

Influence of Machine Learning and Smart Warehousing in the Global Logistics Sector: A Systematic Review

Elsa Maria Jose Lizarribar Chavez, Bachiller ¹, Leydi Diana Ortiz Carbajal, Bachiller ², María del Rosario Quichca-Vilchez, Bachiller ³

¹Universidad Privada del Norte - (PE), Perú, N00280350@upn.pe

²Universidad Privada del Norte - (PE), Perú, N00283287@upn.pe

³Universidad Tecnológica del Perú UTP - (PE), Perú, Mariavilchezq@gmail.com

Abstract—This systematic review examined the influence of machine learning (ML) and smart warehousing (SW) on the global logistics sector through the analysis of literature published between 2022 and 2025, following PRISMA guidelines and the PICOC framework. A total of 40 peer-reviewed articles indexed in EBSCO, PROQUEST, REDALYC, ScienceDirect, Scopus, and Web of Science were analyzed. The findings indicate that ML enhances predictive processes such as demand forecasting and route planning, while SW transforms physical operations through automation and Internet of Things (IoT) integration. The synergy between both technologies leads to substantial improvements in operational efficiency, including cost reductions ranging from 15% to 25% and accuracy levels exceeding 99.5%. However, their implementation faces significant barriers, including high investment requirements, a shortage of specialized talent, and technological integration challenges—particularly for SMEs and in developing regions, especially in Latin America. The study concludes that the strategic adoption of ML and SW is essential for logistics digital transformation and requires approaches that balance technical capabilities with change management and the development of sustainable innovation ecosystems.

Keywords— Machine learning, smart warehousing, logistics sector, intelligent supply chain, logistics automation.

Influencia del Aprendizaje Automático y el Almacenamiento Inteligente en el Sector Logístico Global: Una Revisión Sistemática

Elsa Maria Jose Lizarribar Chavez, Bachiller ¹, Leydi Diana Ortiz Carbajal, Bachiller ², María del Rosario Quichea-Vilchez, Bachiller ³

¹Universidad Privada del Norte - (PE), N00280350@upn.pe

²Universidad Privada del Norte - (PE), N00283287@upn.pe

³Universidad Tecnológica del Perú UTP - (PE), Mariavilchezq@gmail.com

Resumen— Esta revisión sistemática analizó la influencia del machine learning (ML) y el smart warehousing (SW) en el sector logístico global, mediante el examen de literatura publicada entre 2022 y 2025, siguiendo los protocolos PRISMA y el marco PICOC. A partir de 40 artículos científicos de EBSCO, PROQUEST, REDALYC, SCIENCE DIRECT, SCOPUS y WOS, donde se identificó que ML optimiza procesos predictivos como la planificación de demanda, rutas, mientras que SW transforma la ejecución física mediante automatización e IoT. Es importante resaltar, que la sinergia entre ambas tecnologías genera mejoras sustanciales en eficiencia operativa con la reducción de costos del 15-25% y una precisión >99.5%. Cabe mencionar, ante su implementación enfrenta barreras significativas: altas inversiones, escasez de talento especializado y desafíos de integración tecnológica, especialmente en PYMEs y regiones en desarrollo, especialmente en Latinoamérica. Se concluye que la adopción estratégica de ML y SW es fundamental para la transformación digital logística, requiriendo enfoques que equilibren capacidades técnicas con gestión del cambio y desarrollo de ecosistemas de innovación viables.

Palabras claves— Machine learning, smart warehousing, sector logístico, cadena de suministro inteligente y automatización logística.

I. INTRODUCCIÓN

En el sector logístico a nivel global, hasta solo el 6% de las empresas relacionadas con transporte y almacenamiento han empleado la inteligencia artificial; a pesar de ello, el cloud computing, a partir del cual se están desarrollando los llamados almacenamientos inteligentes, está en crecimiento, avalado por el aumento de un 49% en su adopción. La brecha existente aquí pone en evidencia otro reto fundamental [1].

Aunque el machine learning está otorgando sustancia a los modelos de gestión de inventarios, a nivel global, el uso de dichas tecnologías está lejos de llegar a las empresas [2].

Por otra parte, distintos autores han mencionado el smart warehousing como un enfoque moderno de la gestión de almacenes que integra tecnologías inteligentes que permiten, en cierta medida, la automatización, optimización y evolución de

las operaciones logísticas tradicionales [4]. Al mismo tiempo, estos sistemas permiten perfeccionar la precisión del manejo de almacenes e integrar también múltiples tecnologías interconectadas y automatizadas; mejorando la agilidad, escalabilidad y viabilidad del almacenamiento, las cuales son difíciles de integrar y armonizar a la misma vez [5]. La incorporación de sensores e incluso algoritmos predictivos ha permitido a algunas empresas líderes reducir las pérdidas y maximizar la productividad [6].

