ISBN: 978-628-96613-1-6. ISSN: 2414-6390. Digital Object Identifier: https://dx.doi.org/10.18687/LACCEI2025.1.1.891

Machine Learning in Supply Chain Management. A Systematic Literature Review between 2020-2024

Polo Zavala Raul Bernardino, Industrial Engineering Student[1]; Cruzate Castro Jose Fernando, Industrial Engineering Student[2]; Torres Velasquez Julio Winston, Master in Operations and Supply Chain Management[3]; Rivas Mendoza Milagros Isabel, Master in Education Sciences, mention in Teaching and Research[4]
[1,2,3,4] Universidad Tecnológica del Perú, Perú, u20304100@utp.edu.pe, u20232543@utp.edu.pe, c23976@utp.edu.pe, c23212@utp.edu.pe

Abstract- The present systematic research aims to analyze the influence of Machine Learning applications in supply chain management, focusing on studies published between 2020 and 2024. Thirty relevant researches were identified that met the established inclusion criteria. The results show that Machine Learning significantly improves demand forecasting, inventory management and logistics optimization, allowing to reduce operating costs and increase organizational efficiency. In addition, outstanding applications such as Long and Short Term Memory (LSTM) neural networks for accurate predictions and Support Vector Machines (SVM) for complex classifications were identified. However, challenges remain, such as data quality, integration with traditional systems, and the need for professionals trained in this technology. Despite these limitations, the pharmaceutical, manufacturing and food sectors have demonstrated a positive impact by implementing Machine Learning-based solutions, optimizing processes and increasing their competitiveness. In conclusion, Machine Learning is consolidating as a key driver to transform supply chain management, although more investment in training and integration strategies is required to maximize its potential.

Keywords: Machine Learning, operational efficiency, automation, logistics optimization, digital transformation, industrial innovation.

Machine Learning en la Gestión de la Cadena de Suministro Una Revisión Sistemática de Literatura entre 2020-2024

Polo Zavala Raul Bernardino, Estudiante de Ingeniería Industrial[1]; Cruzate Castro Jose Fernando, Estudiante de Ingeniería Industrial[2]; Torres Velasquez Julio Winston, Magister en dirección de Operaciones y Cadena de Abastecimiento[3]; Rivas Mendoza Milagros Isabel, Maestra en Ciencias de la Educación mención Docencia e Investigación[4]

[1,2,3,4] Universidad Tecnologica del Perú, Perú, u20304100@utp.edu.pe, u20232543@utp.edu.pe, c23976@utp.edu.pe, c23212@utp.edu.pe

Resumen- ***La presente investigación sistemática tiene como propósito analizar la influencia de las aplicaciones de Machine Learning en la gestión de la cadena de suministro, enfocándose en estudios publicados entre 2020 y 2024. Se identificaron 30 investigaciones relevantes que cumplieron con los criterios de inclusión establecidos. Los resultados muestran que el Machine Learning mejora significativamente la previsión de la demanda, la gestión de inventarios y la optimización logística, permitiendo reducir costos operativos y aumentar la eficiencia organizacional. Además, se identificaron aplicaciones destacadas como redes neuronales de memoria a largo y corto plazo (LSTM) para predicciones precisas y Máquinas de Soporte Vectorial (SVM) para clasificaciones complejas. Sin embargo, persisten desafíos, tales como la calidad de los datos, la integración con sistemas tradicionales y la necesidad de profesionales capacitados en esta tecnología. A pesar de estas limitaciones, los sectores farmacéutico, manufacturero y alimenticio han demostrado un impacto positivo al implementar soluciones basadas en Machine Learning, optimizando procesos y aumentando su competitividad. En conclusión, el Machine Learning se consolida como un impulsor clave para transformar la gestión de la cadena de suministro, aunque se requiere mayor inversión en formación y en estrategias de integración para maximizar su potencial.***

Palabras clave: Machine Learning, eficiencia operativa, automatización, optimización logística, transformación digital, innovación industrial.

I. INTRODUCCIÓN

En el contexto actual de la transformación digital, el Machine Learning ha revolucionado la gestión de las cadenas de suministro[1]. A medida que los mercados se tornan más competitivos y cambiantes, las organizaciones se han enfocado en mejorar sus procesos con el propósito de preservar una ventaja competitiva.

De este modo, logran adaptarse a las nuevas exigencias del entorno y asegurar su posición en el mercado [2][3]. La habilidad del Machine Learning para manejar extensos conjuntos de datos y realizar análisis predictivos se ha convertido en un recurso fundamental en campos como la previsión de la demanda, la optimización de inventarios y la logística [4]. Estas aplicaciones no solo contribuyen a la reducción de costos, sino que también permiten tomar decisiones más informadas y ágiles [5][6].

El Machine Learning permite a las industrias prevenir antes los cambios del mercado y actuar proactivamente [7]. Desde la optimización de rutas de distribución hasta la reducción de tiempos de entrega, sus aplicaciones son diversas y generan beneficios significativos[8][9]. Asimismo, el análisis en tiempo real ha elevado notablemente la eficiencia operativa, permitiendo que las empresas se adapten de manera rápida a imprevistos y mejoren su capacidad de respuesta [10].

No obstante, la adopción de estas soluciones enfrenta diversos retos. Muchas empresas se enfrentan a barreras como la falta de datos de calidad y los altos costos asociados con la adopción de estas tecnologías [11] Además, la necesidad de contar con profesionales capacitados en Machine Learning es otro obstáculo significativo, ya que estos recursos no siempre están fácilmente disponibles [12][13]. Por lo tanto, para aprovechar plenamente el potencial de esta tecnología, es crucial invertir en la formación y desarrollo de competencias especializadas [14].

Otro reto importante radica en la integración de soluciones de Machine Learning con los sistemas tradicionales de gestión de la cadena de suministro. Si este proceso no se lleva a cabo correctamente, pueden surgir problemas operativos[15] . No obstante, aquellas empresas que logran una integración exitosa obtienen beneficios significativos, como la reducción de costos, una mayor satisfacción del cliente y una ventaja competitiva sostenible[16]. Además, el Machine Learning ha demostrado ser eficiente en la identificación de patrones ocultos en los datos, lo que permite tomar decisiones más precisas y orientadas al futuro [17].

A pesar de estos desafíos, cada vez más empresas reconocen el valor del Machine Learning para enfrentar las complejidades del mercado actual [18]. Aquellas que han implementado esta tecnología han experimentado mejoras considerables, especialmente en la previsión de demanda y la gestión eficiente del inventario [19]. Todo indica que la adopción del Machine Learning continuará expandiéndose, consolidándose como una herramienta indispensable para el éxito a largo plazo [20].

