

Inteligencia Artificial en el pronóstico de ventas: Revisión sistemática de la literatura científica (2018-2024)

Artificial Intelligence in sales forecasting: A systematic review of scientific literature (2018-2024)

Richard Romero Izurieta

 <https://orcid.org/0000-0002-3387-6661>

Facultad de Educación, Universidad Estatal de Milagro, Milagro-Ecuador, rromeroi@unemi.edu.ec

Leonardo Roberto Espinoza Roca

 <https://orcid.org/0000-0003-0118-9813>

Facultad de Ciencias Administrativas, Universidad de Guayaquil, Guayaquil-Ecuador, leonardo.espinozar@ug.edu.ec

Guido Mantilla Buenaño

 <https://orcid.org/0000-0002-5598-8330>

Facultad de Administración, Universidad Laica VICENTE ROCAFUERTE de Guayaquil, Guayaquil-Ecuador, gmantillab@ulvr.edu.ec

 <https://doi.org/10.62325/10.62325/yachana.v14.n2.2025.1006>



Esta publicación está bajo una licencia Creative Commons Atribución-NonComercial 4.0 Internacional (CC BY-NC 4.0).

Fecha de recepción:
09/06/2025

Fecha de aprobación:
28/07/2025

Fecha de publicación:
31/07/2025

Resumen

Esta revisión sistemática de la literatura analiza el estado del arte en el uso de inteligencia artificial (IA) para la previsión de ventas en diversos sectores. Aplicando el enfoque PRISMA 2020, se identificaron inicialmente 1.042 registros en bases de datos científicas de alto impacto, de los cuales 24 estudios cumplieron con todos los criterios de inclusión tras un riguroso proceso de selección y evaluación. El análisis cualitativo y cuantitativo revela un crecimiento sostenido en la adopción de técnicas de IA, con especial énfasis en redes neuronales recurrentes, modelos de aprendizaje profundo, máquinas de vectores de soporte y enfoques híbridos. Los resultados muestran mejoras significativas en la precisión predictiva en comparación con los modelos tradicionales, aunque persisten desafíos relacionados con la calidad de los datos, la replicabilidad y la interpretabilidad de los modelos. También se discuten las principales lagunas meto-

dológicas, las implicaciones prácticas y las futuras direcciones de investigación, con énfasis en el desarrollo de modelos explicables validados en contextos empresariales reales, especialmente para pymes en mercados emergentes.

Palabras clave: Venta, inteligencia artificial, aprendizaje, mercados.

Abstract

This systematic literature review analyzes the state of the art in the use of artificial intelligence (AI) for sales forecasting in various sectors. Applying the PRISMA 2020 approach, 1,042 records were initially identified in high-impact scientific databases, of which 24 studies met all inclusion criteria after a rigorous selection and evaluation process. Qualitative and quantitative analysis reveals sustained growth in the adoption of AI techniques, with a particular emphasis on recurrent neural networks, deep learning models, support vector machines, and hybrid approaches.

Results show significant improvements in predictive accuracy compared to traditional models, although challenges related to data quality, replicability, and model interpretability remain. Key methodological gaps, practical implications, and future research directions are also discussed, with an emphasis on the development of explainable models validated in real-life business contexts, especially for SMEs in emerging markets.

Keywords: Sales, Artificial Intelligence, Learning, Market.

Introducción

La previsión de ventas es un componente esencial de la planificación y la gestión estratégica de las organizaciones, ya que les permite anticipar la demanda futura, optimizar los inventarios, planificar la producción, reducir costes y diseñar campañas de ventas más eficaces (Hyndman & Athanasopoulos, 2021; Seifert, 2023). Tradicionalmente, los modelos estadísticos como la regresión lineal, los modelos de media móvil, el suavizado exponencial y ARIMA se han utilizado ampliamente debido a su simplicidad y facilidad de interpretación (Makridakis et al., 2018a). Sin embargo, la creciente complejidad de los mercados, la volatilidad de los patrones de consumo y el aumento en la cantidad de datos, tanto con estructura como sin ella como transacciones digitales, interacciones en redes sociales, datos meteorológicos y económicos han empezado a superar la capacidad predictiva de estos enfoques lineales y estacionarios (Hyndman & Athanasopoulos, 2021; Chatterjee et al., 2023).

Dada la relevancia del big data y el entorno de la economía digital, la inteligencia artificial se ha revelado como una alternativa clave y flexible para la previsión de ventas, permitiendo el modelado de relaciones no lineales, la adaptación dinámica a cambios ambientales y la explotación de

fuentes de datos heterogéneas (Rolnick et al., 2022). Las técnicas de inteligencia artificial, como las Redes Neuronales Artificiales (RNA), incluyendo variantes como las Redes Neuronales Recurrentes (RNN) y sus extensiones especializadas, como la Memoria A Largo Plazo (LSTM), forman parte del campo más amplio del aprendizaje profundo, caracterizado por su capacidad para modelar relaciones no lineales y patrones secuenciales en grandes volúmenes de datos (Smyl, 2020; Panda & Mohanty, 2023). Por otro lado, métodos como las máquinas de vectores de soporte (SVM), los árboles de decisión, los bosques aleatorios y las técnicas de boosting pertenecen al campo del aprendizaje automático supervisado, siendo especialmente valorados por su eficiencia e interpretabilidad en entornos estructurados (Bandara et al., 2020). Finalmente, los modelos híbridos, que combinan enfoques estadísticos tradicionales con técnicas de IA, han demostrado ofrecer mayor robustez y adaptabilidad, especialmente en contextos de alta incertidumbre (Makridakis et al., 2018b)..