La adopción de nuevas tecnologías es cada vez más necesaria para las empresas aprendiendo de ellas, pero además para saber en qué forma pueden aplicarlas para poder sobrevivir en el mercado. Sobre todo, el área logística se verá notablemente moldeada por el machine learning y el smart warehousing como estas están estableciendo un nuevo umbral de determinación de lo que es la eficiencia dentro de la logística global [6], [7]. Si el ML determina la manera de meterse a analizar considerables volúmenes de datos para pronosticar demandas y sentar las bases de lo que debería ser un routing optimizado, los smart warehousing incorporan la automatización de operaciones mediante robots y sensores de Internet dando como resultado metarredes interrelacionadas que ocasionan una reducción de errores y costes [8]. Además, este proceso conjunto, facilita la habilidad para acceder a mercados muy variables donde la velocidad y la determinación son cruciales para la competitividad [9].

A pesar de su crecimiento, todavía existen brechas en la manera de comprender de qué modo influyen estas tecnologías en la logística. De modo que se ha planteado la forma de analizar la influencia del machine learning y el smart warehousing en la logística a escala global. Así como los obstáculos que plantea, entre ellos la privacidad de los datos, la seguridad y la limitación a ciertos recursos o habilidades [10].

II. METODOLOGÍA

El diseño de la metodología fue diseñado en el marco PICOC, que ofreció una estructura sistemática para formular la pregunta de investigación y agilizar la delimitación de elementos clave que permitieron una búsqueda bibliográfica más precisa y rigurosa de las fuentes para consultar la relación entre el machine learning y el smart warehousing en la eficiencia logística.

RQ: ¿Cuál es la influencia del machine learning y el smart warehousing en la eficiencia operativa y la competitividad del sector logístico a nivel global?

TABLA I
MÉTODO PICOC

COMPONENTES		PALABRAS CLAVE
P	¿Qué nuevos retos enfrentan las cadenas de suministro, operaciones de almacenamiento y distribución en el sector logístico?	"SUPPLY CHAIN" OR "LOGISTICS OPERATIONS" OR "WAREHOUSE MANAGEMENT" OR "INVENTORY MANAGEMENT" OR "FREIGHT DISTRIBUTION"
I	¿Qué impacto tiene la aplicación e implementación de machine learning y smart warehousing en empresas del sector logístico?	"MACHINE LEARNING" OR "ML" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS" AND "SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOTICS" OR "IoT WAREHOUSE"
C	¿Qué diferencias presentan los procesos logísticos tradicionales frente a los procesos optimizados con machine learning y smart warehousing?	"TRADITIONAL LOGISTICS" OR "MANUAL PROCESSES" OR "CONVENTIONAL WAREHOUSE"
O	¿En qué nivel se podría mejorar la eficiencia operativa, optimización de procesos, reducción de costos y errores, incremento de la precisión y ventaja competitiva?	"OPERATIONAL EFFICIENCY" OR "COST REDUCTION" OR "ERROR REDUCTION" OR "ACCURACY IMPROVEMENT" OR "COMPETITIVE ADVANTAGE" OR "PRODUCTIVITY GAIN"
C	¿Cómo varía la aplicación de nuevas tecnologías en el sector logístico?	"GLOBAL LOGISTICS SECTOR" OR "INTERNATIONAL LOGISTICS OPERATIONS" OR "IMPLEMENTATION OF NEW TECHNOLOGY ACROSS COUNTRIES" OR "OPERATIONAL RISK MANAGEMENT IN LOGISTICS"

TABLA II
ECUACIÓN DE BÚSQUEDA

EBSCO
TI (("SUPPLY CHAIN" OR "LOGISTICS" OR "WAREHOUSE" OR "INVENTORY") AND ("MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS") AND ("SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOT" OR "IoT"))

PROQUEST
TI("SUPPLY CHAIN" OR "LOGISTICS" OR "WAREHOUSE" OR "INVENTORY") AND TI("MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS") AND TI("SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOT" OR "INTERNET OF THINGS"))
REDALYC
("SUPPLY CHAIN" OR "LOGÍSTICA" OR "ALMACÉN" OR "INVENTARIO") Y ("MACHINE LEARNING" OR "APRENDIZAJE AUTOMÁTICO" OR "INTELIGENCIA ARTIFICIAL") Y ("ALMACÉN INTELIGENTE" OR "SMART WAREHOUSING" OR "AUTOMATIZACIÓN DE ALMACÉN")
SCIENCE DIRECT
TITLE-ABS-KEY(("SUPPLY CHAIN" OR "LOGISTICS" OR "WAREHOUSE" OR "INVENTORY") AND ("MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS") AND ("SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOT" OR "INTERNET OF THINGS"))
SCOPUS
TITLE-ABS-KEY(("SUPPLY CHAIN" OR "LOGISTICS" OR "WAREHOUSE" OR "INVENTORY") AND ("MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS") AND ("SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOT" OR "INTERNET OF THINGS"))
WOS
TI= (("SUPPLY CHAIN" OR "LOGISTICS" OR "WAREHOUSE" OR "INVENTORY") AND ("MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE" OR "PREDICTIVE ANALYTICS") AND ("SMART WAREHOUSING" OR "INTELLIGENT WAREHOUSE" OR "AUTOMATED STORAGE" OR "WAREHOUSE ROBOT" OR "INTERNET OF THINGS"))

A. Diseño y protocolo

La revisión sistemática se llevó a cabo siguiendo los lineamientos del modelo PRISMA 2020, de manera que se permitió identificar, seleccionar y evaluar de manera estable las evidencias científicas de los estudios llevados a cabo entre 2022 y 2025; en el ámbito de la influencia del machine learning y el smart warehousing en el sector logístico. El procedimiento incluyó las etapas estandarizadas de identificación, cribado, elegibilidad e inclusión, documentadas mediante un diagrama de flujo. El protocolo estableció a priori los criterios de inclusión y exclusión, junto con una estrategia de búsqueda sistemática en seis bases de datos académicas especializadas




Fig. 1. Método PRISMA.