Desde una perspectiva científica el hecho de comprender cómo el Machine Learning mejora la cadena de suministro nos permite desarrollar modelos más avanzados para aprovechar los datos y recursos de manera inteligente. En el ámbito técnico, la aplicación del Machine Learning no solo optimiza procesos, sino que los hace más eficientes y económicos, lo que ayuda a las empresas a mantenerse competitivas.

A nivel social, el uso de estas tecnologías puede favorecer una toma de decisiones más justa y equitativa dentro de las organizaciones. En cuanto al aspecto económico, apostar por estrategias basadas en Machine Learning no solo disminuye los costos relacionados con la gestión del inventario y la logística, sino que también incrementa los beneficios a largo plazo, garantizando una ventaja competitiva.

Por lo mencionado anteriormente, se propone responder la siguiente pregunta de investigación: ¿De qué manera influyen las aplicaciones de machine learning en la gestión de la cadena de suministro en las industrias?

Asimismo, se plantearon las siguientes preguntas complementarias implementando la estructura de PICO (Población, intervención, comparación y resultados):

PC1: ¿De qué manera el aprendizaje automático impacta en la gestión de inventarios?

PC2: ¿Cómo contribuyen las herramientas de machine learning a los procesos logísticos?

PC3: ¿Qué tecnologías se han utilizado para la mejora de la gestión de la cadena de suministros?

PC4: ¿Cómo contribuye el aprendizaje automático a la predicción de la demanda y la planificación de la producción dentro de las industrias?

Como objetivos específicos tenemos: Identificar las fuentes más empleadas por los autores para la publicación de artículos, verificar la relación entre autores y palabras claves en el contexto del machine learning y la cadena de suministro, describir la producción científica según la coincidencia de palabras clave relacionadas con machine learning en la gestión de la cadena de suministro, detallar las aplicaciones de machine learning y los beneficios que otorgan tanto de forma global como en sectores industriales específicos, establecer los indicadores relacionados entre machine learning y los diferentes procesos de la cadena de suministro, como la gestión de inventarios, procesos logísticos, predicción de demanda y planificación de la producción.

II. METODOLOGÍA

Con el objetivo de realizar este análisis, se planteó llevar a cabo una revisión sistemática enfocada en la influencia del machine learning en la gestión de la cadena de suministro.Se define la revisión sistemática de literatura como un tipo de estudio secundario que tiene la función de identificar, combinar y analizar la evidencia proveniente de investigaciones primarias, utilizando un enfoque riguroso apoyado en herramientas estadísticas y gráficos dinámicos para facilitar una mejor comprensión del tema investigado [21].

El proceso inició con la consulta en una base de datos de alcance global, como SCOPUS, donde se encontraron las investigaciones primarias. Cabe destacar que estos estudios fueron publicados entre 2020 y 2024, lo que nos proporciona una base de datos actualizada y sólida sobre las variables en estudio.

El estudio se basa en un enfoque mixto que sigue las directrices de la guía PRISMA 2020, la cual busca mejorar la transparencia y calidad en la presentación de revisiones sistemáticas. Este marco permite a revisores y lectores evaluar más fácilmente los métodos y hallazgos, al incluir 27 ítems recomendados que abordan aspectos clave a comunicar de manera clara y completa. La investigación combina métodos cualitativos y cuantitativos, centrándose en la recopilación y análisis de estudios y datos bibliométricos relevantes para responder a preguntas específicas. Así, el uso de PRISMA asegura una estructura organizada y precisa en la revisión, facilitando la evaluación de la calidad y fiabilidad del análisis realizado [22].

Al adherirse a los principios del método PRISMA, los autores primarios se aseguran de que su revisión sistemática sea exhaustiva, válida y accesible, lo que refuerza la confiabilidad y transparencia del estudio en el área correspondiente [23].

Asimismo, la utilización de este método promueve un análisis crítico de las fuentes y técnicas empleadas, lo que facilita la identificación de posibles sesgos y limitaciones en la revisión.

Por otro lado, se lleva a cabo un análisis bibliométrico, utilizando herramientas que permiten evaluar y examinar la producción científica a través de métodos cuantitativos, lo que facilita el estudio de la estructura y la evolución del desarrollo científico [24].

En la etapa de identificación de registros, se tomaron en cuenta las variables de estudio "Machine learning" y "Supply Chain managament". Inicialmente, se seleccionaron 19,693 investigaciones, las cuales fueron sometidas a un exhaustivo

proceso de filtrado basado en criterios de inclusión y exclusión para garantizar la relevancia del material científico

Tras un riguroso proceso de selección, se identificaron 101 investigaciones que satisfacían los criterios de inclusión establecidos a priori. Estos criterios comprendían la presencia de ambas variables de estudio en el título o resumen, la inclusión de palabras clave específicas, el idioma de publicación. Adicionalmente, se requirió que los estudios fueran de acceso abierto y que hubieran concluido su fase de investigación. Siendo la ecuación de búsqueda resultante: (industries OR "Industry 4.0" OR "Manufacturing" OR "Operations and supply chain management") AND (machine learning OR "machine learning algorithms" OR "artificial intelligence" OR "deep learning" OR "learning systems") AND (efficiency OR "supply chain efficiency" OR "optimization" OR "predictive analytics" OR "decision making") AND (industrial sector OR "supply chain network" OR "supply chain management" OR "inventory management" OR "demand forecasting").

TABLA I

CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN PARA LA REVISIÓN SISTEMATICA DE LITERATURA

Criterios de Inclusión	
CI1	Los estudios especializados en la cadena de suministro y la implementación del aprendizaje automático
CI2	Ofrecer técnicas del aprendizaje automático para mejorar la eficiencia cadena de suministro
Criterios de Exclusión	
EC1	Estudios que se encuentran fuera de la delimitación temporal (2020-2024)
EC2	Publicaciones diferentes a la categoría “Article”
EC3	Artículos fuera de la tematica “Computer science” y “engineering”,” Businnes,Management and Accounting”.
EC4	Estudios que esten escritos en idiomas diferentes a ingles

Finalmente, en el subsiguiente proceso de refinamiento, se procedió a la exclusión de 18 revisiones sistemáticas con el propósito de garantizar la originalidad de las investigaciones analizadas. Asimismo, se descartaron 53 estudios debido a su desviación temática respecto al objeto de investigación. Como resultado de este proceso de selección, el conjunto final quedó constituido por 30 artículos que cumplían cabalmente con los criterios establecidos.

