

# Aplicación de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras.

## Application of Artificial Intelligence–Based Predictive Models for Financial Decision-Making

Mauren Javier Gamboa Mojica<sup>1</sup>

<sup>1</sup>Finance and Management UIS, Escuela de Estudios Industriales y Empresariales., Universidad Industrial de Santander, Colombia. Email: mauren2200393@correo.uis.edu.co

RECIBIDO: Mes dd, aaaa. ACEPTADO: Mes dd, aaaa. VERSIÓN FINAL: Mes dd, aaaa

### RESUMEN

La toma de decisiones financieras en entornos caracterizados por alta incertidumbre y rapidez constituye un desafío central para los sistemas económicos actuales. En este contexto, los modelos predictivos basados en inteligencia artificial se han consolidado como herramientas relevantes para el análisis, pronóstico y apoyo a la toma de decisiones en distintos segmentos financieros. Este estudio presenta un estado del arte cuyo objetivo es identificar los beneficios del uso de dichos modelos, así como los principales segmentos financieros abordados, los horizontes de predicción y los tipos de decisiones que respaldan. La literatura analizada evidencia tres grandes tipos de decisiones financieras: inversión, gestión del riesgo y apoyo estratégico. Asimismo, se identifican tres grupos predominantes de modelos predictivos: aprendizaje automático, redes neuronales profundas y modelos enriquecidos o híbridos, destacándose estos últimos por su mayor desempeño. Los resultados muestran que los modelos basados en inteligencia artificial mejoran la precisión de los pronósticos y fortalecen la toma de decisiones financieras. No obstante, también se evidencian limitaciones asociadas a la calidad y disponibilidad de los datos, la complejidad de los modelos y los desafíos en términos de interpretabilidad y generalización. En consecuencia, se resalta la necesidad de continuar desarrollando enfoques más robustos, específicos y explicables para su aplicación efectiva en diversos contextos financieros.

**PALABRAS CLAVE:** Inteligencia artificial, modelos predictivos, toma de decisiones financieras

### ABSTRACT

Financial decision-making in environments characterized by high uncertainty and rapid dynamics represents a central challenge for contemporary economic systems. In this context, artificial intelligence–based predictive models have become key tools for analysis, forecasting, and decision support across different financial segments. This study presents a state-of-the-art review aimed at identifying the benefits of using artificial intelligence–based predictive models for financial decision-making, as well as the main financial segments addressed, prediction horizons, and types of decisions they support. The reviewed literature highlights three major categories of financial decisions: investment, risk management, and strategic support. In addition, three predominant groups of predictive models are identified: machine learning models, deep neural networks, and enriched or hybrid models, with the latter standing out due to their superior performance. The findings indicate that artificial intelligence–based predictive models enhance forecasting accuracy and strengthen financial decision-making processes. However, the literature also reveals limitations related to data availability and quality, model complexity, and challenges associated with interpretability and result generalization. Consequently, there is a need for continued research focused on developing more robust, context-specific, and explainable approaches to enable the effective application of these models across diverse financial settings.

**KEYWORDS:** Artificial intelligence, predictive models, financial decision-making

## 1. INTRODUCCIÓN

La inteligencia artificial ha sido un tema de interés en los últimos años debido a la amplia gama de soluciones que puede generar a múltiples industrias, llegando incluso a entornos científicos, empresariales y gubernamentales. El término inteligencia artificial fue popularizado en la década de 1950 con la conferencia de Dartmouth, siendo esta una pieza clave en su desarrollo (Russel & Norvig, 2021).

Hoy, 75 años después, se está experimentando un auge en su uso e implementación gracias a la capacidad que esta posee, basándose en instrucciones adecuadas, para generar herramientas que potencien la productividad en las organizaciones y que permitan tomar decisiones más acertadas y lógicas. El año 2022 fue crucial para el desarrollo de la inteligencia artificial, su presencia estaba enfocada en asistentes virtuales como Siri, sistemas de reconocimiento facial, de recomendación y entre otros.

El lanzamiento de ChatGPT -3.5 en noviembre de 2022 marcó un antes y después para la inteligencia artificial, esta evolucionó, dejando de ser una herramienta exclusiva de grandes industrias y abriendo las puertas a usuarios de menor tamaño. En la actualidad es posible encontrar múltiples casos de estudio, revisiones literarias y artículos científicos que revelan y desarrollan las diferentes aplicaciones de la IA relacionadas a modelos predictivos en diversas áreas como logística, política, finanzas, entre otras; que otorgan una visión de los beneficios y las barreras de implementación que surgen de la inteligencia artificial.

