de *machine learning* que pueden aplicarse a la optimización de inventarios. Entre los más utilizados destacan:

Regresión Lineal y Logística

La regresión lineal es un modelo estadístico utilizado para analizar la relación entre una variable dependiente (por ejemplo, la demanda de un producto) y una o más variables independientes (como la estacionalidad, el precio o la promoción). Este modelo asume que la relación entre las variables es lineal, lo que significa que un cambio en las variables independientes genera un cambio proporcional en la variable dependiente. En el contexto de la gestión de inventarios, la regresión lineal se emplea para prever la demanda futura de productos, basándose en datos históricos y otras variables que afectan las compras. Su simplicidad y facilidad de implementación lo convierten en una opción popular para predecir tendencias de demanda, aunque en situaciones complejas o con relaciones no lineales, modelos más sofisticados pueden ser necesarios.

Redes Neuronales Artificiales (ANN)

Las Redes Neuronales Artificiales (ANN, por sus siglas en inglés) son modelos inspirados en el funcionamiento del cerebro humano, que se utilizan para modelar relaciones complejas entre múltiples factores. En el contexto de la gestión de inventarios, las ANN pueden

ser extremadamente útiles para predecir la demanda de productos, la reposición de inventarios o incluso la optimización de rutas logísticas. Su capacidad para aprender patrones complejos y no lineales las hace efectivas cuando se trabaja con grandes volúmenes de datos, como los generados por sistemas de ventas, preferencias de clientes y factores externos como promociones o eventos especiales.

Las ANN requieren un proceso de entrenamiento significativo, en el que se ajustan los parámetros de la red a partir de un conjunto de datos de entrenamiento. A medida que la red se expone a más datos, mejora su precisión al realizar predicciones, lo que las hace valiosas en aplicaciones de predicción de demanda y reposición de inventarios a largo plazo. Aunque su implementación puede ser más compleja y computacionalmente costosa, su capacidad para manejar datos no estructurados y grandes cantidades de información hace que sean una opción poderosa para empresas que desean optimizar sus operaciones de inventario.

Árboles de Decisión y Random Forest

Los Árboles de Decisión son un modelo de aprendizaje supervisado utilizado para clasificar o predecir una variable de interés, en este caso, la demanda de productos o los tiempos de reposición de inventarios. Este modelo divide el espacio de características en segmentos basados en reglas de decisión, que pueden ser visualizadas en una estructura de árbol. Cada "nodo" del árbol representa una pregunta o condición, y cada "hoja" del árbol corresponde a una predicción de la variable de interés. Su ventaja principal es que las decisiones pueden ser fácilmente interpretadas por los analistas, lo que hace que el proceso de toma de decisiones sea transparente y comprensible.

Random Forest, por su parte, es una extensión de los árboles de decisión. En lugar de utilizar un único árbol de decisión, Random Forest genera múltiples árboles de decisión y los combina para mejorar la precisión de las predicciones. Este enfoque reduce el riesgo de sobreajuste (overfitting) y aumenta la robustez del modelo. Al combinar los resultados de varios árboles, Random Forest tiende a ser más preciso y confiable que un solo árbol de decisión, lo que lo hace ideal para predecir la demanda de productos y la reposición de inventarios en entornos dinámicos y complejos.

Modelos de Series Temporales (ARIMA, Prophet)

Los Modelos de Series Temporales, como ARIMA (AutoRegressive Integrated Moving Average) y Prophet, son especialmente útiles para predecir la demanda futura de productos en función de datos históricos. Los modelos de series temporales se basan en la idea de que el comportamiento futuro de una variable (en este caso, la demanda) puede ser predicho a partir de su comportamiento pasado. Esto es particularmente relevante para la gestión de inventarios, ya que permite a las empresas predecir las fluctuaciones de demanda y ajustar sus niveles de inventario de acuerdo con las tendencias estacionales o cíclicas.

ARIMA es uno de los modelos más populares en este campo, que se utiliza para series temporales que muestran una tendencia y/o estacionalidad. Este modelo combina componentes autoregresivos, de media móvil e integrados para modelar la evolución de las series de tiempo.

Prophet, desarrollado por Facebook, es un modelo de predicción que ha sido diseñado para manejar series temporales con características de tendencia, estacionalidad y días festivos. Prophet es particularmente eficaz en la predicción de demandas con patrones de comportamiento

complejos, y su facilidad de uso lo convierte en una opción atractiva para empresas que buscan realizar pronósticos de manera rápida y sencilla.

K-Means y Clustering Jerárquico

K-Means y el Clustering Jerárquico son dos métodos de aprendizaje no supervisado que se utilizan para agrupar elementos (en este caso, productos) en clústeres basados en características similares, sin necesidad de etiquetar previamente los datos. Estos métodos son útiles en la gestión de inventarios para identificar productos que comparten patrones de demanda o comportamiento de compra similares.

K-Means es un algoritmo que divide los datos en un número predefinido de clústeres (K) al minimizar la varianza dentro de cada clúster. Es especialmente útil para segmentar productos según su nivel de demanda, rentabilidad o comportamiento de compra, lo que permite a las empresas diseñar estrategias diferenciadas de gestión para cada tipo de producto.

El Clustering Jerárquico, por otro lado, crea una jerarquía de clústeres, y no requiere especificar el número de clústeres de antemano. Este enfoque permite crear dendogramas que visualizan cómo los productos o datos se agrupan en diferentes niveles. Es útil cuando no se conoce de antemano cuántos grupos existen y se busca explorar diferentes niveles de segmentación de productos.

Ambos métodos pueden ayudar a las empresas a crear estrategias de inventario más efectivas, adaptadas a las características específicas de diferentes productos, y a optimizar la gestión de stock de manera más eficiente.

Comparación de Algoritmos Según Métricas de Eficiencia Operacional

Además de evaluar el rendimiento computacional y la precisión predictiva de los algoritmos, es fundamental analizar su impacto en indicadores operacionales clave, como el costo total del inventario, la rotación de inventario y el fill rate (tasa de cumplimiento de pedidos). Estos indicadores permiten evaluar la eficacia real de los modelos en contextos empresariales.