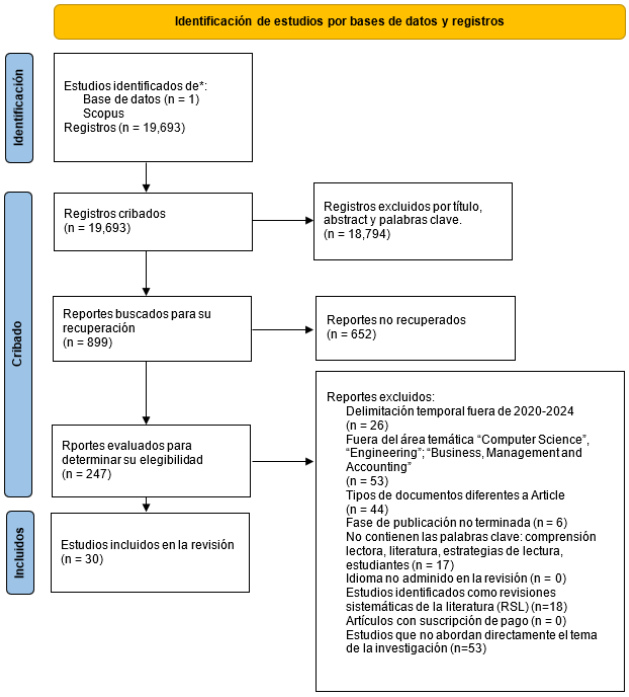


Fig. 1. PRISMA 2020 Diagrama de flujo para nuevos estudios sistemáticos que incluyeron búsquedas solo en bases de datos y registros.

III. RESULTADOS Y DISCUSIÓN

La sección de resultados se estructura en dos partes principales: análisis bibliométrico y análisis de contenido. Inicialmente, se presenta una síntesis de la variedad de investigaciones incluidas en este estudio, las cuales abordan la temática de machine learning y la gestión de cadena de suministro durante los años 2020-2024. Como se evidencia en la Tabla II, el conjunto final comprende 56 trabajos que cumplen con los criterios de selección previamente establecidos.

TABLA II
ESTUDIOS INCLUIDOS EN LA REVISIÓN SISTEMÁTICA DE TECNOLOGÍA Y SU INFLUENCIA EN LA GESTIÓN DE RESIDUOS SÓLIDOS: UNA REVISIÓN SISTEMÁTICA DE LITERATURA 2020-2024

AUTORES	TITULO DE ESTUDIO
Sani S,Xia H,Milisavljevic-Syed J,Salonitis K [25]	Supply Chain 4.0: A Machine Learning-Based Bayesian-Optimized LightGBM Model for Predicting Supply Chain Risk
Ben Elmir W,Hemmak A,Senouci B [26]	Smart Platform for Data Blood Bank Management: Forecasting Demand in Blood Supply Chain Using Machine Learning
Aljohani A[27]	Predictive Analytics and Machine Learning for Real-Time Supply Chain Risk Mitigation and Agility
Islam S,Amin SH [28]	Prediction of probable backorder scenarios in the supply chain using Distributed Random Forest and Gradient Boosting Machine learning techniques

Singh AK,Simha JB,Agarwal R[29]	Prediction of Intermittent Demand Occurrence using Machine Learning
Li L[30]	Predicting the Investment Risk in Supply Chain Management Using BPNN and Machine Learning
Alzaman C,Aljuneidi T,Li Z [31]	Predicting Bike Usage and Optimizing Operations at Repair Shops in Bike Sharing Systems
Kumar I,Rawat J,Mohd N,Husain S [32]	Opportunities of Artificial Intelligence and Machine Learning in the Food Industry
Kumar S,Sharma SC [33]	Integrated Model for Predicting Supply Chain Risk through Machine Learning Algorithms
Biller B,Biller S [34]	Implementing Digital Twins That Learn: AI and Simulation Are at the Core
Song R,Hu H [35]	Impact of green technology innovation based on IoT and industrial supply chain on the promotion of enterprise digital economy
Ghodake SP,Malkar VR,Santosh K,Jabasheela L,Abdufattokhov S,Gopi A [36]	Enhancing Supply Chain Management Efficiency: A Data-Driven Approach using Predictive Analytics and Machine Learning Algorithms
Udokwu C,Zimmermann R,Brandtner P,Obinwanne T [37]	Development of an Ensemble Modeling Framework for Data Analytics in Supply Chain Management
Park KJ [38]	Determining the tiers of a supply chain using machine learning algorithms
Nassibi N,Fasihuddin H,Hsairi L [39]	Demand Forecasting Models for Food Industry by Utilizing Machine Learning Approaches
Bassiouni MM,Chakrabortty RK,Sallam KM,Hussain OK [40]	Deep learning approaches to identify order status in a complex supply chain
Duan G,Dong J [41]	Construction of Ensemble Learning Model for Home Appliance Demand Forecasting
Dong Z,Liang W,Liang Y,Gao W,Lu Y [42]	Blockchained supply chain management based on IoT tracking and machine learning
Dubey R,Gunasekaran A,Childe SJ,Bryde DJ,Giannakis M,Foropon C,Roubaud D,Hazen BT [43]	Big data analytics and artificial intelligence pathway to operational performance under the effects of entrepreneurial orientation and environmental dynamism: A study of manufacturing organisations
Helo P,Hao Y [44]	Artificial intelligence in operations management and supply chain management: an exploratory case study
Nasseri M,Falatouri T,Brandtner P,Darbanian F [45]	Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning
Debnath B,Chattopadhyay AK,Kumar TK [46]	An Economic Optimization Model of an E-Waste Supply Chain Network: Machine Learned Kinetic Modelling for Sustainable Production
Zdravković M,Panetto H,Weichhart G [47]	AI-enabled Enterprise Information Systems for Manufacturing
Nasurudeen Ahamed N,Karthikeyan P [48]	A Reinforcement Learning Integrated in Heuristic search method for self-driving vehicle using blockchain in supply chain management
Khedr AE,Alsahafi YS,Idrees AM [49]	A Proposed Multi-Level Predictive WKM_ID3 Algorithm, Toward Enhancing Supply Chain Management in Healthcare Field
Manoharan H,Teekaraman Y,Kuppusamy R,Radhakrishnan A,Jabarulla MY [50]	A Prognostic Three-Axis Coordination Model for Supply Chain Regulation Using Machine Learning Algorithm
Deng C,Liu Y [51]	A Deep Learning-Based Inventory Management and Demand Prediction Optimization Method for Anomaly Detection
Addou K,El Ghoumari MY,Achkdir S,Azzouazi M [52]	A decentralized model to ensure traceability and sustainability of the food supply chain by combining blockchain, IoT, and machine learning
Wakle SP,Toshniwal VP,Jain R,Soni G,Ramtiyal B [53]	A Data-driven Approach for Planning Stock Keeping Unit (SKU) in a Steel Supply Chain
Abbas K,Afaq M,Khan TA,Song WC [54]	A blockchain and machine learning-based drug supply chain management and recommendation system for smart pharmaceutical industry