B. Fuentes de información y búsqueda

La búsqueda de literatura se desarrolló durante los meses de marzo y abril del año 2025 en las bases de datos académicas: Scopus, Web of Science (WOS), ScienceDirect, ProQuest, EBSCO y Redalyc. Se diseñaron ecuaciones de búsqueda para cada base de datos, utilizando operadores booleanos (AND, OR). Con el objeto de acotar los resultados de búsqueda se aplicaron filtros de forma automática y manual limitando los resultados al periodo 2022-2025 y a los idiomas inglés y español. Inicialmente, se identificaron 53 artículos a partir de las 6 bases de datos consultadas.

C. Filtro y selección

Tras la identificación, se eliminaron 3 registros duplicados mediante el gestor de referencias Mendeley y revisión manual. En esta fase se excluyeron 10 artículos: 2 por no estar dentro del rango temporal, 3 por no presentar la estructura metodológica IMRD requerida, y 5 por no desarrollar adecuadamente las variables de estudio. Posteriormente, se recuperaron y evaluaron a texto completo los 40 artículos restantes, los cuales cumplieron con todos los criterios y fueron incluidos para la extracción y síntesis de datos.

D. Criterios de elegibilidad

Los 40 estudios finalmente seleccionados fueron analizados. La extracción de información se llevó a cabo

mediante una matriz de síntesis estructurada en Microsoft Excel, donde se recogió información de forma sistemática los datos clave de cada artículo. Esta herramienta permitió organizar, comparar y sintetizar los hallazgos, identificando tendencias, beneficios, desafíos reportados y brechas en la literatura sobre la aplicación del machine learning y el smart warehousing en la optimización logística a nivel global.

III. RESULTADOS Y DISCUSIÓN

A. Año de Publicación

La distribución temporal de los 40 estudios incluidos muestra un claro predominio de publicaciones recientes, con el 62.5% de los artículos publicados entre 2024 y 2025. Esta concentración refleja la acelerada evolución e interés académico en las tecnologías de machine learning (ML) y smart warehousing (SW) dentro del sector logístico. El PICO en 2024 (16 artículos) coincide con avances significativos en algoritmos predictivos y sistemas de automatización física, mientras que para 2025 (9 artículos) indico la consolidación de estas tendencias. Esta actualidad garantiza que la revisión sintetiza el conocimiento más reciente sobre la transformación digital de la logística.




Fig. 2. Distribución de los artículos según año de publicación.

B. Bases de datos

Los artículos elegidos provienen de seis bases de datos académicos. Con 21 artículos, ProQuest aportó el mayor número de estudios y se destacó por su extensa cobertura de la literatura. ScienceDirect (5 artículos) y Scopus (6 artículos) proporcionaron estudios de gran alcance que fueron sometidos a estrictos procedimientos de revisión por pares. La selección fue completada con artículos indexados en las bases de datos de EBSCO (5 artículos), Web of Science (2 artículos) y Redalyc (1 artículo).




Fig. 3. Bases de datos de artículos.

C. Retos en el sector logístico

RQ: ¿Qué nuevos retos enfrentan las cadenas de suministro, operaciones de almacenamiento y distribución en el sector logístico?

El sector logístico a nivel mundial enfrenta desafíos de volatilidad en la demanda de requerir una resistencia extrema frente a interrupciones [1], [6], [9] y de esperas más veloces y personalizadas. Estos retos requieren que se pase de modelos logísticos rígidos, tradicionales y reactivos a ecosistemas ágiles, integrados digitalmente y con capacidad predictiva. El reto de gestionar grandes volúmenes de datos en tiempo real para tomar decisiones se considera un desafío fundamental y generalizado [13], [20].

D. Impacto

RQ: ¿Qué impacto tiene la aplicación e implementación de machine learning y smart warehousing en empresas del sector logístico?

La repercusión de estas tecnologías es transformadora y se presenta en dos niveles. El aprendizaje automático impacta la capacidad de decisión, perfeccionando notablemente los pronósticos de la demanda en un 40%, el ajuste dinámico de rutas y la administración preventiva de inventarios, lo cual se evidencia directamente en una disminución de costos y un mejoramiento del servicio [1], [7], [15]. Por otra parte, el almacenamiento inteligente afecta el almacenamiento de la capacidad de ejecución física al automatizar las tareas de embalaje, picking y almacenamiento a través del uso de robots e IoT. Esto disminuye los errores hasta en un 90 % y agiliza los procesos hasta en un 40 % [18], [27], [29]. En términos generales, estas tecnologías crean una ventaja competitiva sostenible fundamentada en la eficiencia, la precisión y la capacidad de adaptación [36], [38].

E. Diferencias

RQ: ¿Qué diferencias presentan los procesos logísticos tradicionales frente a los procesos optimizados con machine learning y smart warehousing?