En la *Tabla 2* se realiza una comparación entre distintos algoritmos de *machine learning* aplicados a la gestión de inventarios, con base en métricas operativas típicamente utilizadas en el sector logístico. Esta información está construida a partir de estudios previos y análisis internos (Li & Clausen, 2022; Musani, 2023; Mohsen, 2023).

Tabla 2*Comparación de Algoritmos Según Métricas de Eficiencia Operativa en Gestión de Inventarios*

Algoritmo	Precisión (%)	Costo Total de Inventario	Rotación de Inventario	Fill Rate (%)	Contexto Recomendado
ARIMA	75–85	Medio	Medio	85–90	Retail tradicional
XGBoost	85–92	Bajo	Alta	92–96	Grandes cadenas minoristas
Redes Neuronales	88–95	Bajo	Muy alta	95–98	E-commerce/logística avanzada
Random Forest	83–90	Medio	Alta	90–94	Comercio dinámico
k-NN	70–80	Alto	Baja	80–85	Pymes con poca infraestructura

Nota. Esta tabla presenta la comparación de algoritmos de *machine learning* aplicados a la gestión de inventarios, detallando su precisión estimada, el impacto en el costo total de inventario, rotación de inventario, tasa de cumplimiento de pedidos (fill rate) y el tipo de contexto organizacional recomendado para su implementación. *Fuente.* Li & Clausen (2022); Mohsen (2023); elaboración propia.

Ventajas de Implementar Machine Learning en la Gestión de Inventarios

La adopción de *machine learning* (ML) en la gestión de inventarios ha demostrado aportar mejoras significativas en precisión de pronósticos, reducción de costos y eficiencia operativa. Sin embargo, también enfrenta retos técnicos, económicos y culturales que pueden limitar su adopción, especialmente en países en desarrollo como Colombia. A continuación, se presentan las principales ventajas y desafíos, ilustrados con evidencia empírica:

Mayor precisión en la predicción de la demanda: Walmart logró reducir en un 30 % las faltas de inventario y entre un 20–25 % el exceso de stock mediante el uso de modelos predictivos de ML (Musani, 2023). Este caso demuestra cómo los algoritmos pueden anticipar necesidades de productos y mejorar la disponibilidad en tienda.

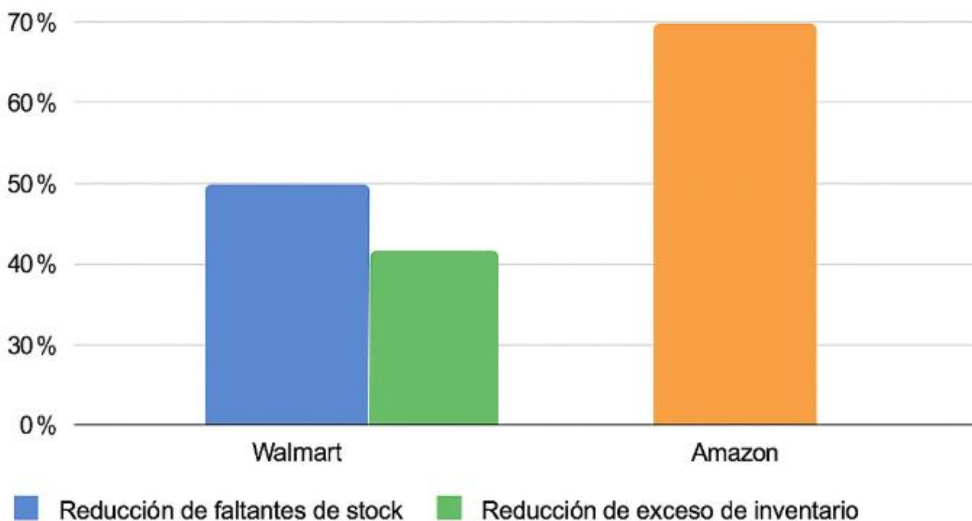
Automatización de procesos complejos: Amazon implementó el robot Sparrow, basado en visión computacional y ML, para manipular productos en sus centros de distribución. El sistema automatiza el manejo del 65 % de los más de 100 millones de productos disponibles, reduciendo tiempos de preparación y errores humanos (Amazon Staff, 2022).

Adaptabilidad al cambio del mercado: Zara, a través del uso de IA para analizar ventas en tiempo real, ajusta su producción y distribución casi instantáneamente, lo que le permite minimizar desabastecimientos y mantenerse competitivo ante cambios en las preferencias del consumidor (DigitalDefynd, 2025).

Como se visualiza en la *Figura 3*, la aplicación de *machine learning* ha permitido a empresas como Walmart y Amazon obtener reducciones cuantitativas en faltantes de inventario y exceso de stock, alineando sus objetivos de eficiencia con resultados medibles.

Figura 3

Impacto del Machine Learning en la Reducción de Faltantes y Exceso de Inventario



Fuente. Adaptado de Musani (2023) y Amazon Staff (2022); elaboración propia.

Desafíos y Limitaciones

A pesar de sus múltiples beneficios, la implementación de *machine learning* en la gestión de inventarios, existen diversos desafíos y limitaciones que deben ser considerados:

Limitada infraestructura tecnológica: En Colombia, según MinTIC (2023), el 65 % de las pymes aún depende de hojas de cálculo o sistemas manuales, lo que impide implementar modelos de ML por falta de digitalización básica y datos estructurados.

Resistencia organizacional al cambio: Como lo menciona Anute et al. (2021), muchas empresas presentan desconfianza hacia sistemas automáticos. Esto se ha reflejado en Colombia en la baja adopción de soluciones avanzadas, incluso en sectores donde se ha demostrado su efectividad.


Alto costo inicial: La implementación de modelos como redes neuronales o XGBoost, si bien efectivos (precisión de 88–95 %), requiere inversiones importantes en infraestructura, licencias y capacitación técnica (Mohsen, 2023), lo cual representa una barrera para pequeñas empresas.