FUENTE: ELABORACIÓN PROPIA

3.1 RESULTADOS BIBLIOMÉTRICOS

A través de la sistematización y el análisis del contenido relacionado con el machine learning en la gestión de la cadena de suministros, se evidenció, mediante el diagrama de Sankey, la relación entre palabras clave, autores y países. El flujo, que sigue una dependencia de izquierda a derecha, muestra cómo las palabras clave se vinculan con los autores y, posteriormente, cómo estos se distribuyen entre los países donde se publicaron los trabajos. En este contexto, se identificó que las palabras clave con mayor frecuencia son “machine learning” (12) y “Supply Chain Management” (7), mientras que las menos utilizadas son “forecasting” (2) y “Supply Chain Risk Management” (1). Asimismo, entre los autores más destacados se encuentran Brandtner Patrick, Alzaman Chaher y Abdufattokhov Shokhjakhon, entre otros. Finalmente, los países con mayor flujo de publicaciones incluyen Estados Unidos, India y Emiratos Árabes Unidos, mientras que otros tienen una menor frecuencia de participación.

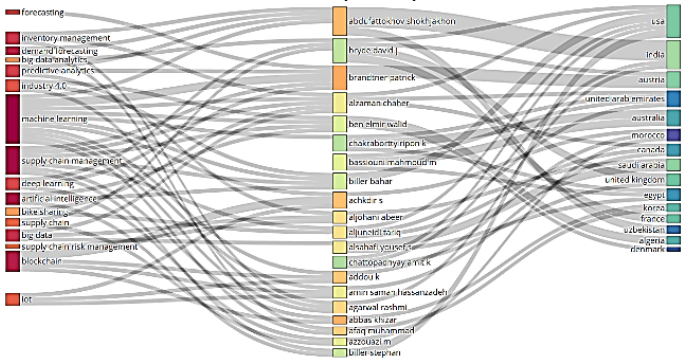


FIG. 2 GRÁFICO DE 3 CAMPOS DE LOS ARTÍCULOS.

A través de la sistematización y el análisis del contenido relacionado con el aprendizaje automático en la gestión de la cadena de suministros, se analiza la producción científica basada en los artículos recopilados. Este proceso, se evidencia que países como India destacan con 16 publicaciones, seguidos por China y Arabia Saudita con 6 artículos cada uno, mientras

que Austria y Estados Unidos registran 5 artículos cada uno. Este análisis resalta el protagonismo de estas regiones en la investigación sobre el tema.

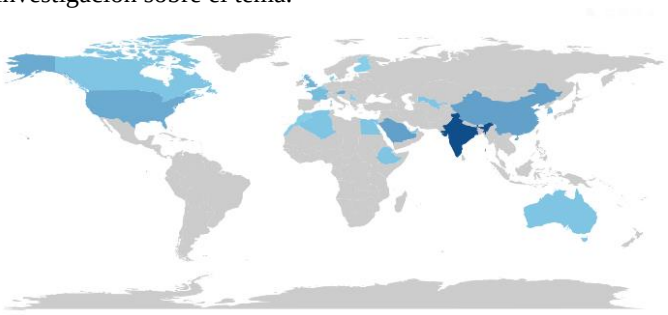


FIG. 3 PRODUCCIÓN CIENTÍFICA SEGÚN PAÍS DE ORIGEN.

Por último, se cuenta con la nube de palabras claves más empleadas entre las investigaciones seleccionadas junto a la frecuencia de su empleabilidad, de las cuales destacaron: supply chain management (22), machine-learning (14), machine learning (10), forecasting (9), learning systems (8), decision making (5), entre otros.

La nube de palabras clave evidencia que "supply chain management" y "machine learning" son conceptos centrales en las investigaciones analizadas, subrayando su importancia en la optimización de procesos en la gestión de la cadena de suministro. Los estudios destacan el uso de técnicas de ML para abordar problemas clave como la predicción de demanda, la gestión de inventarios y la asignación de recursos.

Por ejemplo, en [45], se demuestra que modelos como Extra Trees Regressor (ETR) y LSTM logran predicciones precisas en productos perecederos, mientras que [51] emplea LSTM para optimizar inventarios, reduciendo costos en un 25 %. Asimismo, en [53], se utilizan algoritmos de clustering no supervisado para segmentar inventarios, permitiendo estrategias más específicas para los SKUs. Estas aplicaciones refuerzan la necesidad de personalización frente a enfoques tradicionales generalistas.



Fig. 4 Nube de palabras claves.

En la Figura, se destacan fuentes clave como "APPLIED SCIENCES (SWITZERLAND)" y "IEEE ACCESS", cada una con 2 artículos, reflejando su relevancia en el análisis bibliográfico. Otras fuentes como "SUSTAINABILITY (SWITZERLAND)" también aportan con 2 artículos, mientras que un conjunto de 23 publicaciones, como "JOURNAL OF BIG DATA" y "EXPERT SYSTEMS WITH APPLICATIONS", contribuyen con 1 artículo cada una. Este patrón muestra una concentración en fuentes principales, complementadas por una diversidad de perspectivas secundarias.

Los estudios revisados destacan la aplicación de tecnologías de inteligencia artificial para optimizar la gestión de cadenas de suministro. Técnicas como LightGBM y N-gram han mejorado la trazabilidad y la predicción de riesgos en inventarios, mientras que algoritmos como LSTM y k-means han optimizado la planificación de la demanda y la segmentación de SKUs, reduciendo costos operativos y tiempos de servicio [48] [51] [54]. Estas soluciones fortalecen la toma de decisiones estratégicas y la eficiencia operativa, posicionando a las organizaciones como líderes en entornos dinámicos y competitivos [45] [46] [53] .

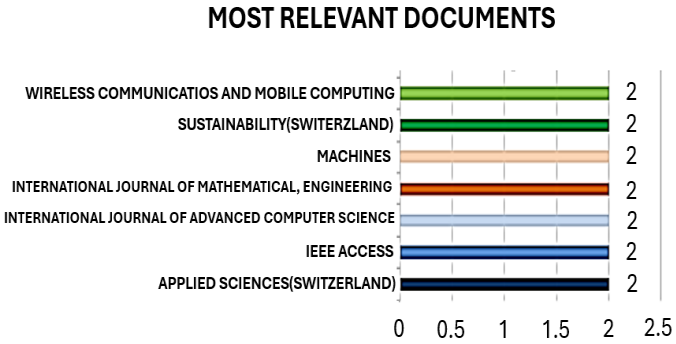


Fig. 5 Documentos más relevantes.