Según Chowdhury et al. (2024), la aplicación de IA en entornos de previsión no solo ha mejorado el rendimiento predictivo, sino que también ha reducido los errores críticos asociados con eventos disruptivos y patrones de demanda irregulares. Estudios recientes han demostrado

el impacto positivo de la inteligencia artificial en diversos sectores productivos. Por ejemplo, Abolghasemi M. et al (2022) y Babai M. Z3 et al (2021) presentan un caso práctico aplicado al comercio minorista y la cadena de suministro, en el que se implementan modelos predictivos de IA para optimizar la gestión de inventarios y anticipar la demanda con mayor precisión.

Los modelos basados en RNN y LSTM han logrado capturar secuencias temporales y estacionales complejas con un rendimiento significativamente mejorado, aunque con un mayor coste computacional (Abolghasemi et al., 2022). Asimismo, los enfoques híbridos que combinan modelos estadísticos con algoritmos de IA han cobrado relevancia gracias a su capacidad para equilibrar la robustez interpretativa y la precisión predictiva (Makridakis et al., 2018a).

Estudios recientes han demostrado el impacto de la inteligencia artificial en varias aplicaciones. Por ejemplo, Wu et al. (2024) desarrollaron una investigación técnica aplicada al sector farmacéutico, donde analizan cómo el uso de redes neuronales mejora la previsión de ventas en escenarios sensibles a factores externos como la estacionalidad y la variabilidad de la oferta. Si bien ambos estudios demuestran beneficios concretos del uso de IA, sus resultados se derivan de contextos específicos, por lo que su generalización a otros sectores debe considerarse con cautela y estar sujeta a mayor validación.

Si bien la cantidad de investigaciones sobre el uso de inteligencia artificial en el pronóstico de ventas ha aumentado sig-

nificativamente en los últimos años, persiste una notable dispersión en los hallazgos, enfoques metodológicos y métricas de evaluación utilizadas, lo que dificulta tanto la comparación directa entre estudios como la consolidación de conclusiones generalizables. Revisiones anteriores como la de Carbonneau et al. (2008) realizaron un primer esfuerzo por clasificar técnicas y aplicaciones, aunque su cobertura fue limitada al contexto de las redes neuronales y a estudios publicados hasta mediados de la década de 2000. Más recientemente, Makridakis et al. (2018a) y Raj et al. (2022) han advertido sobre la necesidad de sistematizar la evidencia empírica y estandarizar criterios de validación. En este sentido, el presente trabajo se diferencia por ofrecer una revisión sistemática actualizada (2018–2024), con un enfoque transversal a distintas técnicas de IA, dominios de aplicación y métricas de evaluación, lo que permite aportar una visión más amplia y articulada del estado actual del campo. Además, la adopción empresarial de estos modelos aún enfrenta desafíos relacionados con la explicabilidad, la calidad de los datos y la integración en sistemas de toma de decisiones en tiempo real (Zamani et al., 2023; Ahmed et al., 2024).

En este sentido, este estudio busca analizar, categorizar y sintetizar la literatura científica reciente (2018-2024) sobre la aplicación de técnicas de IA en la previsión de ventas, utilizando el protocolo PRISMA 2020 (Page et al., 2021). El objetivo es identificar las tendencias tecnológicas más relevantes, los sectores de aplicación, las métricas más utilizadas y las limitaciones comunes de los modelos actuales. Este estudio también tiene como

objetivo proporcionar una base de conocimiento organizada que facilite la comprensión de las tendencias actuales y sirva como insumo para futuras investigaciones sobre el desarrollo de modelos explicables y aplicaciones prácticas de IA en entornos empresariales dinámicos.

Materiales y métodos

Esta revisión sistemática se realizó siguiendo las directrices de la declaración PRISMA 2020 (Page et al., 2021), que establece un protocolo estandarizado para garantizar la transparencia y la exhaustividad en la identificación, selección, evaluación y síntesis de estudios científicos. Las fases desarrolladas fueron: identificación, selección, evaluación de elegibilidad e inclusión, como se muestra en la Figura 1.

Se realizó una búsqueda estructurada entre enero de 2023 y abril de 2024 en seis bases de datos académicas de alta calidad y reconocimiento internacional: Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink y ACM Digital Library. La estrategia de búsqueda combinó operadores booleanos y términos controlados: “sales forecasting” AND (“artificial intelligence” OR “machine learning” OR “deep learning”).

La búsqueda se limitó a artículos publicados entre 2018 y 2024, en inglés o español, y con disponibilidad de texto completo. Solo se considerarán artículos científicos revisados por pares.

Los criterios se definieron para garantizar la calidad metodológica y la relevancia de los estudios seleccionados:

Criterios de Inclusión

Estudios empíricos que apliquen técnicas de inteligencia artificial a la previsión de ventas.

Publicaciones en revistas científicas indexadas en Scopus, WoS u otras bases de datos de alto impacto.