Los procesos logísticos tradicionales se caracterizan por su dependencia de pronósticos manuales o simples, rutas fijas,

inventarios basados en puntos de reorden estáticos, operaciones de almacén manuales propensas a errores y una gestión esencialmente reactiva. Por el contrario, los procesos optimizados con ML y SW son predictivos, adaptativos, automáticos y proactivos, permitiendo una gestión de excepciones antes de que ocurran [4], [10], [30].

F. Mejora

RQ: ¿En qué nivel se podría mejorar muchos de los procesos logísticos luego de haber sido aplicados?

Las mejoras reportadas son cuantificables y significativas. Los estudios documentan reducciones de costos logísticos totales entre un 15-25%, incrementos en la precisión de pedidos por encima del 99.5%, y disminuciones del tiempo de ciclo de cumplimiento de pedidos en un 30-50% [12], [27], [36]. La optimización no es incremental, sino que habilita un cambio de orden en el desempeño. La ventaja competitiva ya no se basa solo en costos bajos, sino en la capacidad de ofrecer servicios más rápidos, confiables y visibles al cliente final, creando una barrera de entrada difícil de igualar para competidores con operaciones tradicionales [38], [39].




Fig. 4. Distribución de mejoras identificadas.

TABLA III
HALLAZGOS DEL ANTES Y EL DESPUES

Aspecto analizado	Procesos Logísticos Tradicionales	Procesos Optimizados con ML y SW
Planificación de la Demanda	Basada en datos históricos y juicio experto. Poca precisión.	Modelos predictivos de ML que integran múltiples variables. Alta precisión.
Gestión de Inventarios	Niveles de stock fijos (mínimo-máximo). Reactiva a rupturas.	Inventario dinámico y predictivo. Minimiza excesos y evita desabastecimientos.

Operaciones de Almacén	Manuales, basadas en papel o listas. Lentas y propensas a errores.	Automatizadas, guiadas por sistemas digitales y robots.
Gestión de rutas	Rutas fijas, basadas en experiencia. Poca adaptación a cambios.	Optimización dinámica en tiempo real. Ahorro de combustible y reducción de tiempos.
Visibilidad de la Cadena	Limitada, basada en informes históricos. Reactiva a disrupciones.	Total, en tiempo real mediante IoT y dashboards predictivos.
Resiliencia	Baja, vulnerable a disrupciones.	Alta, capaz de reconfigurarse rápidamente ante cambios.
Productividad y Desempeño	Accidentes y errores humanos afectan la eficiencia.	Disminución significativa de incidentes, aumento de productividad y compromiso laboral.

G. Aplicación

RQ: ¿Cómo varía la aplicación de nuevas tecnologías en el sector logístico?

La implementación de ML y SW muestra una notable variabilidad contextual, influenciada por elementos geográficos, económicos y organizativas. En zonas con ecosistemas de tecnologías logísticas avanzadas (Norteamérica, Europa, Este asiático) y en corporaciones de gran tamaño (3PL, comercio minorista a gran escala), la implementación es amplia y avanzada, gracias a su capacidad de inversiones iniciales significativas y tener acceso a talento especializado. En cambio, en países en vías de desarrollo y PYMES, la adopción es incipiente y se enfrenta a obstáculos importantes: ausencia de talento en ciencia de, costos de puesta en marcha, ecosistemas de soporte tecnológico y de datos e ingeniería [4], [26], [31].

Esta diferencia evidencia que, aunque la capacidad de transformación de ML y SW es global, su implementación efectiva requiere de tácticas adaptables que tengan en cuenta las competencias locales. Soluciones en la nube de bajo costo, modelos como AI-as-a-Service y programas de capacitación en habilidades digitales permiten que un mayor número de individuos accedan a estas tecnologías [33], [40].

H. Discusión integrada y limitaciones

Esta revisión confirma que el machine learning (ML) y el smart warehousing (SW) actúan como los cimientos tecnológicos clave de la logística 4.0, estableciendo un nuevo modelo operativo [8], [22]. Su efecto sinérgico más allá de la

automatización de tareas, creando un sistema en el que la inteligencia operativa, proveniente de los algoritmos de ML que hacen predicciones, se combina con una implementación física autónoma e impecable, habilitada por el software. La convergencia no solo posibilita la optimización de procesos de manera aislada, sino establecer ciclos de mejora continua y virtuosos [9], [29]. Los hallazgos muestran que esta sinergia es la que ha ocasionado las mejoras más notables en términos cuantitativos, como la disminución de errores en picking y el incremento de la rapidez con que se cumplen los pedidos.

No obstante, la revisión también revela una notable discrepancia entre el potencial teórico que se ha descrito en la literatura y su aplicación de manera equitativa en el sector logístico. Un conjunto de barreras interrelacionadas, que funcionan como filtros de adopción, es responsable de esta brecha. Las barreras más altas al principio de la inversión en infraestructura tecnológica y la falta de ingenieros de sistemas y especialistas en ciencia de datos son las más críticas, pues restringen el acceso a las pequeñas y medianas empresas (PYMES) [4], [19]. A esto se le añaden los problemas de interoperabilidad que persisten entre soluciones tecnológicas diversas y el subdesarrollo de ecosistemas digitales de apoyo en algunas áreas, sobre todo en economías emergentes [26], [41].