3.2 RESULTADOS DE CONTENIDO

En la figura 6, se evidencia el impacto del machine learning en la gestión de inventario, de acuerdo con la revisión realizada. El mayor impacto se observa en la optimización de niveles de inventario, con un 45%, lo que indica que el aprendizaje automático facilita un ajuste preciso de los stocks según las necesidades reales, reduciendo tanto el exceso como el déficit de productos en almacén [26] Asimismo, la predicción precisa de la demanda, con un impacto del 35%, muestra que los algoritmos de aprendizaje automático permiten anticipar con mayor exactitud las cantidades requeridas en el futuro, contribuyendo a una planificación más eficiente y a una mayor satisfacción de la demanda [25] [29] .

Las estrategias de alineación de inventario representaron solo el 5% del impacto identificado en los estudios revisados. Este bajo porcentaje sugiere que, aunque el aprendizaje automático ofrece herramientas para sincronizar el inventario con la demanda en tiempo real, su aplicación en esta área aún es limitada. Las estrategias de alineación buscan adaptar los niveles de inventario de manera precisa según las fluctuaciones del mercado [53].

Sin embargo, aunque estas tecnologías son claramente beneficiosas, su efectividad puede verse limitada por la calidad de los datos. Modelos de machine learning alimentados con datos erróneos o incompletos pueden generar predicciones inexactas, lo que representa un desafío común en la gestión de la cadena de suministro [29] [30] [34] . Además, los costos asociados a su implementación, como la adquisición de software, hardware y la capacitación del personal, pueden ser prohibitivos para algunas empresas, restringiendo su adopción [28].

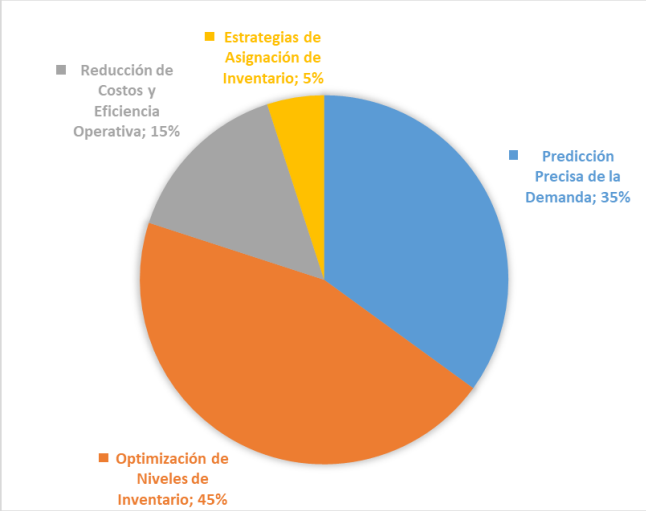


Fig. 6 Impacto del aprendizaje automático en la gestión de inventario.

El gráfico muestra la contribución de las herramientas de machine learning en los procesos logísticos, destacando varias áreas clave. Un 7% de los estudios revisados se enfoca en la optimización del flujo logístico y rutas de transporte, lo cual mejora la planificación de rutas y la eficiencia en el flujo de mercancías, reduciendo costos y tiempos [33]. La predicción de demanda y la gestión de inventarios representan el área de mayor enfoque, abarcando un 56% de los estudios; esta práctica permite anticipar las necesidades de inventario y mejorar la disponibilidad de productos, optimizando así la planificación de inventarios [31] [42].

Por otro lado, un 11% de los estudios aborda la automatización y toma de decisiones en tiempo real, lo cual permite a las empresas responder rápidamente a cambios en la demanda o en el mercado, ajustando así la distribución de productos [39]. Finalmente, un 26% de los estudios destaca la reducción de riesgos y la mejora de la eficiencia en la cadena de suministro mediante el uso de machine learning, minimizando errores y optimizando recursos para incrementar la eficiencia operativa general [47].

Aunque el *machine learning* aporta ventajas a la logística, enfrenta barreras clave: la optimización de rutas (7%) depende de datos escasos, la predicción de demanda (56%) falla en entornos dinámicos, y la automatización (11%) sufre altos costos iniciales. Además, la mejora de eficiencia (26%) enfrenta resistencia organizacional [28].

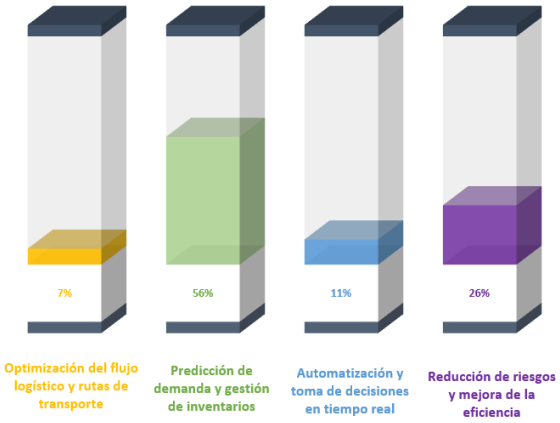


Figura 7. CONTRIBUCIÓN DE LAS HERRAMIENTAS DE MACHINE LEARNING EN LOS PROCESOS LOGÍSTICOS.

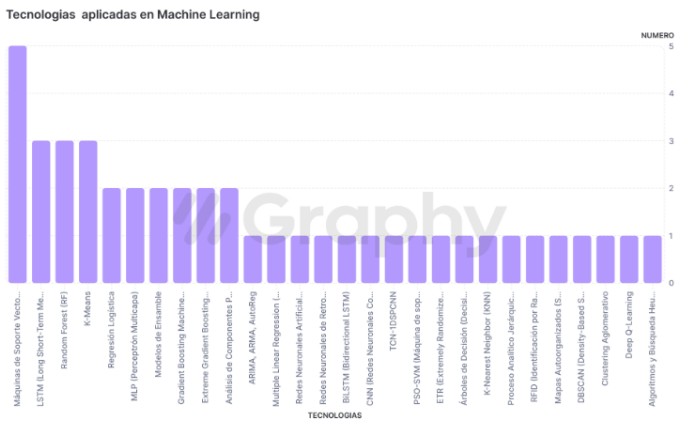


Fig. 8 Tecnologías utilizadas para la mejora de la gestión de la cenada de suministros.