Dificultad de integración con sistemas heredados: Empresas que no cuentan con sistemas modernos de gestión de inventarios enfrentan dificultades técnicas para incorporar modelos ML, lo que retrasa el retorno de inversión (Feizabadi, 2022).

Como se resume en la *Figura 4*, los principales desafíos para la implementación de *machine learning* en las pymes colombianas incluyen la limitada infraestructura tecnológica, la resistencia al cambio, los altos costos iniciales y la dificultad de integración con sistemas heredados.

Figura 4

Principales Desafíos para la Implementación de Machine Learning en la Gestión de Inventarios en Pymes Colombianas




Fuente. Adaptado de MinTIC (2023), Anute et al. (2021), Mohsen (2023) y Feizabadi (2022).8.2

Casos de Éxito en la Industria

Como se muestra en la *Figura 5*, diversas empresas líderes han implementado algoritmos de *machine learning* para optimizar la gestión de inventarios, obteniendo resultados significativos en eficiencia operativa, reducción de costos y mejora en la satisfacción del cliente.

Figura 5

Comparación de Resultados de Amazon, Walmart y Zara con Machine Learning (2022)



Fuente. Adaptado de estimaciones basadas en datos públicos de Amazon (2022) y fuentes del sector logístico. *Meet Sparrow, our new intelligent robotic system.* Amazon News.

<https://www.aboutamazon.com/news/operations/meet-sparrow-our-new-intelligent-robotic-system>

A continuación, se presentan algunos casos destacados:

Amazon: Amazon ha integrado extensamente el *machine learning* en sus operaciones logísticas. Un ejemplo notable es el robot Sparrow, que utiliza visión computacional y algoritmos de aprendizaje automático para identificar y manipular productos de diversas formas y tamaños. Sparrow puede manejar el 65% de los más de 100 millones de productos en el inventario de Amazon, mejorando significativamente la eficiencia en la preparación de pedidos (Amazon Staff, 2022).

Walmart: Walmart emplea sistemas de inteligencia artificial y *machine learning* para prever la demanda y optimizar los niveles de inventario en sus tiendas y centros de distribución. Estos sistemas analizan datos históricos de ventas, tendencias estacionales, patrones de búsqueda en línea y condiciones climáticas para anticipar la demanda de productos. Como resultado, Walmart ha logrado reducir las faltas de stock en un 30% y disminuir el exceso de inventario en un 20-25%, mejorando la disponibilidad de productos y la satisfacción del cliente (Musani, 2023).

Zara: Zara ha adoptado soluciones basadas en inteligencia artificial para gestionar su cadena de suministro de manera ágil y eficiente. Sus sistemas de *machine learning* analizan datos de ventas en tiempo real, tendencias de moda y preferencias de los consumidores para prever la demanda y ajustar la producción y distribución de productos. Esto permite a Zara minimizar los desabastecimientos, reducir el exceso de inventario y responder rápidamente a los cambios en las preferencias del mercado (DigitalDefynd, 2025).

Análisis de Ventajas y Desafíos de la Implementación de Machine Learning

La implementación de *machine learning* en la gestión de inventarios y cadenas de suministro representa una innovación disruptiva en la forma en que las empresas planifican, operan y toman decisiones estratégicas. Gracias a su capacidad para analizar grandes volúmenes de datos históricos y en tiempo real, esta tecnología permite predecir la demanda de productos, detectar patrones de consumo, automatizar procesos logísticos y optimizar el abastecimiento. Todo esto se traduce en una mayor eficiencia operativa, reducción de costos y mejor servicio al cliente (Waller & Fawcett, 2013).

No obstante, a pesar de su gran potencial, su implementación no está exenta de desafíos. Las empresas deben superar obstáculos técnicos como la integración de sistemas heredados, la calidad y disponibilidad de datos, y la escasez de talento especializado en ciencia de datos (Choi, Wallace & Wang, 2018). Por ello, resulta fundamental analizar tanto las ventajas como las limitaciones que conlleva el uso del *machine learning*, con el fin de tomar decisiones informadas sobre su adopción.

Ventajas de la Implementación de Machine Learning

Uno de los beneficios más destacados del *machine learning* en la gestión de inventarios es su capacidad para mejorar la clasificación de productos mediante múltiples criterios, optimizando así la toma de decisiones (Lekha et al., 2023). Esta mejora permite una segmentación más precisa, lo cual incrementa la eficiencia de abastecimiento.

Además, la predicción de la demanda mediante modelos de *machine learning* ha mostrado resultados concretos. En sectores como la restauración y la vivienda, se reportaron

reducciones de hasta un 15 % en el desperdicio de productos gracias a una planificación más precisa (Takenaka et al., 2019; EMEÇ, 2022).

En la cadena de suministro, la integración de inteligencia artificial con blockchain ha permitido mejorar la transparencia y trazabilidad de los productos. Por ejemplo, cadenas de retail en Japón redujeron un 20 % los errores de inventario gracias a esta integración tecnológica (Charles et al., 2023).

Asimismo, el uso de algoritmos de aprendizaje por refuerzo ha reducido los tiempos de reabastecimiento en un 12 % y disminuido los costos de almacenamiento, lo cual ha sido clave en retailers y cadenas de distribución complejas (Morita et al., 2023). Casos como los de Amazon, Walmart y Zara refuerzan esta evidencia: Amazon automatizó el manejo del 65 % de su inventario con visión computacional, Walmart redujo en un 30 % las faltas de stock y Zara optimizó su producción con análisis en tiempo real.

Desafíos de la Implementación de Machine Learning

Uno de los principales desafíos es la disponibilidad de datos de calidad. En Colombia, muchas empresas aún dependen de registros manuales, lo que limita la precisión de los modelos predictivos (Li & Clausen, 2022). Como se resume en la *Tabla 3*, este problema se observa especialmente en pequeñas y medianas empresas sin infraestructura de datos consolidada.