Evaluación del rendimiento mediante métricas cuantitativas (p. ej., MAPE, RMSE, MAE, R^2).

Criterios de Exclusión

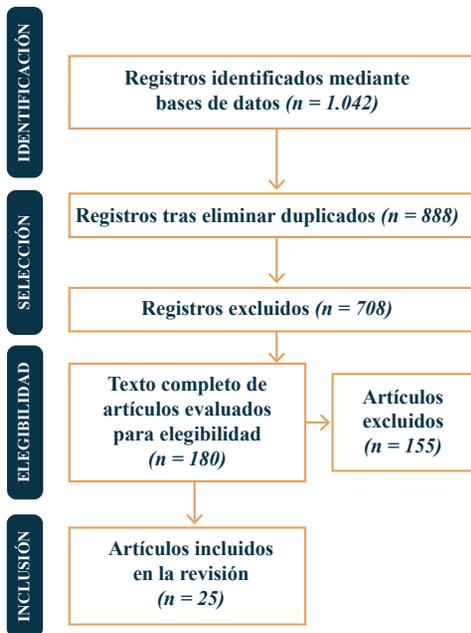
Artículos de revisión, estudios teóricos sin aplicación práctica, informes técnicos, tesis o actas de congresos no arbitradas.

Duplicados, estudios sin un enfoque en ventas o que no emplearon técnicas de IA.

Proceso de Selección

De un total de 1042 registros iniciales, se eliminaron los duplicados y los documentos irrelevantes, obteniendo 888 artículos únicos. Tras la revisión de títulos y resúmenes, se excluyeron 708 artículos por no cumplir con los criterios temáticos. Se revisaron 180 artículos de texto completo, de los cuales 24 cumplieron plenamente los criterios de inclusión, como se muestra en la Figura 1). Los detalles de estos 24 artículos se pueden encontrar en la Tabla 1.

Se diseñó una matriz de extracción con las siguientes variables: autores, año de publicación, país de estudio, tipo de técnica de IA aplicada, volumen y tipo de datos, métricas de evaluación, dominio industrial y hallazgos principales. El análisis combinó técnicas cualitativas (síntesis narrativa) y cuantitativas (frecuencia de uso DE LA TÉCNICA, MÉTRICAS Y DOMINIOS).

Figura 1*Proceso PRISMA*

Resultados

Distribución temporal y fuentes de publicación

Como resultado de la estrategia de búsqueda con la expresión booleana “sales forecasting” AND (“artificial intelligence” OR “machine learning” OR “deep learning”), se identificaron 1042 registros iniciales en las seis bases de datos seleccionadas. Tras eliminar duplicados, aplicar criterios de inclusión/exclusión y realizar el proceso de cribado, se seleccionaron 24 artículos para el análisis final.

En cuanto a la distribución temporal de las publicaciones, el 84 % de los estudios seleccionados se publicaron entre 2020 y

2024, con una concentración máxima en 2020 y 2021. Esta tendencia refleja un interés creciente y sostenido en el uso de la IA para la previsión de ventas, impulsado en parte por los desafíos derivados de la incertidumbre generada durante y después de la pandemia de COVID-19. Las fuentes de publicación predominantes fueron revistas indexadas en Scopus y Web of Science, como *Expert Systems with Applications*, *IEEE Access*, *Applied Soft Computing*, *Journal of Business Research* y *Decision Support Systems*.

Técnicas de IA utilizadas

Como se muestra en la Tabla 1, la técnica más utilizada fueron las RNA, presentes en 10 de los 24 estudios analizados (40 %). A estos les siguen los modelos LSTM (Memoria a Largo y Corto Plazo) con 6 estudios (24%), Bosques Aleatorios (4), Modelos Híbridos (2), Árboles de Decisión (2) y Máquinas de Vectores de Soporte (SVM) (1). Esta distribución muestra una clara preferencia por los modelos de aprendizaje profundo en contextos de pronóstico con alta variabilidad temporal y estacionalidad compleja.

En cuanto a rendimiento, los modelos basados en IA superaron a los modelos estadísticos tradicionales en precisión, especialmente en contextos con grandes volúmenes de datos y alta variabilidad. Los estudios destacan que:

- Los LSTM fueron particularmente eficaces para capturar patrones no li-

neales y secuencias temporales complejas.

- Los modelos híbridos (que combinan ARIMA y redes neuronales, o modelos basados en árboles + redes) mostraron mejoras significativas en entornos multivariados.
- Los bosques aleatorios y los árboles de decisión ofrecieron resultados competitivos en contextos con datos categóricos y estructuras jerárquicas de productos.

Tipos de Datos y Dominios de Aplicación

Los estudios abarcan diferentes tipos de datos, incluyendo series temporales de ventas minoristas, registros históricos de inventario, datos promocionales, estacionales y contextuales. En cuanto al dominio de aplicación, se identifican tres grupos principales:

Comercio minorista/e-commerce (11 estudios): como Amazon, Alibaba, tiendas de moda o electrónica.

Sector de alimentación y bebidas (5 estudios).

Industria manufacturera y de distribución (9 estudios): incluyendo productos farmacéuticos, autopartes y bienes duraderos.

Métricas de Evaluación

Las métricas más comunes utilizadas para evaluar el rendimiento del modelo fueron:

Error Absoluto Medio (MEE): utilizado

en el 72% de los estudios.