La inteligencia artificial permitió que las personas encargadas de realizar modelos predictivos pudieran dejar a un lado una cantidad muy limitada de conexiones entre variables abriendo paso a un análisis más amplio de los datos base, estos modelos basados en IA tienen un objetivo similar a los anteriores a esta tecnología, encontrar conexiones entre variables, la principal diferencia radica en la cantidad de variables que pueden relacionar, teniendo la capacidad de analizar volúmenes masivos de datos y creando algoritmos más elaborados e incluso adaptativos, potenciando una base de conocimiento creada por seres humanos y multiplicándola con el fin de generar un análisis más desarrollado, algunos de los modelos actuales son versiones mejoradas de los ya creados por seres humanos y otros fueron desarrollados netamente después de esta tecnología.

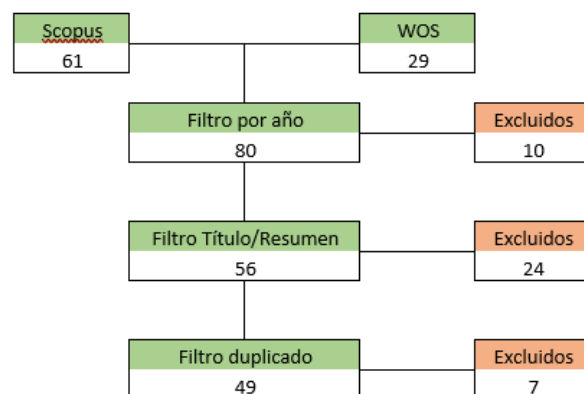
En Colombia, la inteligencia artificial juega un papel importante en los análisis predictivos que se pueden hacer, las decisiones financieras no son tomadas únicamente por grandes corporaciones, estos modelos

ayudan a descifrar lo que podría llegar a suceder, por ejemplo, con los mercados de futuros de materias primas como el maíz, minerales preciosos como el oro o especulaciones en precios de acciones de la bolsa de valores Colombiana, todas estas son opciones que abren un mundo de posibilidades para el uso correcto de la información, aprovechando la variedad de soluciones que la inteligencia artificial puede ofrecer si se le da un uso técnico y profesional para tomar decisiones de impacto positivo en las organizaciones.

Para evaluar la producción científica sobre los modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras se realizó una búsqueda en dos bases de datos (Scopus y Web of Science). Para esto se construyeron dos ecuaciones de búsqueda, teniendo en cuenta términos clave como: Artificial Intelligence, machine learning, Deep learning, predictive models, forecasting models, prediction algorithms, financial forecasting, investment analysis, financial decision making, en idioma inglés, con el objetivo de abarcar un grupo más amplio de contenido científico debido al uso generalizado de este idioma en el entorno mencionado.

Con los documentos ya recopilados se procede a realizar un filtro de artículos para incluir únicamente los de año 2021 hasta la actualidad, es necesario también excluir los documentos que, aunque tengan presencia de las palabras claves utilizadas en la ecuación de búsqueda no tienen relación con el objetivo de la investigación que se realiza y, por último, revisando sus títulos y resúmenes, se eliminaron los artículos duplicados. La **Figura 1** recopila el resultado de este proceso, con 49 artículos.

**Figura 1:** Metodología PRISMA



## 2. RESULTADOS

### 2.1. Análisis bibliométrico

## 2.2. Análisis de resultados

Es esta sección donde se realiza la exploración de las temáticas revisadas bajo los criterios de selección, inclusión y exclusión de este estudio. Entre los 49 artículos revisados fueron identificados puntos importantes a resaltar relacionados con el segmento financiero donde fue aplicado el modelo predictivo y el tipo de decisión en la que se veía involucrado.

El objetivo de este análisis es dar a conocer el estado de la literatura actual y revisar su posible tendencia a futuro junto con sus oportunidades de mejora en el proceso de integración de esta clase de modelos predictivos en los mercados financieros, se busca documentar el alcance de los estudios y su influencia en la toma de decisiones, así como también las diferentes clases de modelos que existen, sus casos de aplicación y variaciones.

### 2.2.1. Tipos de modelos predictivos basados en inteligencia artificial

En el contexto actual es extremadamente relevante abordar las problemáticas asociadas a la predicción de variables financieras mediante el uso de inteligencia artificial, en la literatura estudiada existen diversos tipos de modelos predictivos que están fuertemente diferenciados principalmente por su arquitectura empleada y la forma de procesamiento que ejecutan sobre su información financiera de entrada, que destaca por su volatilidad y dependencia temporal.

El enfoque de los modelos predictivos estudiados en la revisión de literatura no es único, estos se agrupan en categorías diseñadas para basar su atención en diferentes comportamientos, como dinámicas de precio, rendimientos o volatilidad, el origen de esta diversidad es consecuencia de la complejidad con la que los mercados financieros operan y la necesidad de adaptar esos modelos a esas estructuras de datos evolutivas y dispersas.

Las redes neuronales artificiales tradicionales, usadas como modeladores de relaciones entre conjuntos de datos y variables financieras complejas son ampliamente aplicadas en estudios iniciales para predicción bursátil y sigue vigentes en la literatura científica como una línea base para evaluar mejoras en desempeños predictivos, especialmente cuando se integran variables más complejas o indicadores de precios históricos (Dash et al, 2023).