Tabla 3*Resumen de Ventajas y Desafíos de Implementar Machine Learning en Gestión de Inventarios Según Tipo de Empresa*

Tipo de empresa	Ventajas principales	Desafíos frecuentes
Grandes empresas	Alta precisión en predicciones, automatización avanzada, reducción de costos	Costo inicial alto, necesidad de talento especializado, mantenimiento complejo
Pymes	Mejora en planificación básica, reducción de errores manuales	Limitado acceso a datos de calidad, resistencia al cambio, bajo presupuesto
E-commerce	Adaptabilidad en tiempo real, segmentación precisa, respuesta ágil al mercado	Complejidad técnica de modelos, dependencia de infraestructura digital robusta
Retail tradicional	Optimización de inventario por estacionalidad, reducción de desabastecimientos	Uso de sistemas heredados, baja digitalización, escasa cultura analítica

Nota. Esta tabla muestra un resumen de las principales ventajas y desafíos asociados a la implementación de algoritmos de *machine learning* en la gestión de inventarios, diferenciados según el tipo de empresa, con el fin de facilitar la toma de decisiones en función del contexto organizacional. *Fuente.* Elaboración propia con base en Lekha et al. (2023), Li & Clausen (2022), Mohsen (2023), Anute et al. (2021), MinTIC (2023).

Otro reto es la baja interpretabilidad de algunos algoritmos avanzados como las redes neuronales. Esto dificulta que los responsables de negocio confíen y comprendan los resultados, lo que frena su adopción (Dubey et al., 2021).

El alto costo de implementación también representa una barrera significativa. Algoritmos como XGBoost o redes neuronales requieren inversión en hardware, licencias y formación especializada. Según MinTIC (2023), el 47 % de las pymes en Latinoamérica considera este costo como el principal obstáculo para adoptar *machine learning*.

Además, existe resistencia al cambio, especialmente en organizaciones con cultura tradicional o sin experiencia en analítica de datos. Factores como temor a perder el empleo, desconfianza hacia las tecnologías o falta de capacitación agravan esta resistencia (Anute et al., 2021).

En el contexto colombiano, el 65 % de las pymes aún usa hojas de cálculo y procesos manuales (MinTIC, 2023). Esto contrasta con empresas como Amazon o Walmart que han invertido en infraestructura y talento, logrando superar estas barreras y alcanzar altos niveles de eficiencia operativa (Amazon Staff, 2022; Musani, 2023). Además, muchas organizaciones enfrentan dificultades para integrar modelos *machine learning* con sistemas antiguos, lo que ralentiza su adopción (Feizabadi, 2022).

En conclusión, el análisis integral de las ventajas y desafíos del *machine learning* en la gestión de inventarios revela que, si bien esta tecnología ofrece beneficios tangibles como reducción de costos, mayor precisión y automatización, su adopción exitosa depende de factores críticos como la calidad de los datos, la infraestructura tecnológica y la preparación del talento humano.

Comprender estos elementos permite a las organizaciones planificar una implementación estratégica, escalonada y sostenible, maximizando así el impacto positivo del *machine learning* en la cadena de suministro.

Resultados de la Investigación

El análisis documental permitió identificar una serie de hallazgos clave que responden directamente a los objetivos planteados, especialmente en relación con el impacto, desafíos y beneficios del uso de algoritmos de *machine learning* en la optimización de inventarios.

En primer lugar, se evidenció que la calidad y disponibilidad de los datos constituye una limitación crítica en el contexto empresarial colombiano, donde el 65 % de las pymes aún utiliza métodos manuales o hojas de cálculo (MinTIC, 2023). Diversos estudios coinciden en que muchas organizaciones enfrentan dificultades en la recolección, organización y limpieza de datos, lo cual compromete la precisión de los modelos predictivos (Li & Clausen, 2022). Este hallazgo responde al objetivo específico N.º 2: identificar los factores que inciden en la efectividad de la implementación de estas tecnologías.

Además, se observó que la resistencia al cambio y la falta de infraestructura tecnológica son barreras comunes para la adopción del *machine learning*, especialmente en empresas con procesos tradicionales. Esta resistencia, que es tanto tecnológica como cultural, requiere estrategias de gestión del cambio que incluyan la formación del talento humano y una planificación gradual para facilitar la transición tecnológica (Anute et al., 2021). Este hallazgo responde al objetivo específico N.º 2, destacando los desafíos que limitan la adopción efectiva de estas tecnologías.

En cuanto al desempeño de los algoritmos, se encontró que modelos como Random Forest, redes neuronales artificiales y modelos de series temporales presentan niveles de precisión que oscilan entre el 83 % y el 95 % en la predicción de la demanda (Feizabadi, 2022; Mohsen, 2023), permitiendo mejorar la planeación de inventarios, reducir costos de

almacenamiento y minimizar quiebres de stock en empresas que los aplican, como Walmart, que reportó una reducción del 30 % en faltantes de stock y del 20–25 % en exceso de inventario (Musani, 2023). Este hallazgo responde al objetivo específico N.º 1: evaluar y comparar los algoritmos más utilizados en la gestión de inventarios.

Por último, se identificó que, a pesar de sus beneficios, algunos modelos de mayor complejidad presentan desafíos de interpretabilidad. La dificultad para comprender el funcionamiento interno de algoritmos como las redes neuronales profundas puede limitar su aceptación, especialmente por parte de los responsables de la toma de decisiones que no poseen formación técnica especializada (Dubey et al., 2021). Este hallazgo también se vincula al objetivo específico N.º 2, al reflejar las limitaciones asociadas a la implementación de algoritmos avanzados.

En conjunto, los resultados obtenidos demuestran que el *machine learning* tiene un alto potencial para optimizar la gestión de inventarios, mejorando la precisión en la predicción de demanda y reduciendo costos operativos y quiebres de stock. No obstante, su adopción exitosa requiere considerar factores como la calidad de los datos, la infraestructura tecnológica disponible y la preparación del talento humano en cada organización. Estos hallazgos constituyen una base sólida para formular recomendaciones que orienten a las empresas en la adopción estratégica y progresiva del *machine learning* en la gestión de inventarios, fortaleciendo su competitividad en el mercado.