La literatura analizada tiene como limitación principal su perspectiva desmedida en temas técnicos y en ejemplos exitosos de grandes empresas [1], [27]. Hay una falta de investigaciones empíricas que estudien modelos para implementar estrategias más asequibles, ágiles y escalables, creados concretamente para las limitaciones y habilidades de las PYMES [31], [43]. Además, es necesario realizar más estudios que midan el retorno de inversión (ROI) a largo plazo de estas tecnologías, más allá de las métricas operativas inmediatas, y que examinen minuciosamente los efectos en el ámbito social y laboral, como la modificación de los perfiles laborales y las nuevas competencias necesarias en la fuerza laboral logística [2], [46].

Por lo tanto, los estudios futuros deberían enfocarse en tratar estos vacíos para ofrecer una guía más completa, contextualizada y justa para la digitalización del sector. Las líneas de trabajo abarcan la investigación de políticas públicas o incentivos que puedan promover una innovación tecnológica inclusiva [33], [40]; el desarrollo de marcos para la adopción por etapas; y el estudio de modelos empresariales basados en cloud computing y AI-as-a-Service para disminuir las barreras de acceso. Acelerar una transición digital que afiance una logística mundial realmente ágil, resiliente y competitiva solo es posible a través de una comprensión holística que balancee el potencial tecnológico con las condiciones económicas, organizativas y humanas.

IV. CONCLUSIONES

La implementación de smart warehousing (SW) y machine learning (ML) es un componente esencial para la digitalización del sector logístico mundial, como corroboró esta revisión sistemática. La información reunida muestra que estas

tecnologías logran un incremento significativo en la eficiencia operativa, disminuyen los costos y errores, y aumentan la precisión y resistencia de la cadena de suministro, lo cual fortalece las ventajas competitivas sostenibles.

La interacción entre ML y SW establece un ciclo virtuoso de mejora constante, que supera con creces los modelos logísticos de la vieja escuela fundamentados en procesos reactivos y manuales.

Sin embargo, existen retos importantes que restringen una adopción más justa y amplia: escasez de talento especializado, barreras de inversión elevadas, dificultades con la interoperabilidad y ecosistemas digitales deficientes, en particular en las regiones en desarrollo y en las pequeñas y medianas empresas.

Por lo tanto, la incidencia de ML y SW debe considerarse no únicamente como una mejora tecnológica progresiva, sino también como un proceso estratégico de reinversión en las operaciones que combina aspectos técnicos, humanos y organizacionales. Las políticas e investigaciones futuras deben centrarse en democratizar el acceso a estas tecnologías, utilizando marcos de gobernanza que apoyen una digitalización sostenible e inclusiva, modelos escalables y capacitación especializada. De este modo, la logística global tendrá la capacidad de fortalecerse como un sector ágil, resiliente y competitivo, listo para afrontar los retos cambiantes del futuro.

AGRADECIMIENTOS

Un gran agradecimiento a la Universidad Tecnológica del Perú quien fomenta la investigación y el impacto en la innovación. Por otro lado, a la Dra. Leidy Lucía Méndez Gutiérrez por su apoyo constante para seguir mejorando y fortaleciendo el campo de la investigación.

REFERENCIAS

- [1] OECD, OECD Digital Economy Outlook 2024 (Volume 1): Embracing the Technology Frontier. Paris, France: OECD Publishing, 2024. <https://doi.org/10.1787/a1689dc5-en>
- [2] N. L. Rane, P. Desai, J. Rane, and M. Paramesha, "Artificial intelligence, machine learning, and deep learning for sustainable and resilient supply chain and logistics management," in *Trustworthy Artificial Intelligence in Industry and Society*, Deep Science Publishing, 2024, pp. 156–184, [doi: 10.70593/978-81-981367-4-9_5](https://doi.org/10.70593/978-81-981367-4-9_5)
- [3] S. Alfayoumi, A. Elgammal, and N. El-Tazi, "Predictive machine learning approaches for supply and manufacturing processes planning in mass-customization products," *Informatics*, vol. 12, no. 1, p. 22, 2025, [doi: 10.3390/informatics12010022](https://doi.org/10.3390/informatics12010022)
- [4] J. Kembro and A. Norrman, "The transformation from manual to smart warehousing: an exploratory study with Swedish retailers," *Int. J. Logist. Manag.*, vol. 33, no. 5, pp. 107–135, 2022, [doi: 10.1108/IJLM-11-2021-0525](https://doi.org/10.1108/IJLM-11-2021-0525)
- [5] S. Ahmadi, "Optimizing data warehousing performance through machine learning algorithms in the cloud," *Int. J. Sci. Res.*, vol. 12, no. 22, pp. 1859–1867, 2023, [doi: 10.21275/SR231224074241](https://doi.org/10.21275/SR231224074241)
- [6] A. Aljohani, "Predictive analytics and machine learning for real-time supply chain risk mitigation and agility," *Sustainability*, vol. 15, no. 20, p. 15088, 2023, [doi: 10.3390/su152015088](https://doi.org/10.3390/su152015088)
- [7] D. Aloini, E. Benevento, R. Dulmin, E. Guerrazzi, and V. Mininno, "Unlocking real-time decision-making in warehouses: A machine learning-based forecasting and alerting system for cycle time