Por otro lado, otro gran tipo de modelo predictivo definido fueron los relacionados con aprendizaje automático que destacan por no depender de arquitecturas neuronales profundas y aun así mostrar un desempeño sólido en la predicción financiera. Cuando se trabajan grandes volúmenes o conjuntos de datos y se requiere un balance entre precisión y eficiencia, estos

modelos mencionados anteriormente son los utilizados, lo que explica la adopción de estos para predicciones financieras y múltiples contextos financieros.

Dentro de este grupo se destaca el uso de algoritmos de ensamble y árboles de decisión como Random Forest, XGBoost y LightGBM que permiten analizar relaciones no lineales entre variables macroeconómicas. En la literatura estudiada son utilizados para la predicción de inflaciones en economías emergentes, facilitando la integración de múltiples fuentes, como variables macroeconómicas, indicadores monetarios e incluso reservas internacionales, mejorado la capacidad predictiva frente a métodos tradicionales (Aruleba et al., 2023).

Son ampliamente utilizados en la predicción de comportamientos dentro de los mercados bursátiles en horizontes de corto plazo, llegando a intradías, donde la rapidez de cálculo es fundamental para lograr resultados determinantes. En este sector estos algoritmos son eficaces para identificar patrones en precios de activos usando como pilar datos históricos.

Es importante mencionar que una línea de este grupo de modelos pertenece a aquellos que incorporan enfoques explicables y equitativos, para aplicaciones financieras de carácter sensible.

Específicamente diseñadas por ejemplo para gestiones del riesgo crediticio, donde el valor se construye no solo con la predicción si no también con la capacidad del modelo para justificar y explicar los resultados finales. Estudios como el de Mirza et al. (2021) emplean esta clase de modelos para la predicción del riesgo, resaltando soluciones que incorporan análisis de variables relevantes fortaleciendo la transparencia del análisis.

Estudios como el de Acharya et al. (2024), enfatizan la necesidad de emplear principios de explicabilidad a los modelos, para la evaluación financiera, principalmente cuando las decisiones automatizadas pueden tener consecuencias económicas y sociales importantes, el enfoque deja de ser el resultado y empieza a ser el proceso para llegar al resultado, el autor propone uso de modelos de ensamble avanzados sumados a técnicas de interpretabilidad, con el objetivo de analizar la influencia de variables sobre resultados.

Estos enfoques refuerzan al papel de los modelos predictivos basados en inteligencia artificial como componentes clave en la toma de decisiones financieras informadas.

Los modelos híbridos se consolidan como el enfoque predominante dentro de la literatura estudiada, evidenciando una clara tendencia hacia la predicción y el modelado con técnicas que integran múltiples modelos para un resultado final. Estos surgen como respuesta directa a las limitaciones individuales observadas en las

categorías superiores, de aprendizaje automático o de redes neuronales profundas, particularmente frente a la tarea de predecir variables no lineales, no estacionarias y altamente volátiles al interior de los mercados financieros.

Una línea corresponde a los modelos que integran múltiples arquitecturas de aprendizaje profundo con técnicas estadísticas y de procesamiento de señales, que permiten capturar de manera simultánea patrones temporales y comportamientos sospechosos. En esta línea, Zhang et al. (2025) propone, por ejemplo, un modelo híbrido que combina árboles de decisiones, aprendizaje automático, con un algoritmo metaheurístico de optimización, teniendo como resultado final una mejora significativa en la predicción del índice bursátil coreano estudiado.

Existen enfoques híbridos que integran redes neuronales profundas con modelos econométricos tradicionales, orientados a predecir volatilidad. En esta línea de estudios, Wei et al. (2022) combina modelos GARCH con LSTM. Los primeros poseen una alta capacidad para modelar la volatilidad que se quería predecir y los segundos para capturar las dependencias temporales de largo plazo. Cuando los modelos se enfrentan a escenarios de alta incertidumbre, esta clase de técnicas demuestran ser más efectivas en conjunto que individualmente.

Los modelos predictivos híbridos que combinan estructuras de redes neuronales profundas que cumplen funciones complementarias dentro del proceso predictivo se ven evidenciados también, investigaciones como la de Forzap et al. (2025) donde se desarrolla un modelo híbrido LSTM-CNN que combina indicadores financieros temporales que pueden identificar patrones tanto de largo plazo como de corto plazo, siendo esta una ventaja sustancial ya que el horizonte de predicción se vuelve variable.

Combinar grafos con redes neuronales recurrentes amplía la capacidad del modelo para hallar relaciones dentro de los conjuntos de datos y representarlas. Zhang et al (2025) integra redes convolucionales sobre grafos con LSMT, permitiendo una simultaneidad dinámica de los precios y una generación de relaciones estructurarles sobre los activos financieros estudiados.