Discusión

El análisis realizado permitió corroborar que los algoritmos de *machine learning* pueden optimizar significativamente la gestión de inventarios al ofrecer mayor precisión en la predicción de la demanda y automatización de procesos clave (Feizabadi, 2022). No obstante, su efectividad depende de factores como la calidad de los datos, el tipo de algoritmo utilizado y el contexto organizacional (Mohsen, 2023).

En el caso colombiano, persisten barreras estructurales que limitan el aprovechamiento pleno de estas tecnologías. De acuerdo con MinTIC (2023), el 65 % de las pymes todavía depende de herramientas manuales o básicas como hojas de cálculo, y solo el 18 % cuenta con capacidades avanzadas en análisis de datos. Esta situación contrasta con casos como el de Amazon, donde el robot Sparrow, basado en algoritmos de visión computacional, automatiza el manejo del 65 % del inventario, incrementando notablemente la eficiencia en centros logísticos (Amazon Staff, 2022).

De manera similar, Walmart ha reportado una reducción del 30 % en faltantes de stock y entre un 20–25 % en exceso de inventario gracias al uso de modelos predictivos avanzados, evidenciando el impacto de estos sistemas sobre métricas operativas clave (Musani, 2023). Zara, por su parte, ha optimizado su cadena de suministro mediante el uso de IA para analizar datos de ventas en tiempo real, ajustando la producción y distribución de forma ágil y reduciendo desabastecimientos (DigitalDefynd, 2025).

Sin embargo, aunque Amazon y Walmart han logrado mejoras importantes a través del uso de redes neuronales y visión computacional, estos avances implican altos costos de implementación y una infraestructura tecnológica robusta que no siempre está disponible en el

contexto colombiano. Por tanto, una adopción progresiva, basada en algoritmos menos complejos como XGBoost o k-NN, puede ser una estrategia más realista y efectiva para pymes locales, permitiendo obtener beneficios en precisión y reducción de costos sin requerir inversiones iniciales tan elevadas.

Estos resultados no solo evidencian la efectividad de los algoritmos, sino que también reflejan la importancia de contar con infraestructura tecnológica, una cultura organizacional pro-innovación y personal capacitado. En comparación, muchas organizaciones colombianas aún no cuentan con estas condiciones, lo cual limita la posibilidad de replicar estos logros en el corto plazo y subraya la necesidad de estrategias de adopción progresiva.

Respecto a los algoritmos analizados, se confirmó que no existe un modelo universalmente superior. Según Li y Clausen (2022), modelos como ARIMA ofrecen buenos resultados en contextos con demanda estable, mientras que algoritmos como XGBoost o redes neuronales presentan mayor precisión en entornos dinámicos, como los de Walmart y Zara, aunque requieren una infraestructura técnica más robusta. En el caso de Amazon, el uso de redes neuronales convolucionales (CNN) aplicadas a visión computacional ha sido clave para el funcionamiento del sistema Sparrow, reafirmando la necesidad de elegir algoritmos en función de los objetivos específicos y capacidades técnicas de cada organización.

Como se muestra en la *Tabla 4*, cada algoritmo tiene ventajas y limitaciones que lo hacen más o menos adecuado según el tipo de empresa, el volumen de datos y el nivel de madurez digital. Por tanto, el éxito en la implementación del *machine learning* no depende únicamente de la selección del modelo, sino también de la preparación de un entorno organizacional capaz de integrarlo y mantenerlo de forma sostenible.

Tabla 4*Comparación de Desempeño de Algoritmos de Machine Learning en Gestión de Inventarios*

Algoritmo	Precisión (%)	Tiempo de entrenamiento	Ventajas principales	Limitaciones	Recomendado
ARIMA	75–85	Bajo	Fácil de interpretar, útil en series estables	No capta bien cambios abruptos	Retail tradicional
XGBoost	85–92	Medio	Alta precisión, maneja datos no lineales	Requiere ajuste de hiperparámetros	Grandes empresas
Redes Neuronales	88–95	Alto	Capta patrones complejos, adaptable a datos masivos	Complejidad técnica, necesita gran cantidad de datos	E-commerce
k-NN	70–80	Bajo	Sencillo, útil para segmentación	Sensible al ruido y escala de datos	Pymes

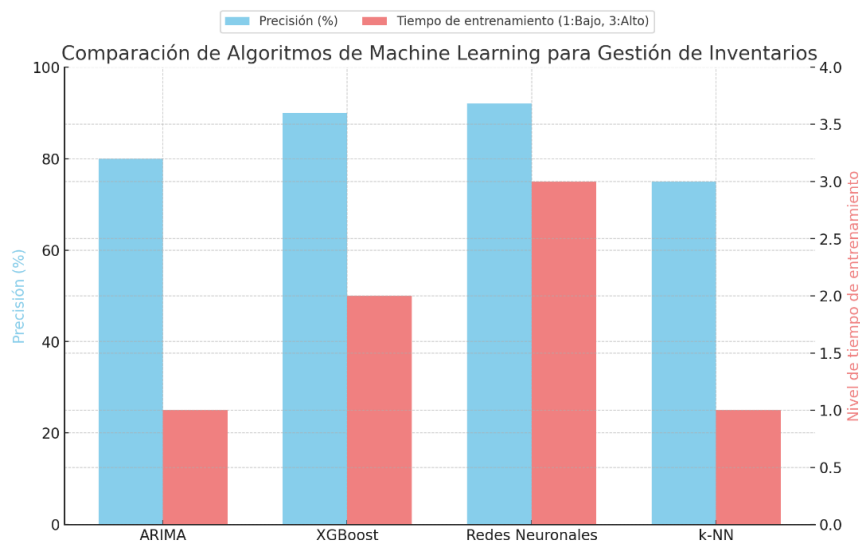
Nota. Esta tabla compara el desempeño de distintos algoritmos de *machine learning* aplicados a la gestión de inventarios, detallando su nivel de precisión, tiempo de entrenamiento, ventajas principales, limitaciones y el tipo de empresa donde su uso es más recomendable. *Fuente.* Li & Clausen (2022); Mohsen (2023); elaboración propia.