En la figura 8 se muestra que las Máquinas de Soporte Vectorial (SVM) son las tecnologías más empleadas para mejorar la gestión de la cadena de suministro, debido a su efectividad en la clasificación y predicción [33] [35] [38] . Le siguen las redes de Memoria a Largo y Corto Plazo (LSTM), son herramientas valiosas para examinar series temporales y prever la demanda. Ambas técnicas son clave para optimizar

procesos y mejorar la eficiencia en la cadena de suministro [40][51].

No obstante, se ha demostrado que LSTM puede superar a SVM en términos de precisión, ya que su capacidad para manejar grandes volúmenes de datos y capturar patrones temporales complejos lo hace especialmente útil para la previsión de demanda. Esto permite a las empresas anticipar con mayor exactitud sus necesidades de inventario y ajustar estrategias de suministro, reduciendo riesgos operativos y mejorando la eficiencia general [39] [41].

TABLA III
INDUSTRIAS QUE IMPLEMENTARON EL MACHINE LEARNING.

Contribuciones del aprendizaje automático a la predicción de la demanda.	**Industrias que implementaron el machine learning**		
	Industria Manufacturera	**Industria Farmacéutica**	**Industria Alimenticia**
Predicción precisa de la demanda mediante el análisis de patrones y datos históricos	[45] [53]		[52]
Optimización de inventario y reducción de costos	[43] [46] [51]	[54]	
Ajustes en producción y distribución en función de la demanda	[44] [46] [48]		
Planificación de inventario para asegurar la disponibilidad	[47] [50]		

El uso de machine learning ha evolucionado drásticamente, transformando distintas industrias empresariales con una repercusión significativa en sus operaciones.

En la industria farmacéutica, el machine learning ha sido clave para optimizar el inventario y mejorar la precisión en la distribución de productos. Esta tecnología facilita el seguimiento de los medicamentos en todas las etapas de la cadena de suministro, combatiendo la falsificación y asegurando que solo productos auténticos lleguen a los consumidores. Esto incrementa la trazabilidad y la calidad, reduciendo riesgos para los pacientes y reforzando la seguridad en la entrega de medicamentos [54].

En la industria alimenticia, la implementación de machine learning y tecnologías IoT fortalece la seguridad y transparencia en la cadena de suministro. Como destaca el artículo [52], estas herramientas permiten una trazabilidad en tiempo real, asegurando que los productos mantengan condiciones óptimas y evitando posibles riesgos de contaminación. Sensores IoT monitorizan continuamente el estado de los alimentos en tránsito, lo que facilita decisiones rápidas y efectivas en cada etapa de la cadena alimentaria y genera confianza en la calidad y seguridad del producto final.

Finalmente, en las industrias manufactureras, el machine learning y el análisis de big data están revolucionando la gestión de inventarios y la predicción de la demanda. Los artículos [43][46][51] subrayan cómo estas herramientas mejoran la precisión en la gestión de inventarios, logrando reducir costos y aumentar beneficios, mientras que los artículos [44] [46] [48] destacan la optimización en producción y distribución mediante modelos de aprendizaje automático y Adicionalmente, los artículos [47] [50] muestran que el uso de machine learning en estrategias de inventario no solo garantiza la disponibilidad de productos sino que también permite una adaptación rápida ante cambios en la demanda, fortaleciendo la resiliencia y eficiencia de la cadena de suministro en un entorno de mercado dinámico.

IV. CONCLUSIONES

Esta revisión sistemática de literatura ha analizado el impacto del Machine Learning (ML) en la gestión de la cadena de suministro, enfocándose en estudios publicados entre 2020 y 2024. Los hallazgos destacan al ML como una herramienta transformadora en procesos críticos, como la previsión de demanda, la optimización de inventarios y la eficiencia logística. Estas tecnologías no solo han reducido costos operativos, sino que también han fortalecido la capacidad de adaptación de las organizaciones a dinámicas de mercado complejas, incrementando su competitividad global.La implementación de algoritmos avanzados, como las redes de memoria a largo y corto plazo (LSTM) y las Máquinas de Soporte Vectorial (SVM), ha logrado niveles de precisión sin precedentes en la predicción de la demanda y la planificación de recursos. Sectores como el alimenticio, farmacéutico y manufacturero han adoptado estas herramientas con éxito, optimizando la trazabilidad, seguridad operativa y eficiencia en la distribución y producción. Sin embargo, se identificaron retos significativos, entre ellos, la calidad y disponibilidad de datos, los altos costos de implementación y la limitada oferta de talento especializado. Estos desafíos resaltan la importancia de promover estrategias para la formación técnica avanzada y la integración eficiente de ML en sistemas de gestión tradicionales. En futuras investigaciones, es fundamental explorar metodologías para escalar la implementación de ML en sectores diversos, considerando sus particularidades y objetivos estratégicos. Asimismo, se recomienda el desarrollo de estudios de caso prácticos en empresas que ya emplean estas tecnologías, evaluando su impacto desde perspectivas operativas y estratégicas. Finalmente, diseñar herramientas personalizadas para alinear las soluciones de ML con las metas organizacionales será crucial para maximizar su efectividad y sostenibilidad a largo plazo.

REFERENCIAS

[1] Duan G. & Dong J. (2024). Construction of Ensemble Learning Model for Home Appliance Demand Forecasting. *Applied Sciences (Switzerland)*, 14(17). doi: 10.3390/app14177658.

[2] Amellal, I., Amellal, A., Seghiouer, H. & Ech-Charrat, M. R. (2024). An integrated approach for modern supply chain management: Utilizing advanced machine learning models for sentiment analysis, demand forecasting, and probabilistic price prediction. *Decision Science Letters*, 13(1), 237–248. doi: 10.5267/j.dsl.2023.9.003.

[3] Sharabati A.-A. A., Awawdeh H. Z., Sabra S., Shehadeh H. K., Allahham M., & Ali A. (2024). The role of artificial intelligence on digital supply chain in industrial companies: Mediating effect of operational efficiency. Uncertain Supply Chain Management, 12(3), 1867–1878. doi: 10.5267/j.uscm.2024.2.016.

[4] Purwaningsih E. (2024). Utilizing blockchain technology in enhancing supply chain efficiency and export performance, and its implications on the financial performance of SMEs. *Uncertain Supply Chain Management*, 12(1), 449–460. doi: 10.5267/j.uscm.2023.9.007.

[5] El-Khchine R., Amar A., Guennoun Z. E., Bensouda C., & Laaroussi Y. (2018). Machine learning for supply chain's big data: State of the art and application to social networks' data. *MATEC Web of Conferences*. doi: 10.1051/matecconf/201820000015.