Estos estudios de carácter integrados, como los presentados por Vitale et al. (2020) y Bai et al. (2021), refuerzan la evidencia de que el rendimiento y los indicadores de error de los modelos híbridos, pueden superar los indicadores de sus competidores individuales, la diversidad de combinaciones que se encuentran dentro de la literatura analizada confirma que hibridar

algoritmos es una buena práctica que representa una estrategia central en la evolución de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras.

Un grupo menos numeroso pero relevante dentro de la literatura analizada corresponde a los modelos enriquecidos, se diferencian de los enfoques superiores por la acción de incorporar información adicional o procesos avanzados de transformación que ayudan a ampliar el contexto con el que trabaja el modelo predictivo. Surgen como respuesta a la necesidad de incorporar factores externos que alteran las predicciones e influyen en el comportamiento de los mercados financieros, factores que no pueden ser representados únicamente en los números de datos históricos.

El enriquecimiento se logra a través de la integración de variables externas como análisis de sentimientos, indicadores compuestos o información contextual del mercado, que después se procesan con técnicas de transformación de datos de entrada, destacando el análisis de componentes. Los modelos predictivos se ven beneficiados con esta información ya que amplían el contexto con el que trabajan, traducándose a una mejor estabilidad y capacidad predictiva del modelo. En general, estos modelos aportan una perspectiva complementaria que amplía aún más los resultados predictivos y recuerda la importancia de procesar conocimiento externo en el análisis de los sistemas financieros.

### **2.2.2. Horizontes de predicción en modelos basados en inteligencia artificial**

El horizonte de predicción es extremadamente importante porque constituye un eje central en el análisis de modelos predictivos basados en inteligencia artificial para la toma de decisiones, determina no solo un marco temporal de acción, sino también la naturaleza de los datos con que son alimentados, la arquitectura necesaria de los modelos para procesarlos y la velocidad de mecanismos de validación para poder comprobar sus resultados finales.

La predominancia es clara dentro de la literatura estudiada, corresponde a horizontes de corto plazo, que enfrentan entornos financieros de volatilidad altísima, no estacionarios y sensibles a eventos externos en algunos casos no controlables.

Este enfoque se observa de manera fuerte en estudios orientados a la predicción diaria de volatilidad, siendo el objetivo principal capturar fluctuaciones inmediatas en el ámbito del riesgo financiero. En este contexto Kim et al

(2022) propone un modelo híbrido GARCH-LSTM con una estrategia que busca manipular la distribución que poseen el conjunto de datos de entrada enfocado principalmente en predecir la volatilidad del índice S&P500. Justifican su uso basándose en el argumento de que la variable volatilidad es altamente latente y muy dependiente de información reciente, lo que limita la efectividad de estos modelos si se ajustaran a medianos o largos plazos, mediante restricciones de intervalos de tiempo. El argumento en este caso se basa en que la información textual de los sitios consultados se ve reflejada en un impacto inmediato en el mercado, pero que, de nuevo, se diluye en función del tiempo.

El uso de horizontes de muy corto plazo cuando se analizan variables financieras caracterizadas por alta sensibilidad a factores externos tiene como ejemplo representativo el trabajo de Kanzari et al. (2023) quien desarrolla un modelo basado en redes LSTM que predicen inestabilidad macro financiera en el mercado estadounidense en un plazo de una semana, en este estudio se utiliza como variable de entrada información histórica de estrés financiero junto con varios índices de

En la **tabla 1** es posible visualizar los tipos de horizontes de predicción identificados en la literatura, junto con su descripción y autores correspondientes.

**Tabla 1:** Horizontes de predicción en modelos

| Horizonte de predicción | Características principales  | Autores   |
|-------------------------|--|---|
| <b>Intradía</b>         | Modelos orientados a capturar dinámicas de muy corto plazo, microestructura del mercado y reacción inmediata a noticias y sentimiento.                         | Kılıç et al. (2023); Khalil et al. (2022); Nguyen et al. (2024)   |
| <b>Corto</b>            | Predicción de uno a pocos días, enfocada en precios, volatilidad, dirección del mercado y señales de inversión. Es el horizonte predominante en la literatura. | Nagdiya et al. (2024); de Almeida et al. (2021); de Almeida et al. (2021); Amiri et al. (2025); Koo et al. (2022); Yang et al. (2023); Liu et al. (2024); Li et al. (2024); Lin et al. (2024); Giri et al. (2025); Kanzari et al. (2023); Jin (2023); Chung et al. (2023); Xu et al. (2023); Pokou et al. (2024); Sarikoç et al. (2025); Pabuccu et al. (2024); Zhang et al. (2025); Kim (2025); Chahuán-Jiménez (2024); Goodell et al. (2023); Pitta de Jesus et al. (2025); Fozap (2025); Barua et al. (2023); Wei-Jie Chen et al. (2023); Syriopoulos et al. (2021); Yongjie Zhang et al. (2021); Safari et al. (2025) |
| <b>Mediano</b>          | Horizontes semanales o mensuales, utilizados para análisis de tendencia, riesgo agregado y apoyo estratégico.  | Kuryłek (2024); Wei et al. (2024); Mirza et al. (2024); Vitale et al. (2025); Choi et al. (2024)  |
| <b>Largo</b>            | Predicciones estructurales asociadas a quiebra financiera, estabilidad sistémica y planificación estratégica.  | Yu-Cheng Lin et al. (2025); Aljawazneh et al. (2021); Fozap (2025)  |
| <b>Multihorizonte</b>   | Estudios que evalúan simultáneamente varios horizontes para analizar robustez y estabilidad del desempeño predictivo.  | Khattak et al. (2023); Behera et al. (2024); Bao et al. (2025); Praveen et al. (2025); Dash et al. (2023); Vitale et al. (2025)   |