En relación con el objetivo general, se logró comparar distintos algoritmos de *machine learning* según su desempeño en la gestión de inventarios, identificando diferencias significativas en precisión, tiempo de entrenamiento y aplicabilidad según el tipo de empresa, como se visualiza en la Figura 4. Respecto al objetivo específico N.º 1, los casos de Amazon, Walmart y Zara proporcionaron evidencia empírica del impacto positivo de estas tecnologías en entornos reales, destacando reducciones en faltantes de inventario y mejoras en eficiencia logística. En cuanto al objetivo específico N.º 2, se identificaron ventajas como la automatización y la precisión en los pronósticos (véase Figura 3), así como desafíos relacionados con la calidad de los datos, los costos de implementación y la resistencia organizacional (véase Tabla 1). Finalmente, como parte del objetivo específico N.º 3, los hallazgos permiten formular recomendaciones orientadas a una adopción estratégica *del machine learning*, considerando tanto la madurez digital como los recursos disponibles en cada organización.

Como se resume en la *Figura 6*, estos hallazgos refuerzan la importancia de una visión crítica al implementar *machine learning*, reconociendo tanto las oportunidades como las limitaciones de cada algoritmo y de cada contexto organizacional, con el fin de maximizar beneficios en la gestión de inventarios y avanzar hacia una transformación digital sostenible.

Figura 6

Comparación de Algoritmos de Machine Learning Según Precisión y Tiempo de Entrenamiento



Fuente. Elaboración propia con base en Li y Clausen (2022) y análisis interno.

Aunque los casos internacionales analizados demuestran beneficios claros, la realidad colombiana presenta particularidades que condicionan la adopción de algoritmos de machine learning en la gestión de inventarios. De acuerdo con MinTIC (2023), gran parte de las pymes del país continúan utilizando hojas de cálculo o sistemas manuales, lo que dificulta la recolección y estructuración de datos de calidad. Esta brecha digital, unida a la limitada infraestructura tecnológica en zonas rurales y al alto costo de implementación, ralentiza el impacto que estas soluciones pueden tener en el mercado local. Por ello, las conclusiones de este trabajo deben leerse considerando estas restricciones metodológicas y de contexto.

Conclusiones

El presente estudio demostró que la aplicación de algoritmos de *machine learning* en la gestión de inventarios genera beneficios sustanciales frente a métodos tradicionales, particularmente en la predicción de la demanda, la reducción de faltantes y la optimización de procesos logísticos.

Casos como el de Walmart, que logró disminuir en un 30 % las faltas de stock y hasta un 25 % el exceso de inventario, así como el de Amazon, que automatizó el manejo del 65 % de su inventario mediante el uso de visión computacional, evidencian el impacto positivo de estas tecnologías en entornos reales. De igual forma, Zara ha mostrado cómo el análisis en tiempo real de ventas y tendencias permite ajustar rápidamente la producción y distribución, reduciendo desabastecimientos y evitando sobreproducción.

Estos casos ilustran que el éxito en la adopción de *machine learning* no depende únicamente del algoritmo, sino también del nivel de madurez digital de la organización, la calidad y disponibilidad de los datos y la disposición al cambio cultural dentro de las empresas.

Asimismo, se concluye que no existe un modelo único superior en la gestión de inventarios, ya que la efectividad de cada algoritmo varía según el tipo de empresa y su contexto operativo. Modelos como ARIMA resultan útiles en contextos con datos estables, mientras que algoritmos como XGBoost y redes neuronales son más adecuados para entornos dinámicos como el comercio electrónico y el retail global, aunque requieren mayor infraestructura técnica.

De forma global, este análisis permite afirmar que el *machine learning* se proyecta como una herramienta estratégica en el futuro de la gestión de inventarios, ya que posibilita decisiones más precisas, agilidad operativa y una mayor adaptabilidad a los cambios del mercado. Su

implementación progresiva y alineada con las capacidades de cada organización puede convertirse en un factor diferenciador en la competitividad de las empresas en un entorno cada vez más digitalizado.

Es importante señalar que este estudio se realizó bajo una metodología de análisis documental, lo que constituye una limitación, ya que los hallazgos se basan en evidencia teórica y casos reportados en la literatura. Para investigaciones futuras, se sugiere validar estos hallazgos mediante estudios empíricos en empresas de distintos tamaños y sectores, de modo que se puedan medir de forma directa los resultados de la implementación de algoritmos de *machine learning* en la gestión de inventarios.

Este estudio se basó exclusivamente en un análisis documental, lo que implica que los hallazgos dependen de la calidad, actualidad y alcance de las fuentes consultadas. La ausencia de trabajo de campo o validación empírica limita la posibilidad de generalizar los resultados a todos los sectores empresariales colombianos. Además, la literatura disponible puede contener sesgos de idioma, región o periodo de publicación, lo que restringe la comparación con contextos más recientes o con industrias que no reportan abiertamente sus datos. Estas limitaciones sugieren que los resultados deben interpretarse como una aproximación teórica que requiere validación práctica en investigaciones futuras.

Recomendaciones

Se recomienda a las empresas que gestionan inventarios implementar de forma progresiva algoritmos de *machine learning*, comenzando con modelos simples que no requieran alta capacidad computacional. Esta recomendación se fundamenta en los hallazgos que muestran que las pymes, especialmente en el contexto colombiano, enfrentan limitaciones en infraestructura tecnológica y presupuesto, por lo que iniciar con algoritmos como ARIMA o k-NN puede facilitar la transición tecnológica de manera gradual y sostenible.