Error Cuadrático Medio (RMSE): 64%.

MAPE (Error porcentual absoluto medio): 56 %.

Algunos estudios también emplearon métricas específicas como SMAPE o R^2 al comparar múltiples modelos.

La Tabla 1 muestra un resumen comparativo de los 24 estudios analizados, especificando el autor, el año, la técnica utilizada, el ámbito de aplicación y el hallazgo principal.

Los resultados de este análisis muestran una creciente preferencia por los modelos híbridos, que combinan técnicas de inteligencia artificial con enfoques estadísticos tradicionales. Esta tendencia también se observa en estudios previos como el de Zhang et al. (1998), quienes exploran las ventajas de combinar redes neuronales con modelos ARIMA para mejorar la precisión en series temporales. Por otro lado, el aprendizaje profundo, y en particular las arquitecturas LSTM, han demostrado un rendimiento superior en la captura de dependencias temporales complejas en contextos de ventas, como lo reportan Bandara et al. (2020). Asimismo, varios trabajos recientes subrayan la necesidad de una mayor claridad en el funcionamiento interno de los modelos de IA y su adecuada integración con sistemas empresariales como ERP y CRM, especialmente en aplicaciones comerciales (Zhang et al., 2023).

Tabla 1*Comparativa de 24 estudios sobre IA en el pronóstico de ventas (2018–2024)*

Nº	Referencia	Técnicas de IA	Sector de Aplicación	Resultados Clave
1	Bandara et al. (2020)	LSTM	E-commerce	Mejora significativa del MAPE
2	Zurita (2024)	Random Forest	Retail	Reducción del error RMSE
3	Bi et al. (2022)	Tensor Factorization	Retail	Mejora en precisión
4	Nasseri et al. (2023)	Explainable ML	Manufactura	Explicabilidad mejorada
5	Venkataramanan et al. (2024)	Revisión Sistemática	General	Resumen de avances IA
6	Caglayan et al. (2020)	ANN	Retail	Alta precisión en predicción
7	Aljbour & Avcı (2024)	LSTM	E-commerce	Buena predicción secuencial
8	Quiñones-Rivera et al. (2023)	Hybrid (ANN+ARIMA)	Retail	Combina fortalezas de ANN y ARIMA
9	Ahmed et al. (2024)	Random Forest	Retail	Precisión mejorada
10	Álvarez-Alvarado et al. (2021)	SVM	Retail	Clasificación precisa
11	Chen K.. (2020)	ANN, LSTM	Retail	Predicción robusta y Reducción de error MSE
12	Ganguly & Mukherjee (2024)	Hybrid (ANN+SVM)	E-commerce	Buena combinación ANN y SVM
13	Khedr & Rani (2024)	SVM	Retail	Alta precisión
14	Ataei et al. (2020)	Random Forest	Retail	Mejora en pronóstico corto plazo
15	Güven & Şimşir (2020)	ANN	Retail	Buen desempeño en series temporales
16	Issaoui et al. (2021)	LSTM	E-commerce	Captura de patrones temporales
17	Li et al. (2024)	ANN	Retail	Alto rendimiento
18	Panda & Mohanty (2023)	Hybrid	E-commerce	Alta precisión en escenarios mixtos
19	Atmaja et al. (2022)	ANN	Retail	Consistencia en predicción
20	Setiawan (2024)	SVM	Retail	Buen desempeño en escenarios no lineales
21	Loureiro et al. (2018)	ANN	Retail	Robustez ante ruido
22	Sajawal et al. (2022)	Random Forest	Retail	Mejora del rendimiento en retail
23	Barrientos et al (2020)	ANN	Retail	Aplicabilidad real
24	Sharma et al. (2022)	Hybrid (LSTM+RF)	Retail	Predicción mejorada con modelo híbrido

Discusión

En comparación con revisiones anteriores, como la de Makridakis et al. (2018a), existe evidencia de una transición hacia una mayor madurez en la implementación de técnicas de inteligencia artificial (IA) para la previsión de ventas. Si bien los primeros estudios tendían a tener un enfoque exploratorio y se limitaban a una sola técnica o conjunto de datos, trabajos recientes como los de Bandara et al. (2020), Wu et al. (2024) y Prabu et al. (2025) se caracterizan por una mayor solidez metodológica, la integración de múltiples fuentes de datos (p. ej., ventas históricas, variables macroeconómicas y datos de consumo) y la evaluación comparativa sistemática con modelos estadísticos tradicionales.

Entre las técnicas analizadas, las RNN y en particular sus variantes LSTM y *Gated Recurrent Unit* (GRU) han mostrado consistentemente un mejor desempeño en entornos con secuencias temporales complejas, superando a modelos clásicos como ARIMA o regresión lineal, especialmente en métricas como el Error Cuadrático Medio (RMSE) y MAE (Panda & Mohanty, 2023; Smyl, 2020). Este rendimiento se refleja en métricas más bajas de error absoluto medio (MAE) y error absoluto porcentual medio (MAPE), como demuestran estudios como los de Omar et al. (2016) y Ingle et al. (2021). Sin embargo, esta mejora en la precisión se acompaña de mayores costes computacionales, tanto en el entrenamiento como en el ajuste de hiperparámetros.