[6] Wang J. (2024). Machine Learning Applications in Biomass Supply Chain Management and Optimization. *Bioresources*, 19(4), 6961–6963. doi: 10.15376/biores.19.4.6961-6963.

[7] Es-satty A., Naimi M., Lemghari R., & Okar C. (2024). The interplay between machine learning techniques and supply chain performance: A structured content analysis. International Journal of Advanced Computer Science and Applications, 15(7), 194–203. doi: 10.14569/IJACSA.2024.0150719.

[8] Meghla T. I., Rahman M. M., Biswas A. A., Hossain J. T., & Khatun T. (2021). Supply Chain Management with Demand Forecasting of Covid-19 Vaccine using Blockchain and Machine Learning. *12th International Conference on Computing* Communication *and Networking Technologies (ICCCNT 2021)*. doi: 10.1109/ICCCNT51525.2021.9580006.

[9] Falkner D., Bögl M., Gattinger A., Stainko R., Zenisek J., & Affenzeller M. (2024). Integrating Machine Learning into Supply Chain Management: Challenges and Opportunities. *Procedia Computer Science*, 1779–1788. doi: 10.1016/j.procs.2024.01.176.

[10] Zimmermann R. & Brandtner P. (2024). From Data to Decisions: Optimizing Supply Chain Management with Machine Learning-Infused Dashboards. Procedia Computer Science, 955–964. doi: 10.1016/j.procs.2024.05.184.

[11] Bhatia S. & Albarrak A. S. (2023). A Blockchain-Driven Food Supply Chain Management Using QR Code and XAI-Faster RCNN Architecture. *Sustainability (Switzerland)*, 15(3). doi: 10.3390/su15032579.

[12] Borrero J. D. & Borrero-Domínguez J. D. (2023). Enhancing Short-Term Berry Yield Prediction for Small Growers Using a Novel Hybrid Machine Learning Model. *Horticulturae*, 9(5). doi: 10.3390/horticulturae9050549.

[13] Steinberg F., Burggräf P., Wagner J., Heinbach B., Saßmannshausen T., & Brintrup A. (2023). A novel machine learning model for predicting late supplier deliveries of low-volume-high-variety products with application in a German machinery industry. *Supply Chain Analytics*, 1. doi: 10.1016/j.sca.2023.100003.

[14] Huerta-Soto R., Francis F., Asís-López M., & Panduro-Ramirez J. (2023). Implementation of Machine Learning in Supply Chain Management process for Sustainable Development by Multiple Regression Analysis Approach (MRAA). *Evergreen*, 10(2). doi: 10.5109/6793671.

[15] Sayyad J., Attarde K., & Saadouli N. (2024). Optimizing e-commerce Supply Chains with Categorical Boosting: A Predictive Modeling Framework. *IEEE Access*, 1. doi: 10.1109/ACCESS.2024.3447756.

[16] Lin H., Lin J., & Wang F. (2022). An innovative machine learning model for supply chain management. *Journal of Innovation and Knowledge*, 7(4). doi: 10.1016/j.jik.2022.100276.

[17] Gong Z. (2024). Optimization of cross-border E-commerce (CBEC) supply chain management based on fuzzy logic and auction theory. *Scientific Reports*, 14(1). doi: 10.1038/s41598-024-64123-3.

[18] Xia Y., Xu T., Wei M. X., Wei Z. K., & Tang L. J. (2023). Predicting Chain's Manufacturing SME Credit Risk in Supply Chain Finance Based on Machine Learning Methods. *Sustainability (Switzerland)*, 15(2). doi: 10.3390/su15021087.

[19] García-Barrios D., Palomino K., García-Solano E., & Cuello-Quiroz A. (2021). A Machine Learning based Method for Managing Multiple Impulse Purchase Products: An Inventory Management Approach. *Journal of Engineering Science and Technology Review*, 14(1). doi: 10.25103/jestr.141.02.

[20] Rai R., Tiwari M. K., Ivanov D., & Dolgui A. (2021). Machine learning in manufacturing and industry 4.0 applications. International Journal of Production Research. doi: 10.1080/00207543.2021.1956675.

[21] Carrizo D. & Moller C. (2018). Estructuras metodológicas de revisiones sistemáticas de literatura en Ingeniería de Software: un estudio de mapeo sistemático. *Ingeniare. Revista chilena de ingeniería*, 26, 45–54. doi: 10.4067/S0718-33052018000500045.

[22] Urrútia G. & Bonfill X. (2010). Declaración PRISMA: una propuesta para mejorar la publicación de revisiones sistemáticas y metaanálisis. *Medicina Clínica (Barcelona)*, 135(11), 507–511. doi: 10.1016/j.medcli.2010.01.015.

[23] Moher D., et al. (2016). Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Revista Española de Nutrición Humana y Dietética*, 20(2), 148–160. doi: 10.1186/2046-4053-4-1/tables/4.

[24] Rubaszek, J., Ziemiá, M., Ribeiro, H., Valente, K., Santana, S., & Oliver, S. L. (2024). Natural environments in university campuses and students' well-being. *International Journal of Environmental Research and Public Health*, *21*(4), 413. doi: 10.3390/IJERPH21040413.

[25] Sani, S., Xia, H., Milisavljevic-Syed, J., & Salonitis, K. (2023). Supply Chain 4.0: A machine learning-based Bayesian-optimized LightGBM model for predicting supply chain risk. *Machines*, *11*(9). doi: 10.3390/machines11090888.

[26] Ben Elmir, W., Hemmak, A., & Senouci, B. (2023). Smart platform for data blood bank management: Forecasting demand in blood supply chain using machine learning. *Information (Switzerland)*, *14*(1). doi: 10.3390/info14010031.

[27] Aljohani, A. (2023). Predictive analytics and machine learning for real-time supply chain risk mitigation and agility. *Sustainability (Switzerland)*, *15*(20). doi: 10.3390/su152015088.

[28] Islam, S., & Amin, S. H. (2020). Prediction of probable backorder scenarios in the supply chain using distributed random forest and gradient boosting machine learning techniques. *Journal of Big Data*, *7*(1). doi: 10.1186/s40537-020-00345-2

[29] Singh, A. K., Simha, J. B., & Agarwal, R. (2024). Prediction of intermittent demand occurrence using machine learning. *EAI Endorsed Transactions on Internet of Things*, *10*. doi: 10.4108/eetiot.5381.

[30] Li, L. (2022). Predicting the investment risk in supply chain management using BPNN and machine learning. *Wireless Communications and Mobile Computing*, *2022*. doi: 10.1155/2022/4340286.