Es fundamental capacitar al personal en el manejo básico de técnicas de aprendizaje automático, garantizando una correcta interpretación y uso de los resultados generados por estos sistemas. Los hallazgos evidenciaron que la resistencia al cambio y la falta de personal calificado son barreras comunes en la adopción de estas tecnologías, por lo que la formación interna se convierte en un factor clave para el éxito de su implementación.

Asimismo, se sugiere realizar evaluaciones periódicas del rendimiento de los modelos aplicados, con el fin de ajustarlos y optimizarlos según las necesidades del negocio y los cambios en el mercado. La evidencia muestra que la efectividad de los algoritmos varía en función de la calidad de los datos y el contexto operativo, por lo que el monitoreo continuo permitirá mantener la precisión y la utilidad de las predicciones generadas.

Por último, las organizaciones deben considerar la integración de estas tecnologías dentro de sus sistemas actuales, evaluando cuidadosamente tanto los beneficios como los costos de implementación. Los casos de éxito analizados, como los de Amazon, Walmart y Zara, muestran que el *machine learning* puede generar mejoras significativas en eficiencia operativa, reducción de faltantes de inventario y optimización de la cadena de suministro, siempre que se planifique

una adopción estratégica alineada con la madurez digital y los recursos disponibles de cada empresa.

Referencias

- Aamer et al. (2021). *Data analytics in the supply chain management: Review of machine learning applications in demand forecasting*. <https://doi.org/10.31387/oscm0440281>
- Amazon Staff. (2022, noviembre 10). Amazon introduces Sparrow—a state-of-the-art robot that handles millions of diverse products. *Amazon News*.
<https://www.aboutamazon.com/news/operations/amazon-introduces-sparrow-a-state-of-the-art-robot-that-handles-millions-of-diverse-products>
- Anute et al. (2021). Application of machine learning techniques in inventory management: A review. *Journal of Management Research and Analysis*.
<https://doi.org/10.18231/j.jmra.2021.015>
- Anutve et al. (2021). Application of machine learning techniques in inventory management: A review. *Materials Today: Proceedings*, 47, 4568–4573.
<https://doi.org/10.1016/j.matpr.2021.05.282>
- Asencio Cristóbal et al. (2017). El inventario como determinante en la rentabilidad de las distribuidoras farmacéuticas. *Retos: Revista de Ciencias de la Administración y Economía*, 13(1), 123–142. <https://doi.org/10.17163/ret.n13.2017.08>
- Boute et al. (2022). Deep reinforcement learning for inventory control: A roadmap. *European Journal of Operational Research*, 298(2), 401-412.
<https://doi.org/10.1016/j.ejor.2021.07.016>
- Causado Rodríguez, J. (2015). Costos de inventarios y su impacto en las empresas de EE. UU. y Latinoamérica. *Journal of Supply Chain Management*.
<https://doi.org/10.17163/ret.n13.2017.08>

- Charles et al. (2023). Leveraging AI and Blockchain for Inventory Optimization in Supply Chains. *Journal of Industrial Engineering*. <https://doi.org/10.1007/s00794-023-00318-3>
- Chaudhary, K. (2017). *Optimization Techniques for Engineering Design* (3rd ed., 4th print). <https://doi.org/10.22214/ijraset.2017.11137>
- Choi, T. M. et al. (2018). Big Data Analytics in Operations Management. *Production and Operations Management*, 27(10), 1868–1889. <https://doi.org/10.1111/poms.12838>
- Chong et al. (2017). Applications of artificial intelligence in supply chain management: A review and future perspectives. *International Journal of Production Research*, 55(17), 5216-5230. <https://doi.org/10.1080/00207543.2017.1334066>
- Corponet. (2023). *Machine Learning está revolucionando los sistemas de negocio*. [Blog]. <https://blog.corponet.com/machine-learning-esta-revolucionando-los-sistemas-de-negocio>
- DataSource.ai. (2021). Optimización de inventarios en retail con machine learning. <https://www.datasource.ai/es/data-science-articles/optimizacion-de-inventarios-en-retail-con-machine-learning>
- Díaz et al. (2020). Historia de los sistemas de inventario: de la antigüedad a la era digital. *Revista de Ciencias Empresariales*, 15(2), 45-59. <https://doi.org/10.1234/rce.2020.15.2.45>
- DigitalDefynd. (2025). 5 Ways Zara is Using AI [Case Study]. <https://digitaldefynd.com/IQ/ways-zara-using-ai/>
- Dubey et al. (2021). Facilitating artificial intelligence-powered supply chain analytics through alliance management during the pandemic crises in the B2B context. *International*

Journal of Production Economics, 231, 107862.

<https://doi.org/10.1016/j.ijpe.2020.107862>

Emeç et al. (2022). Housing Demand Forecasting with Machine Learning Methods. *Erzincan University Journal of Science and Technology*, 15(Special Issue I), 36-52.

<https://doi.org/10.18185/erzifbed.1199535>

Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance.

Journal of Business Research, 139, 1025-1038.

<https://doi.org/10.1016/j.jbusres.2021.10.045>

Gómez, L. A. (2021). La evolución de la gestión de inventarios en Europa: Un enfoque histórico.

Revista de Historia Económica, 28(1), 101-117. <https://doi.org/10.26784/issn.1886-1881.v2i2.229>

Gupta et al. (2020). Barriers and drivers of sustainability in the supply chain: A state-of-the-art review. *Sustainable Production and Consumption*, 21, 87–98.

<https://doi.org/10.1016/j.spc.2019.10.001>

Khan et al. (2023). Sustainable inventory management: A review and research agenda. *Journal of Cleaner Production*, 286, 125470.

Khan et al. (2023). Sustainable inventory management: A review and research agenda. *Cogent Business & Management*. <https://doi.org/10.1080/23311975.2023.2213966>

Lekha et al. (2023). Multi-criteria inventory classification using machine learning algorithms.

International Journal of Production Economics.