### 2.2.3. Tipos de decisiones financieras

Corresponde al tema más relevante dentro de todo el estudio, la toma de decisiones financieras apoyadas de modelos predictivos basados en inteligencia artificial ya está claro que el diseño del modelo y sus resultados dependen directamente de lo que se desee analizar, no obstante, modelos diseñados con diferentes arquitecturas pueden apoyar a una clase de decisión en común. Dentro de la selección final de 49 artículos, es posible observar tendencias clave en relación a los tipos de decisiones que estos modelos predictivos apoyan. En la literatura se distinguen tres enfoques fuertes de decisión que responden a naturalezas diferentes dentro de los mercados financieros.

El apoyo a decisiones de inversión constituye el eje predominante al interior de la literatura estudiada, evidenciando que la mayoría de los modelos predictivos generados se desarrollan con el objetivo de predecir movimientos de mercado, precios o rendimientos, para obtener beneficios económicos.

La comparación entre varios modelos y su hibridación es una práctica común con el fin de generar diferentes escenarios y evaluarlos mediante los indicadores de error; la razón por la cual estos modelos son tan estudiados es debido a que pueden responder a los entornos de alta volatilidad y liquidez como las criptomonedas o las acciones, permiten identificar dependencias no lineales que modelos tradicionales no podrían procesar e incluso ser enriquecidos mediante datos externos como noticias, dando paso a una capacidad de procesamiento extra que resulta en operaciones con horizontes de predicción excesivamente bajos, aprovechando el comportamiento reactivo de los mercados.

Los modelos híbridos propuestos por Nagdiya et al (2024) desarrollados para Bitcoin y Ethereum demuestra mejoras significativas en las precisiones de pronósticos a corto plazo, convirtiéndose en herramientas de uso cotidiano para decisiones directas de inversión. De igual manera, Amiri et al (2025) aplica enfoques híbridos GCN-LSTM específicamente para acciones del sector energético altamente correlacionadas, al ser todas de una misma clase, este modelo optimizó las decisiones de inversión teniendo en cuenta las interrelaciones de mercado de los activos analizados.

Enfoques mayormente enriquecidos como Liu et al (2024) incorporan información exógena con el objetivo de ampliar el contexto de operación de los modelos predictivos, al hacer esto, los movimientos de la variable o activo analizado poseen más explicabilidad, gracias a esta clase de enriquecimiento Mirza et al (2024) pudo

mejorar la predicción de inflación, integrando las reservas internacionales de monedas. Incluso en mercados alternativos como NFTs o commodities, los estudios de Giri et al (2025) y Vitale et al (2025) confirman que los modelos que utilizan arquitecturas de redes neuronales profundas para superar enfoques tradicionales, al capturar dinámicas particulares, especulativas y estacionales, relevantes para los inversionistas.

Jesus et al. (2025) constituye un ejemplo representativo de la influencia de los modelos predictivos basados en inteligencia artificial sobre la toma de decisiones financieras orientadas al uso eficiente del capital, analizaron el mercado accionario, específicamente el índice Ibovespa, integrando como variables indicadores financieros técnicos enriquecidos con noticias financieras reales y textos generados con LLMs como ChatGPT.

El objetivo principal de esto no fue únicamente minimizar el error de predicción, sino adelantarse a identificar las tendencias futuras que permitan al inversionista anticiparse a los movimientos de mercado en horizontes de corto plazo.

Fozap (2025) se orienta a fortalecer la capacidad predictiva de los inversionistas haciendo uso de modelos híbridos de redes neuronales profundas aplicadas al S&P500. El objetivo central del trabajo es entregar una base cuantitativa sólida que sirva como insumo para la toma de decisiones mediano y largo plazo, para esto, integraron redes LSTM (útiles en capturar dependencias temporales de largo plazo) con redes CNN, especializadas en la detección de patrones locales, enfrentándolo a los tradicionales ARIMA Y SVM, esta combinación predice precios con mayor robustez.

La verdadera representación de esa mejora está en la toma de decisiones de inversión más informadas, específicamente en movimientos de entrada y permanencia, utilizar prácticas tradicionales como medias móviles, Bollinger Bands, RSI y la habilidad técnica de los operadores combinada con esta herramienta extra contribuye a reducir la incertidumbre y generar estrategias de decisión más consistentes frente a cambios estructurales del mercado.