- prediction," *Transp. Res. Part E Logist. Transp. Rev.*, vol. 194, p. 103933, 2025, [doi: 10.1016/j.tre.2024.103933](https://doi.org/10.1016/j.tre.2024.103933)
- [8] M. Z. Babai, M. Arampatzis, M. Hasni, F. Lolli, and A. Tsadiras, "On the use of machine learning in supply chain management: A systematic review," *IMA J. Manag. Math.*, vol. 36, no. 1, pp. 21–49, 2025, [doi: 10.1093/imaman/dpae029](https://doi.org/10.1093/imaman/dpae029)
- [9] J. Du, J. Wang, and R. Liang, "Research on the impact of smart logistics on the manufacturing industry chain resilience," *Sci. Rep.*, vol. 15, no. 1, p. 93806, 2025, [doi: 10.1038/s41598-025-93806-8](https://doi.org/10.1038/s41598-025-93806-8)
- [10] N. Rezki and N. Mansouri, "Integrating machine learning and deep learning for enhanced supplier risk prediction," *Int. Sci. J. Logist.*, vol. 11, no. 3, pp. 387–396, 2024, [doi: 10.22306/al.v11i3.523](https://doi.org/10.22306/al.v11i3.523)
- [11] E. Flores-García, D. H. Kwak, Y. Jeong, and M. Wiktorsson, "Machine learning in smart production logistics: a review of technological capabilities," *Int. J. Prod. Res.*, vol. 63, no. 5, pp. 1898–1932, 2025, [doi: 10.1080/00207543.2024.2381145](https://doi.org/10.1080/00207543.2024.2381145)
- [12] S. K. Jauhar et al., "How to use no-code artificial intelligence to predict and minimize the inventory distortions for resilient supply chains," *Int. J. Prod. Res.*, vol. 62, no. 15, pp. 5510–5534, 2024, [doi: 10.1080/00207543.2023.2166139](https://doi.org/10.1080/00207543.2023.2166139)
- [13] L. Schmid, M. Roidl, A. Kirchheim, and M. Pauly, "Comparing Statistical and Machine Learning Methods for Time Series Forecasting in Data-Driven Logistics, A Simulation Study," *Entropy*, vol. 27, no. 1, p. 25, 2025, [doi: 10.3390/e27010025](https://doi.org/10.3390/e27010025)
- [14] M. Hudnurkar, K. M. Renji, S. Ambekar, G. Sahu, and M. J. Kavitha, "Predicting Delays for Truck Delivery Logistics: An Application of AI and ML," in *Proc. Int. Conf. Sci. Technol. Eng. Manag. (ICONSTEM), Chennai, India, 2024*, pp. 1–10, [doi: 10.1109/ICONSTEM60960.2024.10568601](https://doi.org/10.1109/ICONSTEM60960.2024.10568601)
- [15] S. Polo Triana, J. C. Gutierrez, and J. Leon Becerra, "Integration of machine learning in the supply chain for decision making: A systematic literature review," *J. Ind. Eng. Manag.*, vol. 17, no. 2, pp. 344–372, 2024, [doi: 10.3926/jiem.6403](https://doi.org/10.3926/jiem.6403)
- [16] P. Visconti et al., "Machine learning and IoT-based solutions in industrial applications for smart manufacturing: A critical review," *Future*, vol. 16, no. 11, p. 394, 2024, [doi: 10.3390/fi16110394](https://doi.org/10.3390/fi16110394)
- [17] J. Sayyad, K. Attarde, and B. Yilmaz, "Improving Machine Learning Predictive Capacity for Supply Chain Optimization through Domain Adversarial Neural Networks," *Big Data Cogn. Comput.*, vol. 8, no. 8, p. 81, 2024, [doi: 10.3390/bdcc8080081](https://doi.org/10.3390/bdcc8080081)
- [18] Y. Wang, "IoT-assisted machine learning model for engineering project warehouse management," *J. Comput. Methods Sci. Eng.*, vol. 23, no. 2, pp. 663–673, 2023, [doi: 10.3233/JCM-226630](https://doi.org/10.3233/JCM-226630)
- [19] C. A. Henao-Baena, B. Zuluaga-Zuluaga, J. Galeano-Castro, E. J. Marin-Garcia, and A. F. Calvo-Salcedo, "Methodology for Inventory Management in Neighborhood Stores Using Machine Learning and Integer Linear Programming," *Ingeniería*, vol. 29, no. 1, pp. 1–24, 2024, [doi: 10.14483/23448393.19423](https://doi.org/10.14483/23448393.19423)
- [20] R. Velastegui, R. Poler, and M. Diaz-Madroñero, "Aplicación de algoritmos de aprendizaje automático a sistemas robóticos multiagente," *Dir. Organ.*, vol. 80, pp. 60–70, 2023, [doi: 10.37610/dyo.v0i80.643](https://doi.org/10.37610/dyo.v0i80.643)
- [21] H. Lin, J. Lin, and F. Wang, "An innovative machine learning model for supply chain management," *J. Innov. Knowl.*, vol. 7, no. 4, p. 100276, 2022, [doi: 10.1016/j.jik.2022.100276](https://doi.org/10.1016/j.jik.2022.100276)
- [22] M. Mohamed-Ilias, L. Benabou, and A. Berrado, "Machine learning in supply chain management: A systematic literature review," *Int. J. Supply Oper. Manag.*, vol. 9, no. 4, pp. 398–416, 2022, [doi: 10.22034/ijsum.2021.109189.2279](https://doi.org/10.22034/ijsum.2021.109189.2279)
- [23] L. S. López Telechana, G. J. Serrano Torres, X. A. Quintana López, and D. M. Reina Haro, "Machine learning in Industry 4.0: A systematic review," *Salud Cienc. Tecnol.*, vol. 4, p. 1068, 2024, [doi: 10.56294/saludcyt20241068](https://doi.org/10.56294/saludcyt20241068)
- [24] B. Arslan and B. Y. Ekren, "Transaction selection policy in tier-to-tier SBSRS by using Deep Q-Learning," *Int. J. Prod. Res.*, vol. 61, no. 21, pp. 7353–7366, 2023, [doi: 10.1080/00207543.2022.2148767](https://doi.org/10.1080/00207543.2022.2148767)
- [25] A. Maged, S. Haridy, M. Awad, and M. Shamsuzzaman, "Machine learning aided Six Sigma: Perspective and practical implementation," *IEEE Trans. Eng. Manag.*, pp. 1–12, 2023, [doi: 10.1109/TEM.2023.3335237](https://doi.org/10.1109/TEM.2023.3335237)
- [26] S. Zhang, Q. Han, H. Zhu, and K. Wang, "Real time task planning for order picking in intelligent logistics warehousing," *Sci. Rep.*, vol. 15, p. 7331, 2025, [doi: 10.1038/s41598-025-88305-9](https://doi.org/10.1038/s41598-025-88305-9)