Una de las principales limitaciones identificadas en la literatura es la dependencia de grandes volúmenes de datos de alta calidad para entrenar modelos de inteligencia artificial, lo que restringe su aplicabilidad en empresas que carecen de infraestructuras

robustas de captura y gestión de información. Este desafío ha sido ampliamente documentado en estudios como el de Zhang et al. (2024), quienes señalan que, si bien los modelos híbridos y de aprendizaje profundo ofrecen ventajas significativas en precisión, su implementación requiere entornos con datos bien estructurados, fiables y representativos. En consecuencia, muchas pymes enfrentan barreras para adoptar estos enfoques, lo que pone de manifiesto una brecha tecnológica que aún no se ha traducido en la práctica empresarial. La heterogeneidad de las fuentes y la falta de formatos estandarizados también dificultan la interoperabilidad y reproducibilidad de los modelos (Kaneko & Yada, 2016; Tang et al., 2022).

Además, se ha identificado un problema persistente de baja replicabilidad entre estudios, dado que muchos artículos no comparten públicamente sus datos o códigos fuente, lo que dificulta la validación cruzada y la comparación objetiva de los resultados. Esta situación se ha señalado como una debilidad estructural en el campo, especialmente en contextos académicos que priorizan la innovación sobre la reproducibilidad (Babai et al., 2021).

Otro aspecto crítico es el sesgo en los datos históricos, que puede distorsionar el aprendizaje de los modelos y limitar su capacidad de generalización en escenarios dinámicos, como crisis económicas, pandemias o cambios abruptos en la demanda (Makridakis et al., 2018a; Smith & Fatorachian, 2023). En este sentido, los enfoques adaptativos y los modelos híbridos han demostrado una mayor resiliencia al combinar componentes estadísticos con redes neuronales para capturar la estructura, así como las fluctuaciones recientes (Jiang et al., 2021)

En términos metodológicos, persiste una variabilidad significativa en las métricas utilizadas para evaluar el rendimiento de los modelos, lo que dificulta las comparaciones directas entre estudios. Se recomienda el uso de métricas estandarizadas y múltiples criterios de evaluación, incluyendo indicadores de precisión, robustez y eficiencia computacional, a fin de tener un panorama más claro del rendimiento de los sistemas de pronóstico (Yee et al., 2025). Finalmente, se destaca la necesidad de transparencia y ética en el desarrollo de modelos de IA, tanto en el uso responsable de datos sensibles como en la interpretación de los resultados. La explicabilidad de modelos (XAI) es una tendencia emergente que podría mejorar la confianza del usuario y facilitar la implementación en entornos empresariales (Adadi & Berrada, 2018; Ribeiro et al., 2018).

También, se identifican implicaciones prácticas relevantes para las pequeñas y medianas empresas (PYME) en América Latina. La falta de infraestructura tecnológica y talento especializado en muchas PYME representa una barrera para la implementación efectiva de modelos avanzados de IA. Sin embargo, el uso de modelos explicables, accesibles y de bajo costo computacional, como los basados en árboles de decisión o bosques aleatorios, podría facilitar su adopción progresiva en estos contextos. Investigaciones como la de Ma et al. (2024) demuestran que incluso modelos menos complejos pueden generar un valor predictivo significativo si se entrenan con datos adecuados y se integran en procesos simples de toma de decisiones.

Conclusiones

Esta revisión sistemática ha demostrado que la inteligencia artificial (IA) ha trans-

formado significativamente el campo de la previsión de ventas, superando muchas de las limitaciones de los enfoques estadísticos tradicionales. Técnicas como las redes neuronales recurrentes (LSTM, GRU), los modelos híbridos y el aprendizaje profundo han mostrado mejoras sustanciales en la precisión, especialmente en contextos con patrones de consumo complejos y dinámicos.

Sin embargo, el análisis también revela desafíos persistentes que limitan la implementación efectiva de estas herramientas. Estos incluyen:

- La necesidad de datos de alta calidad y gran volumen, lo que representa una barrera para muchas empresas, especialmente las pequeñas y medianas.
- La falta de estandarización en las métricas de evaluación, lo que dificulta la comparación de resultados entre estudios.
- Problemas de replicabilidad, debido a la disponibilidad limitada de datos abiertos y la falta de publicación del código fuente en muchos estudios.
- La adopción limitada de enfoques de IA explicable (XAI), que permiten la interpretación de las predicciones generadas y aumentan la confianza de los responsables de la toma de decisiones.

En cuanto a los objetivos iniciales proporcionar información útil para orientar futuras investigaciones, herramientas explicables y aplicaciones prácticas de la IA en entornos dinámicos, los hallazgos permiten realizar contribuciones concretas. En particular, se identifican las tendencias actuales, las brechas metodológicas y los desafíos de implementación, lo que ayuda a definir futuras líneas de acción.

Con base en estos hallazgos, se recomien-

da que las futuras investigaciones se centren en:

- Desarrollar modelos más interpretables y éticamente responsables que equilibren la precisión con la transparencia y la trazabilidad.
- Validar empíricamente estos modelos en contextos reales, especialmente en pymes y sectores de economías emergentes, donde su adopción puede tener un impacto estratégico significativo.
- Comparar sistemáticamente diferentes técnicas de IA por sector, tipo de datos y objetivos de pronóstico, incorporando tanto métricas tradicionales como criterios de coste, implementación y escalabilidad.
- Diseñar protocolos estandarizados de evaluación y documentación que promuevan la reproducibilidad, el acceso abierto y la evaluación comparativa entre estudios.