Chahuán et al. (2024) evalúa el uso de múltiples modelos de redes neuronales profundas para predecir el índice S&P500, un indicador clave que sirve como insumo para las decisiones financieras. El trabajo compara modelos LSTM, CNN, ANN y RNN, contra indicadores de error RMSE, MAPE y precisiones direccionales, configurando este último como criterio relevante para inversionistas ya que el enfoque más allá del error está en predecir la dirección de mercado.

En este caso, algunos modelos presentan menos errores que otros, pero las CNN ofrecen la mayor capacidad para predecir la tendencia de mercado, lo cual es fundamental en operaciones de compra y venta de activos financieros. Dash et al (2023) realiza una contribución clave al analizar el sentimiento del inversor, este se extrae mediante técnicas de aprendizaje automático y se integra como herramienta de soporte para la formulación de estrategias en el mercado accionario indio, la particularidad con este estudio se basa en que a diferencia de estudios netamente predictivos orientados a operaciones inmediatas y direcciones de mercado, este adopta un enfoque netamente estratégico al sintetizar evidencias empíricas de que el sentimiento de los inversores, derivada de múltiples fuentes de información económica, influye de manera sistemática en el precio de las acciones.

El enriquecimiento de estos modelos con datos de sentimiento abre la posibilidad a disminuir el horizonte de predicción y generar un tiempo de reacción menor a los cambios inesperados del mercado, reforzando que el análisis de sentimiento juega un papel crucial como insumo de refuerzo a las herramientas ya creadas más que como mecanismo estratégico de trading tradicional, como las bollinger bands mencionadas anteriormente.

El segundo tipo de decisiones que apoyan los modelos predictivos basados en inteligencia artificial revisaron en la literatura son las relacionadas con gestión del riesgo, caracterizadas por estar en entornos de alta volatilidad, incertidumbre y dependencias a la complejidad estructural del mercado.

Las orientadas a inversiones buscan maximizar el rendimiento esperado mientras que los estudios enfocados en gestión del riesgo tienen como objetivo principal la identificación temprana de escenarios complejos, la reducción de exposición al riesgo y el fortalecimiento de la adaptabilidad o resiliencia financiera a los agentes económicos.

La tendencia de los modelos predictivos en estos casos es actuar como herramientas para anticipar episodios de volatilidad extrema, quiebras empresariales, inestabilidad sistémica permitiendo a los usuarios finales tomar decisiones más prudentes y sobre todo más fundamentadas, este último aspecto siendo completado con mejoras en aplicabilidad de los resultados, reflejando la necesidad de no solo mejorar la precisión predictiva sino justificar las decisiones que se tomen en estos entornos.

El estudio de Koo et al. (2022) aborda la predicción de la volatilidad como variable clave para la medición y control del riesgo financiero. Los autores construyen un modelo GARCH con redes LSTM, integrando también una estrategia de manipulación de distribución llamada

Volume-Up, esta última característica es relevante ya que las ocasiones con volatilidades extremas, aunque pocos frecuentes, son las que generan más pérdida potenciales a futuro.

La aplicación de estos modelos representa mejoras significativas en las métricas como RMSE, específicamente en regiones apartadas de la distribución, hecho que refuerza más la capacidad de estos para anticipar casos particulares y episodios de estrés financieros.

La gestión del riesgo en la predicción de quiebra empresarial la trabaja Lin et al. (2025) estudiando modelos de redes neuronales profundas que apoyaran la toma de decisiones preventivas de alto impacto. Los autores abordan el riesgo de insolvencia económica mediante una arquitectura CNN, transformando ratios financieros en representaciones tipo imagen a través de Gramian Angular Field (GAF), permitiendo capturar patrones temporales complejos asociados al deterioro financiero, el objetivo de este modelo no es maximizar retornos, sino anticipar escenarios de quiebra en un horizonte de predicción de 1 a 3 años, para instituciones financieras, inversionistas institucionales y reguladores, en este caso la integración de las dos tecnologías mencionadas anteriormente mejora significativamente al hallar los ratios financieros que contribuyen más al riesgo de quiebra y tener como resultado final la calificación de solvencia o insolvencia de una empresa.

Aruleba et al (2024) aborda modelos predictivos basados en inteligencia artificial, específicamente de aprendizaje automático, que apoyan decisiones financieras críticas relacionadas con la evaluación y mitigación de riesgo crediticio. En su artículo, la variable a predecir es el incumplimiento crediticio, una tarea clave para todas las organizaciones financieras que se dediquen a prestar dinero a particulares; a partir de modelos como Random Forest, AdaBoost, XGBoost, LightGBM, es importante mencionar que combinas técnicas de balanceo de clases llamadas SMOTE-ENN, esta integración mejora el desempeño predictivo y genera como valor agregado una interpretación de los factores que influyen en el resultado calificación de riesgo.