- [27] P. C. Kandarkar and V. Ravi, "Investigating the impact of smart manufacturing and interconnected emerging technologies in building smarter supply chains," *J. Manuf. Technol. Manag.*, vol. 35, no. 5, pp. 984–1009, 2024, [doi: 10.1108/JMTM-11-2023-0498](https://doi.org/10.1108/JMTM-11-2023-0498)
- [28] Y. Fernando, A. Suhaini, M.-L. Tseng, A. Z. Abideen, and M. S. Shaharudin, "A smart warehouse framework, architecture and system aspects under industry 4.0: A bibliometric networks visualisation and analysis," *Int. J. Logist. Res. Appl.*, vol. 27, no. 12, pp. 2688–2711, 2023, [doi: 10.1080/13675567.2023.2215179](https://doi.org/10.1080/13675567.2023.2215179)
- [29] H. Rahman, B. C. Menezes, and R. Baldacci, "Exploring the role of blockchain technology, warehouse automation, smart routing, and cloud computing in logistics performance," *Prod. Manuf. Res.*, vol. 12, no. 1, 2024, [doi: 10.1080/21693277.2024.2393614](https://doi.org/10.1080/21693277.2024.2393614)
- [30] P. Khare and M. Chansonba, "Impact of technology on warehouse management: A mixed-methods research approach," *IUP J. Supply Chain Manag.*, vol. 20, no. 4, pp. 17–40, 2023, [doi: 10.2139/ssrn.4920144](https://doi.org/10.2139/ssrn.4920144)
- [31] Y. Tang, G. T. Sum Ho, L. Yui-Yip, and S. Tsui, "Integrated smart warehouse and manufacturing management with demand forecasting in small-scale cyclical industries," *Machines*, vol. 10, no. 6, p. 472, 2022, [doi: 10.3390/machines10060472](https://doi.org/10.3390/machines10060472)
- [32] H. Liu, Z. Hu, and J. Hu, "E-Commerce Logistics Intelligent Warehousing System Solution Based on Multimedia Technology," *J. Electr. Comput. Eng.*, vol. 2022, pp. 1–12, 2022, [doi: 10.1155/2022/1754797](https://doi.org/10.1155/2022/1754797)
- [33] J. R. Hamilton, S. J. Maxwell, S. A. Ali, and S. Tee, "Adding external artificial intelligence (AI) into internal firm-wide smart dynamic warehousing solutions," *Sustainability*, vol. 16, no. 10, p. 3908, 2024, [doi: 10.3390/su16103908](https://doi.org/10.3390/su16103908)
- [34] Y. Mashayekhy, A. Babaei, X. M. Yuan, and A. Xue, "Impact of Internet of Things (IoT) on Inventory Management: A Literature Survey," *Logistics*, vol. 6, no. 2, p. 33, 2022, [doi: 10.3390/logistics6020033](https://doi.org/10.3390/logistics6020033)
- [35] J. McGarvey, M. R. Grabowski, B. Custard, and S. Gabelein, "Self-Healing Databases for Emergency Response Logistics in Remote and Infrastructure-Poor Settings," *Logistics*, vol. 9, no. 1, p. 23, 2025, [doi: 10.3390/logistics9010023](https://doi.org/10.3390/logistics9010023)
- [36] L. Goel et al., "Revealing the dynamics of demand forecasting in supply chain management: a holistic investigation," *Cogent Eng.*, vol. 11, no. 1, 2024, [doi: 10.1080/23311916.2024.2368104](https://doi.org/10.1080/23311916.2024.2368104)
- [37] S. He, Y. Wang, and L. Hongda, "Image Information Recognition and Classification of Warehoused Goods in Intelligent Logistics Based on Machine Vision Technology," *Trait. Signal*, vol. 39, no. 4, pp. 1275–1282, 2022, [doi: 10.18280/ts.390420](https://doi.org/10.18280/ts.390420)
- [38] N. Su, S. Huang, and C. Su, "Elevating smart manufacturing with a unified predictive maintenance platform: The synergy between data warehousing, Apache Spark, and machine learning," *Sensors*, vol. 24, no. 13, p. 4237, 2024, [doi: 10.3390/s24134237](https://doi.org/10.3390/s24134237)