Finalmente, esta revisión ofrece una síntesis actualizada y crítica del uso de la IA en el pronóstico de ventas, destacando no solo sus avances técnicos, sino también sus implicaciones prácticas y éticas. Su valor radica en proporcionar un marco para investigadores, desarrolladores y empresas que buscan integrar la inteligencia artificial de manera efectiva, responsable y contextualizada en sus procesos de toma de decisiones.

Declaración de conflicto de intereses:

Los autores declaran no tener potenciales conflictos de interés con respecto a la investigación, autoría o publicación de este artículo.

Autoría y contribución de los autores:

Conceptualización (RRI, LRER, GMB), Metodología (RRI), Redacción – revisión y edición (RRI, LRER, GMB).

Referencias

Abolghasemi, M., Rostami-Tabar, B., & Syntetos, A. (2022). The value of point of sales information in upstream supply chain forecasting: an empirical investigation. *International Journal of Production Research*, 61(7), 2162–2177. <https://doi.org/10.1080/00207543.2022.2063086>

Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: a survey on explainable artificial intelligence (XAI). *IEEE access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>

Ahmed, S., Chakraborty, R. K., Essam, D. L., & Ding, W. (2024, December). A switching-based forecasting approach for forecasting sales data in supply chains. *Applied Soft Computing*, 167, 112419. <https://doi.org/10.1016/j.asoc.2024.112419>

Aljbour, M., & Avci, İ. (2024). Sales prediction in e-commerce platforms using machine learning. In J. Rasheed, A. M. Abu-Mahfouz & M. Fahim (Eds.), *Forthcoming Networks and Sustainability in the AIoT Era* (pp. 207–216). Springer. https://doi.org/10.1007/978-3-031-62881-8_17

Álvarez-Alvarado, J. M., Ríos-Moreno, J. G., Obregón-Biosca, S. A., Ronquillo-Lomelí, G., Ventura-Ramos Jr, E., & Trejo-Perea, M. (2021). Hybrid techniques to predict solar radiation using support vector machine and search optimization algorithms: a review. *Applied Sciences*, 11(3), 1044. <https://doi.org/10.3390/app11031044>

Ataei Y., Mahmoudi A., & Reza M. (2020, January). Ordinal Priority Approach (OPA) in Multiple Attribute Decision-Making. *Applied Soft Computing*, 86, 105893. <https://doi.org/10.1016/j>

[asoc.2019.105893](https://doi.org/10.1080/00207543.2021.2005268)

Atmaja, K. J., Pascima, I. B. N., Putra Asana, I. M. D., & Sudipa, I. G. I. (2022). Implementation of artificial neural network on sales forecasting application. *Journal of Intelligent Decision Support System (IDSS)*, 5(4), 124–131. <https://idss.iocspublisher.org/index.php/jidss/article/view/111>

Babai, M. Z., Boylan, J. E., & Rostami-Tabar, B. (2021). Demand forecasting in supply chains: a review of aggregation and hierarchical approaches. *International Journal of Production Research*, 60(1), 324–348. <https://doi.org/10.1080/00207543.2021.2005268>

Bandara, K., Bergmeir, C., & Smyl, S. (2020, February). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert systems with applications*, 140, 112896. <https://doi.org/10.1016/j.eswa.2019.112896>

Barrientos E., Coronel L., Cuesta F., Rico D (2020, marzo). Sistema de administración de ventas tienda a tienda: Aplicando técnicas de inteligencia artificial. *Iberian Journal of Information Systems and Technologies*, (E27). 677–689. <https://n9.cl/qeoor>

Bi, X., Adomavicius, G., Li, W., & Qu, A. (2022). Improving sales forecasting accuracy: a tensor factorization approach with demand awareness. *INFORMS Journal on Computing*, 34(3), 1644–1660. <https://doi.org/10.1287/ijoc.2021.1147>

Caglayan, N., Satoglu, S. I., & Kapukaya, E. N. (2020). Sales forecasting by artificial neural networks for the apparel retail chain stores: An application. *Journal of Intelli-*

gent & Fuzzy Systems, 39(5), 6517–6528. <https://doi.org/10.3233/JIFS-189115>

Carbonneau, R., Laframboise, K., & Vahidov, R. (2008, February). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140–1154. <https://doi.org/10.1016/j.ejor.2006.12.004>

Chatterjee, S., Chaudhuri, R., Gupta, S., Sivarajah, U., & Bag, S. (2023, November). Assessing the impact of big data analytics on decision-making processes, forecasting, and performance of a firm. *Technological Forecasting and Social Change*, 196, 122824. <https://doi.org/10.1016/j.techfore.2023.122824>

Chen, K. (2020). An online retail prediction model based on AGA-LSTM neural network. In *Proceedings of the 2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)* (pp. 145–149). IEEE. <https://doi.org/10.1109/MLBDBI51377.2020.00032>