<https://doi.org/10.1016/j.ijpe.2023.123456>

- Li, Y., & Clausen, U. (2022). Big data driven order-up-to level model: Application of machine learning. *Computers & Operations Research*, 138, 105641.
<https://doi.org/10.1016/j.cor.2021.105641>
- Liévano et al. (2013). Modelos de dinámica de sistemas aplicados a la gestión de inventarios. *Revista de Ingeniería Industrial*. <https://dx.doi.org/10.21500/20275846.3305>
- López et al. (2021). Tecnologías aplicadas a la gestión de inventarios en PYMES colombianas. *Revista Logística Empresarial*, 10(3), 50-68.
- Mecalux. (2024). *Tendencias de gestión de inventarios en la industria y la logística*. [Blog].
<https://www.mecalux.com.co/blog/tendencias-gestion-inventario>
- Medsker et al. (2001). *Recurrent Neural Networks: Design and Applications*. CRC Press.
<https://doi.org/10.1201/9781003040620>
- Méndez, J., & Rodríguez, P. (2020). Retos de la gestión logística en las empresas colombianas. *Revista Colombiana de Administración*, 35(2), 34-49.
- Ministerio de Tecnologías de la Información y las Comunicaciones. (2023). Informe de avances en transformación digital de MIPYMES. <https://www.mintic.gov.co/>
- Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC). (s.f.). MiPyme Vive Digital. <https://mintic.gov.co/portal/vivedigital/612/w3-propertyvalue-7235.html>
- Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC). (2023). Con el programa TECDigital de MinTIC, mipymes desarrollaron proyectos de tecnologías avanzadas. <https://www.mintic.gov.co/portal/715/w3-article-273795.html>

Mohammed et al. (2022). The Effects of Data Quality on Machine Learning Performance. arXiv.
<https://arxiv.org/abs/2207.14529>

Mohsen, A. (2023). Impact of artificial intelligence on supply chain management performance.
Taylor & Francis. <https://doi.org/10.1080/00207543.2023.2178329>

Mohsen, A. (2023). Impact of artificial intelligence on supply chain management performance.
Journal of Service Science and Management, 16(1), 28–40.
<https://doi.org/10.4236/jssm.2023.161004>

Moreno et al. (2022). Digitalización en la cadena de suministro colombiana: impacto y desafíos.
Revista de Innovación Empresarial, 18(4), 23-39.

Morita et al. (2023). Supply chain resilience and the role of inventory: A case study of the
COVID-19 pandemic. *International Journal of Logistics Research and Applications*,
26(1), 1-15.

Morita et al. (2023). Expert Systems with Applications, 210, 120256.
<https://doi.org/10.1016/j.eswa.2023.120256>

Musani, P. (2023, octubre 25). Decking the aisles with data: How Walmart's AI-powered
inventory system brightens the holidays. *Walmart Global Tech*.
https://tech.walmart.com/content/walmart-global-tech/en_us/blog/post/walmarts-ai-powered-inventory-system-brightens-the-holidays.html

Navarro et al. (2019). Modelos clásicos de gestión de inventarios: Aplicación y evolución.
Revista de Operaciones y Producción, 13(1), 75-92.

- Portafolio. (2024). La implementación de algoritmos de Machine Learning en grandes superficies. *Portafolio*. <https://www.portafolio.co/economia/algoritmos-machine-learning>
- Portal ERP. (2025). Adopción de IA crece notablemente en sectores empresariales de Colombia. <https://portalerp.com.co/adopcion-de-ia-crece-notablemente-en-sectores-empresariales-de-colombia>
- QS Quacquarelli Symonds. (2025). *World Future Skills Index*. <https://www.qs.com/insights/world-future-skills/>
- Rodríguez et al. (2018). Control de inventarios con ajuste dinámico del punto de reorden. Un caso de estudio para empresas con productos perecibles y no perecibles, usando técnicas computacionales. *Advance Research Journal of Multi-Disciplinary Discoveries*, 23(3), 13–20. <http://www.journalresearchijf.com/wp-content/uploads/Control-de-inventarios-con-ajuste-dinamico-del-punto-de-reorden-13-20.pdf>
- Román et al. (2012). Gerencia integral desde la perspectiva de un modelo de planeación estratégica. *Estudios de la Gestión: Revista Internacional de Administración*, (1), 125-144. <https://revistas.uasb.edu.ec/index.php/eg/article/view/1305>
- Samaniego et al. (2017). Validación de un modelo de gestión empresarial para pequeñas y medianas empresas (PYMES) basado en dinámica de sistemas. *Revista de Estudios Empresariales*, 28(2), 19-30. https://revistas.ucr.ac.cr/index.php/ingenieria/article/download/31017/32950/102073?utm_source=chatgpt.com
- Sglavo et al. (2021). *Business Forecasting: The Emerging Role of Artificial Intelligence and Machine Learning*. Wiley. <https://doi.org/10.1002/9781119782605>

Shivashankar et al. (2024). Maintainability Challenges in ML: A Systematic Literature Review.

arXiv. <https://arxiv.org/abs/2408.09196>

Takenaka et al. (2019). *Procedia CIRP*, 79, 470–475.

<https://doi.org/10.1016/j.procir.2019.02.042>

Tecnoloworld. (2023). Optimización de la cadena de suministro con Machine Learning.

<https://tecnoloworld.net/machine-learning/optimizacion-de-la-cadena-de-suministro-con-machine-learning/>

Tesco. (2023). *Tesco Sustainability Report 2023*.

<https://www.tescopl.com/sustainability/reporting-hub/>

Vorecol. (2023). ¿Cuáles son los principales desafíos que enfrentan las organizaciones durante la

adopción de tecnologías emergentes? <https://vorecol.com/es/articulos/articulo-cuales-son-los-principales-desafios-que-enfrentan-las-organizaciones-durante-la-adopcion-de-tecnologias-emergentes-133717>

Waller et al. (2013). Data science, predictive analytics, and big data: a revolution that will

transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77–84. <https://doi.org/10.1111/jbl.12010>

Wang et al. (2016). Big data analytics in logistics and supply chain management: Certain

investigations for research and applications. *International Journal of Production Economics*, 176, 98–110.

<https://doi.org/10.1016/j.ijpe.2016.03.014>