- [39] J. Sebastian, J. A. Riascos-Guerrero, E. Galván-Colonia, and J. L. Pincay-Lozada, "Estrategias basadas en inteligencia artificial para la gestión de inventarios en la cadena de suministro," *Tecnol. Marcha*, vol. 37, no. 6, pp. 88–97, 2024, [doi: 10.18845/tm.v37i6.7271](https://doi.org/10.18845/tm.v37i6.7271)
- [40] V. P. Sharma, S. Prakash, R. Singh, and C. Malik, "Analysing industry 4.0 key performance indicators for sustainability of smart warehouses," in *Recent Adv. Green Technol. Sustain. Dev.*, M. H. Doshi, R. Nair, and P. Savsani, Eds., London: CRC Press, 2024, pp. 1–12, [doi: 10.1201/9781003450917](https://doi.org/10.1201/9781003450917)
- [41] W. Carpeta Camacho, "Big data analytics in programme evaluation: Examining models for the assessment of sustainable development goals in Colombia," *Cuad. Econ.*, vol. XLII, no. 89, pp. 233–264, 2023, [doi: 10.15446/cuad.econ.v42n89.95487](https://doi.org/10.15446/cuad.econ.v42n89.95487)
- [42] A. Correa, "Predicting business bankruptcy in Colombian SMEs: A machine learning approach," *J. Int. Commer. Econ. Policy*, vol. 14, no. 3, 2023, [doi: 10.1142/S1793993323500278](https://doi.org/10.1142/S1793993323500278)
- [43] M. E. García Camacho and J. D. Anido R., "Encouragement Policies and Productivity Indicators for Colombian SMEs Using Data Envelopment Analysis and Malmquist Indexes," *Rev. CEA*, vol. 10, no. 22, 2024, [doi: 10.22430/24223182.2708](https://doi.org/10.22430/24223182.2708)
- [44] K. Govindan, D. Kannan, T. Ballegard, and N. Straarup, "Supply Chain 4.0 performance measurement: A systematic literature review, framework development, and empirical evidence," *Comput. Ind. Eng.*, vol. 172, p. 108574, 2022, [doi: 10.1016/j.cie.2022.108574](https://doi.org/10.1016/j.cie.2022.108574)
- [45] N. R. Haddaway, M. J. Page, C. C. Pritchard, and L. A. McGuinness, "PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and Open Synthesis," *Campbell Syst. Rev.*, vol. 18, p. e1230, 2022, [doi: 10.1002/cl2.1230](https://doi.org/10.1002/cl2.1230)
- [46] W. Hadid, S. Horii, and A. Yokota, "Artificial intelligent technologies in Japanese manufacturing firms: an empirical survey study," *Int. J. Prod. Res.*, vol. 63, no. 1, pp. 193–219, 2025, [doi: 10.1080/00207543.2024.2358409](https://doi.org/10.1080/00207543.2024.2358409)
- [47] M. E. Martínez Zabaleta and R. E. Rodríguez Luna, "Inteligencia empresarial y su rol en la generación de valor en los procesos de negocios," *Rev. Fac. Cienc., Univ. Nariño*, vol. 24, no. 1, pp. 226–251, 2023, [doi: 10.22267/rtend.222302.222](https://doi.org/10.22267/rtend.222302.222)
- [48] S. P. Plakantara, A. Karakitsiou, and T. Mantzou, "Managing risks in smart warehouses from the perspective of Industry 4.0," in *Disruptive Technol. Optim. Towards Ind. 4.0 Logist.*, A. Karakitsiou, A. Migdalas, and P. M. Mardalos, Eds., Cham: Springer, 2024, pp. 1–47, [doi: 10.1007/978-3-031-58919-5_1](https://doi.org/10.1007/978-3-031-58919-5_1)
- [49] B. Rolf et al., "A review on unsupervised learning algorithms and applications in supply chain management," *Int. J. Prod. Res.*, vol. 63, no. 5, pp. 1933–1983, 2025, [doi: 10.1080/00207543.2024.2390968](https://doi.org/10.1080/00207543.2024.2390968)
- [50] B. Unglesbee, "AI opens new frontier in supply chain planning," *Supply Chain Dive*, 2023. <https://www.proquest.com/trade-journals/ai-opens-new-frontier-supply-chain-planning/docview/2820821953/se-2>