[31] Alzaman, C., Aljuneidi, T., & Li, Z. (2023). Predicting bike usage and optimizing operations at repair shops in bike-sharing systems. *IEEE Access*, *11*, 32534–32547. doi: 10.1109/ACCESS.2023.3250230.

[32] Kumar, I., Rawat, J., Mohd, N., & Husain, S. (2021). Opportunities of artificial intelligence and machine learning in the food industry. *Journal of Food Quality*, *2021*. doi: 10.1155/2021/4535567.

[33] Kumar, S., & Sharma, S. C. (2023). Integrated model for predicting supply chain risk through machine learning algorithms. *International Journal of Mathematical, Engineering and Management Sciences*, *8*(3), 353–373. doi: 10.33889/IJMEMS.2023.8.3.021.

[34] Biller, B., & Biller, S. (2023). Implementing digital twins that learn: AI and simulation are at the core. *Machines*, *11*(4). doi: 10.3390/machines11040425.

[35] Song, R., & Hu, H. (2023). Impact of green technology innovation based on IoT and industrial supply chain on the promotion of enterprise digital economy. *PeerJ Computer Science*, *9*. doi: 10.7717/peerj-cs.1416.

[36] Ghodake, S. P., Malkar, V. R., Santosh, K., Jabasheela, L., Abdufattokhov, S., & Gopi, A. (2024). Enhancing supply chain management efficiency: A data-driven approach using predictive analytics and machine learning algorithms. *International Journal of Advanced Computer Science and Applications*, *15*(4), 672–686. doi: 10.14569/IJACSA.2024.0150469.

[37] Udokwu, C., Zimmermann, R., Brandtner, P., & Obinwanne, T. (2023). Development of an ensemble modeling framework for data analytics in supply chain management. *Journal of Advances in Information Technology*, *14*(6), 1289–1300. doi: 10.12720/jait.14.6.1289-1300.

[38] Park, K. J. (2021). Determining the tiers of a supply chain using machine learning algorithms. *Symmetry (Basel)*, *13*(10). doi: 10.3390/sym13101934.

[39] Nassibi, N., Fasihuddin, H., & Hsairi, L. (2023). Demand forecasting models for the food industry by utilizing machine learning approaches. *International Journal of Advanced Computer Science and Applications*, *14*(3), 892–898. doi: 10.14569/IJACSA.2023.01403101.

[40] Bassiouni, M. M., Chakrabortty, R. K., Sallam, K. M., & Hussain, O. K. (2024). Deep learning approaches to identify order status in a complex supply chain. *Expert Systems with Applications*, *250*. doi: 10.1016/j.eswa.2024.123947.

[41] Afzal, M., Rahman, S., Singh, D. & Imran, A. (2024). Cross-sector application of machine learning in telecommunications: Enhancing customer retention through comparative analysis of ensemble methods. IEEE Access, 12, 115256–115267. doi: 10.1109/ACCESS.2024.3445281.

[42] Dong, Z., Liang, W., Liang, Y., Gao, W. & Lu, Y. (2022). Blockchained supply chain management based on IoT tracking and machine learning. *EURASIP Journal on Wireless Communications and Networking*, 2022(1). doi: 10.1186/s13638-022-02209-0.

[43] Dubey, R., et al. (2020). Big data analytics and artificial intelligence pathway to operational performance under the effects of entrepreneurial orientation and environmental dynamism: A study of manufacturing organisations. *International Journal of Production Economics*, 226. doi: 10.1016/j.ijpe.2019.107599.

[44] Helo, P. & Hao, Y. (2022). Artificial intelligence in operations management and supply chain management: An exploratory case study. *Production Planning and Control*, 33(16), 1573–1590. doi: 10.1080/09537287.2021.1882690.

[45] Nasseri, M., Falatouri, T., Brandtner, P. & Darbanian, F. (2023). Applying machine learning in retail demand prediction—A comparison of tree-based ensembles and long short-term memory-based deep learning. *Applied Sciences (Switzerland)*, 13(19). doi: 10.3390/app131911112.

[46] Debnath, B., Chattopadhyay, A. K. & Kumar, T. K. (2024). An economic optimization model of an e-waste supply chain network: Machine learned kinetic modelling for sustainable production. *Sustainability (Switzerland)*, 16(15). doi: 10.3390/su16156491.

[47] Zdravković, M., Panetto, H. & Weichhart, G. (2022). AI-enabled enterprise information systems for manufacturing. *Enterprise Information Systems*, 16(4), 668–720. doi: 10.1080/17517575.2021.1941275.

[48] Ahamed, N. N. & Karthikeyan, P. (2020). A reinforcement learning integrated in heuristic search method for self-driving vehicle using blockchain in supply chain management. *International Journal of Intelligent Networks*, 1, 92–101. doi: 10.1016/j.ijin.2020.09.001.

[49] Khedr, A. E., Alsahafi, Y. S. & Idrees, A. M. (2023). A proposed multi-level predictive WKM_ID3 algorithm, toward enhancing supply chain management in healthcare field. *IEEE Access*, 11, 125897–125908. doi: 10.1109/ACCESS.2023.3330691.

[50] Manoharan, H., Teekaraman, Y., Kuppusamy, R., Radhakrishnan, A. & Jabarulla, M. Y. (2021). A prognostic three-axis coordination model for supply chain regulation using machine learning algorithm. *Scientific Programming*, 2021. doi: 10.1155/2021/1894768.

[51] Deng, C. & Liu, Y. (2021). A deep learning-based inventory management and demand prediction optimization method for anomaly detection. *Wireless Communications and Mobile Computing*, 2021. doi: 10.1155/2021/9969357.

[52] Addou, K., El Ghoumari, M. Y., Achkdir, S. & Azzouazi, M. (2023). A decentralized model to ensure traceability and sustainability of the food supply chain by combining blockchain, IoT, and machine learning. *Mathematical Modeling and Computing*, 10(2), 498–510. doi: 10.23939/mmc2023.02.498.

[53] Wakle, S. P., Toshniwal, V. P., Jain, R., Soni, G. & Ramtiyal, B. (2024). A data-driven approach for planning stock keeping unit (SKU) in a steel supply chain. *International Journal of Mathematical, Engineering and Management Sciences*, 9(2), 283–304. doi: 10.33889/IJMEMS.2024.9.2.015.

[54] Abbas, K., Afaq, M., Khan, T. A. & Song, W.-C. (2020). A blockchain and machine learning-based drug supply chain management and recommendation system for smart pharmaceutical industry. *Electronics (Switzerland)*, 9(5). doi: 10.3390/electronics9050852.