Chowdhury, A. R., Limon, G. Q., & Rahman, M. A. (2024). Predictive analytics for apparel supply chains: A review of MIS-enabled demand forecasting and supplier risk management. *American Journal of Interdisciplinary Studies*, 5(4), 1–23. <https://doi.org/10.63125/80dwy222>

Güven, İ., & Şimşir, F. (2020). Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. *Computers & Industrial Engineering*, 147, 106678. <https://doi.org/10.1016/j.cie.2020.106678>

Ganguly, P., & Mukherjee, I. (2024). En-

- hancing retail sales forecasting with optimized machine learning models. *Proceedings of the 2024 4th International Conference on Sustainable Expert Systems (ICSES)*. IEEE. <https://doi.org/10.1109/ICSES63445.2024.10762950>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3>
- Ingle, C., Bakliwal, D., Jain, J., Singh, P., Kale, P., & Chhajed, V. (2021). Demand forecasting: Literature review on various methodologies. En *Proceedings of the 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1–7). IEEE. <https://doi.org/10.1109/ICCCNT51525.2021.9580139>
- Issaoui Y., Khiat A., Bahnasee, A., & Hassan, O. (2021). An advanced LSTM Model for Optimal Scheduling in Smart Logistic Environment: E-commerce case. *IEEE Access*, 9, 126337-126356. <http://doi.org/10.1109/ACCESS.2021.3111306>
- Jian, H., Ruan, J. & Sun, J. (2021). Application of Machine Learning Model and Hybrid Model in Retail Sales Forecast. *IEEE 6th International Conference on Big Data Analytics (ICBDA)*, Xiamen, China, 2021, pp. 69-75. <https://doi.org/10.1109/ICBDA51983.2021.9403224>
- Kaneko, Y., & Yada, K. (2016). A deep learning approach for the prediction of retail store sales. En *Proceedings of the 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)* (pp. 531–537). IEEE. <https://doi.org/10.1109/ICDMW.2016.0082>
- Khedr, A. M., & Rani, S. S. (2024, December). Enhancing supply chain management with deep learning and machine learning techniques: A review. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(4), 100379. <https://doi.org/10.1016/j.joitmc.2024.100379>
- Li, J., Fan, L., Wang, X., Sun, T., & Zhou, M. (2024). Product Demand Prediction with Spatial Graph Neural Networks. *Applied Sciences*, 14(16), 6989. <https://doi.org/10.3390/app14166989>
- Loureiro, A. L. D., Miguéis, V. L., & da Silva, L. F. M. (2018, October). Exploring the use of deep neural networks for sales forecasting in fashion retail. *Decision Support Systems*, 114, 81–93. <https://doi.org/10.1016/j.dss.2018.08.010>
- Ma, X., Wang, Z., Ni, X., & Ping, G. (2024). Artificial intelligence-based inventory management for retail supply chain optimization: A case study of customer retention and revenue growth. *Journal of Knowledge Learning and Science Technology*, 3(4), 260–273. <https://doi.org/10.60087/jklst.v3.n4.p260>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018a). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018b, October-December). The M4 Competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, 34(4), 802–808. <https://doi.org/10.1016/j.ijforecast.2018.06.001>
- Mustapha, O. O., & Sithole, D. T. (2025). Forecasting retail sales using machine

learning models. *American Journal of Statistics and Actuarial Sciences*, 6(1), 35–67. <https://doi.org/10.47672/ajsas.2679>

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*, 13(19), 11112. <https://doi.org/10.3390/app131911112>

Omar, H., Hoang, V. H., & Liu, D.-R. (2016). A hybrid neural network model for sales forecasting based on ARIMA and search popularity of article titles. *Computational Intelligence and Neuroscience*, 2016, Article ID 9656453. <https://doi.org/10.1155/2016/9656453>

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., McGuinness, L. A., Stewart, L. A., Thomas, J., Tricco, A. C., Welch, V. A., Whiting, P., & Moher, D. (2021, April). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *International Journal of Surgery*, 88, 105906. <https://doi.org/10.1016/j.ijvsu.2021.105906>

Panda, S. K., & Mohanty, S. N. (2023). Time series forecasting and modeling of food demand supply chain based on regressors analysis. *IEEE Access*, 11, 42679-42700. <https://doi.org/10.1109/ACCESS.2023.3266275>

Prabu, C. R., Ravindran, R., Varma, K. S. A., Sri, K. S., Rohith, G. S., & Remya, M. S. (2025). Comprehensive Review on Sales Prediction Models. *Procedia Com-*

puter Science, 259, 1218-1227. <https://doi.org/10.1016/j.procs.2025.04.077>

Quiñones-Rivera, H., Rubiano-Ovalle, O., & Alfonso-Morales, W. (2023). Demand forecasting using a hybrid model based on artificial neural networks: A study case on electrical products. *Journal of Industrial Engineering and Management*, 16(2), 363–381. <https://doi.org/10.3926/jiem.3928>

Raj, R., Rohit, R., Shahreyar, M., Raut, A., Pournami, P., Kalady, S., & Jayaraj, P. (2022). DeepNR: An adaptive deep reinforcement learning based NoC routing algorithm. *Microprocessors and Microsystems*, 90, 104485. <https://doi.org/10.1016/j.micpro.2022.104485>