Desde la perspectiva de toma de decisiones aporta evidencias concretas y con explicaciones para la aprobación, rechazo o re ajuste de condiciones, reduciendo el sesgo que posean los analistas financieros y aumentando la transparencia del proceso de decisión.

A diferencia de los estudios previos de gestión del riesgo, que priorizan el desempeño predictivo mediante modelos de aprendizaje automático híbridos para generar una reducción en clasificación a préstamos morosos o riesgo de quiebra, Acharya et al (2024) introduce un cambio



conceptual relevante en las decisiones de gestión del riesgo, el autor integra explícitamente criterios de equidad y explicabilidad al proceso de modelado, mientras que las investigaciones anteriores se enfocan en identificar variables clave y mejorar la interpretabilidad, el autor enriqueció su modelo al incorporar restricciones “fairness” directamente en el entrenamiento del modelo.

La diferencia es importante desde el análisis de decisiones financieras, mitigar el riesgo sistémico al evitar que los propios algoritmos generen sesgos, por ejemplo, discriminatorios con implicaciones legales y reputacionales para las organizaciones.

El tercer tipo de decisión más apoyada en la literatura estudiada son los modelos orientados al apoyo estratégico. A diferencia de los modelos centrados en inversión directa o gestión explícita del riesgo, estos estudios se centran en crear herramientas de soporte para la toma de decisiones financieras y estrategias corporativas.

En esta sección los modelos dejan de lado el enfoque predictivo y tienden a mejorar la calidad de la información disponible para el decisor humano. Por ejemplo, en los trabajos de Almeida et al. (2021) se emplean arquitecturas híbridas para apoyar la gestión de flujos en instituciones financieras, mientras que khattak et al. (2023) y Bao et al (2025) sistematizan y comparan múltiples enfoques de IA para generar modelos más robustos que apoyen la toma de decisiones en mercados complejos, de manera simultánea estudios como Lin et al. (2024) y Kurylek (2024) evidencian como estos modelos se adaptan a segmentos muy específicos como el biotecnológico o el análisis de utilidades empresariales, y aportan estabilidad y soporte analítico en los momentos cruciales de alta incertidumbre.


#### 2.2.4. Segmentos financieros

Es extremadamente importante la discusión frente a los segmentos financieros debido a que, gracias a esta, es posible identificar las áreas en donde se aplica con mayor frecuencia la integración de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras, también es importante explorar qué tan relevantes son los segmentos financieros donde más se aplican, para analizar si guardan relación con las tendencias actuales.

La revisión de literatura realizada es posible encontrar como cada estudio está relacionado con un mercado financiero específico y con un activo específico de ese mercado financiero, esto genera una categorización en la aplicación de estos modelos. De los 49 artículos revisados se puede notar que hay modelos predictivos

aplicados a criptomonedas, mercados accionarios, índices financieros, Forex, ETFs, es claro que hay categorías que sobresalen mucho más que las demás, esto se puede apreciar en la **Figura 5**, la literatura tiene un enfoque alto en las predicciones aplicadas a mercados accionarios, criptomonedas y macroeconomía.

**Figura 5:** Segmentos financieros



Aunque el segmento de mercados accionarios es el que posee mayor proporción de estudios, es necesario aclarar que hay subdivisiones.

Lin et al (2024) aplica modelos híbridos basados en intervalos para el mercado accionario enfocado en biotecnología, usando como insumo el índice biotecnológico de Taiwán durante un periodo de pandemia, este enfoque permitió combinar los precios históricos junto con el volumen de lógica difusa, logrando como resultado una predicción de incertidumbre y su comportamiento en tiempos de altas fluctuaciones, en su caso debido a las crisis sanitarias.

De forma complementaria, Li et al (2024) abordó el mercado accionario chino, pero desde una perspectiva multisectorial, analizando sectores como el ferroviario, energía y banca, utilizando como insumo para sus modelos precios históricos y enriqueciéndolos con información textual de noticias, comentarios de expertos y datos pandémicos, este caso es particular porque más allá de tomar en cuenta precios históricos de un mercado accionario, analiza a la par el contexto actual de una emergencia, incluyendo análisis de sentimientos e información externa.

En el caso de Hafiz et al (2024), su enfoque se basa en el mercado accionario, siguiendo índices bursátiles como es NASDAQ, enfrentando como problema principal la predicción direccional en horizontes de corto plazo bajo restricciones como la alta eficiencia del mercado y los cambios estructurales dados en entornos de pandemia, el autor hace énfasis en el uso de redes neuronales

profundas que puedan equilibrar complejidad con desempeño apoyadas de seguimiento de indicadores técnicos derivados de precios históricos y volúmenes accionarios, que son coherentes con las decisiones de inversión y trading estratégico que realizan las personas.