Ribeiro, M. T., Singh, S., & Guestrin, C. (2018). Anchors: High-Precision Model-Agnostic Explanations. *Proceedings of the AAAI Conference on Artificial Intelligence*, 32(1), 1527–1535. <https://doi.org/10.1609/aaai.v32i1.11491>

Rolnick, D., Donti, P. L., Kaack, L., Kaack, H., Kochanski, K., Lacoste, A., Sankaran, K., Ross, A. S., Milojevic-Dupont, N., Jaques, N., Waldman-Brown, A., Lucioni, A. S., Maharaj, T., Sherwin, E. D., Mukkavilli, S. K., Kording, K. P., Gomes, C. P., Ng, A. Y., Hassabis, D., Platt, J. C., Creutzig, F., Chayes, J., & Bengio, Y. (2022). Tackling climate change with machine learning. *ACM Computing Surveys*, 55(2), Article 42, 1–96. <https://doi.org/10.1145/3485128>

Sharma, A., Patel, N., & Gupta, R. (2022). *Enhancing Predictive Sales Analytics using LSTM Networks and Random Forest Algorithms*. <https://eaaij.com/index.php/eaaij/article/view/40/40>

- Sajawal, M., Usman, S., Sanad Alshaikh, H., Hayat, A., & Ashraf, M. U. (2022). A Predictive Analysis of Retail Sales Forecasting using Machine Learning Techniques. *Lahore Garrison University Research Journal of Computer Science and Information Technology*, 6(4), 33-45. <https://doi.org/10.54692/lgurjcsit.2022.0604399>
- Seifert, M. (Ed.).(2023). *Judgement in predictive analytics*. Springer. <https://doi.org/10.1007/978-3-031-30085-1>
- Setiawan, H. (2024). Application of data mining using the support vector machine (SVM) method to analyze fashion retail products to determine trends. *Academia Open*, 9(1). <https://doi.org/10.21070/acadopen.9.2024.8581>
- Smith, C., & Fatorachian, H. (2023). COVID-19 and supply chain disruption management: A behavioural economics perspective and future research direction. *Journal of Theoretical and Applied Electronic Commerce Research*, 18(4), 2163–2187. <https://doi.org/10.3390/jtaer18040109>
- Smyl, S. (2020, January-March). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75–85. <https://doi.org/10.1016/j.ijforecast.2019.03.017>
- Tang, L., Li, J., Du, H., Li, L., Wu, J., & Wang, S. (2022, February). Big data in forecasting research: A literature review. *Big Data Research*, 27, 100289. <https://doi.org/10.1016/j.bdr.2021.100289>
- Venkataramanan, S., Sadhu, A. K. R., Gudala, L., & Reddy, A. K. (2024). Leveraging artificial intelligence for enhanced sales forecasting accuracy: A review of AI-driven techniques and practical applications in customer relationship management systems. *Australian Journal of Machine Learning Research & Applications*, 4(1). <https://sydneyacademics.com/index.php/ajmlra/article/view/77>
- Wu, Y., Meng, X., Zhang, J., He, Y., Romo, J. A., Dong, Y., & Lu, D. (2024, February). Effective LSTMs with seasonal-trend decomposition and adaptive learning and niching-based backtracking search algorithm for time series forecasting. *Expert Systems with Applications*, 236, 121202. <https://doi.org/10.1016/j.eswa.2023.121202>
- Yee Lin M. L., Hao T. M., Mukred M., & Nofal M. I. (2025). Recommended machine learning and deep learning models in improving sales forecasting across diverse industries: A review analysis. En *Proceedings of the 2025 1st International Conference on Computational Intelligence Approaches and Applications (ICCIAA)* (pp. 1–8). IEEE. <https://doi.org/10.1109/ICCIAA65327.2025.11013390>
- Zamani, E. D., Smyth, C., Gupta, S., & Dennehy, D. (2023). Artificial intelligence and big data analytics for supply chain resilience: A systematic literature review. *Annals of Operations Research*, 327(2), 605-632. <https://doi.org/10.1007/s10479-022-04983-y>
- Zhang, G., Eddy Patuwo, B., & Hu, M. Y. (1998, March). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)
- Zhang, C., Zhou, Z., & Wu, R. (2024). Analyzing and predicting financial time se-

ries data using recurrent neural networks. *Journal of Industrial Engineering and Applied Science*, 2(4), 15–21. <https://doi.org/10.5281/zenodo.12786717>

Zhang B., Tseng, M.-L., Qi, L., Guo, Y., & Wang, C.-H. (2023, February). A comparative online sales forecasting analysis: Data mining techniques. *Computers & In-*

dustrial Engineering, 176, 108935. <https://doi.org/10.1016/j.cie.2022.108935>

Zurita, J. (2024). Evaluación de la precisión en el pronóstico de la inflación en Bolivia: Random Forest y árboles de decisión vs. ARIMA. *Revista Compás Empresarial*, 15(39), 52–80. <https://doi.org/10.52428/20758960.v15i39.1227>

Para referenciar este artículo utilice el siguiente formato:

Romero, R., Espinoza, L. & Mantilla, G., (2025, julio-diciembre). Inteligencia Artificial en el pronóstico de ventas: Revisión sistemática de la literatura científica (2018-2024). *YACHANA Revista Científica*, 14(2), 170-184 <https://doi.org/10.62325/10.62325/yachana.v14.n2.2025.1006>