En contraste, Amiri et al. (2023) su mercado accionario específico corresponde al sector energético donde el activo analizado se basa en empresas que tienen interrelación, el segmento en este caso se caracteriza por las relaciones estructurales que surgen entre activos, esto indica que la predicción se basa en la comprensión de dependencias y riesgos sistémicos que pueden afectar a un sector específico del mercado accionario, demostrando que aunque las decisiones se toman dentro de un mercado accionario, las variables de entrada están sujetas al segmento específico y al tipo de decisión que se pretende apoyar.

En la literatura también se encuentran autores como Zhang et al. (2025) que abordan acciones del mercado chino, específicamente las que componen el SSE50 enriqueciendo la predicción agregando la atención del inversor, mediante noticias y Baidu Index, un motor de búsqueda chino, a sus modelos LSTM teniendo como resultado una mejora significativa en la predicción del movimiento diario de precios del SSE50 frente a modelos que solo consideran precios históricos, liquidez y volumen de mercado.

Este resultado se vuelve más relevante si se usa en mercados compuestos por inversionistas minoristas, donde el comportamiento colectivo sí tiene alta influencia sobre el precio de las acciones.

Jie et al. (2023) se enfoca en la predicción de volatilidad de índices bursátiles interrelacionados, proponiendo un modelo de red neuronal profunda que se apoya de características temporales, al contrario de Zhang, este se enfoca en la transformación de retornos históricos en vectores densos que permiten capturar de una mejor forma los movimientos de esos mercados financieros.

Aunque ambos artículos están enfocados en mercados accionarios, usan técnicas, indicadores y enriquecimientos diferentes para mejorar sus predicciones.

Existen otros artículos cuyo segmento no es mercado accionario, el estudio de Aruleba et al (2024) es un caso particular dentro de la literatura estudiada, es relevante al demostrar que los modelos de aprendizaje automático pueden superar las limitaciones clásicas de datos desbalanceados e integrar las exigencias regulatorias de interpretabilidad, aunque el resultado final es importante,

el proceso para llegar a este es necesario para manejar el riesgo de crédito.

Los autores analizan dos conjuntos de datos que son utilizados normalmente para este segmento y proponen un marco basado en un modelo de aprendizaje automático, específicamente comparando Random Forest, AdaBoost, XGBoost y LightGBM, apoyándose de técnicas de balanceo, teniendo como resultado una mejora sustancial en métricas de riesgo críticas como recall y especificidad.

En el segmento de finanzas internacionales, el estudio desarrollado por Mirza et al (2024) aborda el problema de predicción de inflación en economías emergentes, integrando modelos de aprendizaje automático con variables macro financieras que no son tan relevantes, como las reservas internacionales de divisas.

Logran demostrar que, a diferencia de los modelos econométricos tradicionales, algoritmos como Random Forest y Gradient Boosting analiza y predice de forma más efectiva las relaciones no lineales y la complejidad de la dinámica inflacionaria. El uso de un indicador como las reservas internacionales de divisas marcó una gran diferencia ya que mejoró significativamente la precisión predictiva, actuando como un amortiguador frente a las dinámicas políticas externas, volatilidades cambiarias y presiones externas.

Este análisis de segmentos financieros evidencia que la aplicación de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras se encuentra fuertemente influenciada por las particulares inherentes a cada mercado.

El mercado accionario y el de criptomonedas concentran la mayor cantidad de estudios, consecuencia de la inmediatez de la información histórica, alta frecuencia de datos y relevancia directa para decisiones de inversión, lo que crea un ambiente propicio para la adopción de modelos avanzados basados en inteligencia artificial, cuyas mejoras, incluso mínimas, pueden representar millones de dólares en ganancias.

Los estudios enfocados en macroeconomía y estabildades financieras se aplican a horizontes de predicción más largos y requieren en ciertos casos, más allá de un resultado numérico, una explicabilidad en su proceso de análisis para generar respuestas a los clientes finales.

En segmentos como el riesgo crediticio, commodities y activos reales, también se evidencia el uso de técnicas explicables como consecuencia la necesidad de interpretabilidad y cumplimiento regulatorio.

No existe un modelo universalmente superior, la efectividad de los enfoques basados en inteligencia artificial dependen directamente de las variables que definan, del tipo de mercado que se quiera analizar e incluso del activo, siempre será necesaria una selección metodológica adecuada para sacar el mayor provecho del resultado final generado por el modelo predictivo.

## 2.3. Documentación de beneficios y oportunidades de mejora

### 2.3.1. Beneficios

A lo largo de este trabajo, se analizaron las conclusiones de cada artículo de investigación; sin embargo, esta sección consolida y profundiza en los beneficios más relevantes derivados de la aplicación de modelos predictivos basados en inteligencia artificial en la toma de decisiones financieras, con el objetivo de ofrecer una visión crítica, integral y equilibrada de su impacto real en los diferentes mercados y segmentos financieros.

La literatura estudiada en esta investigación muestra que estos beneficios no se limitan a mejoras cuantitativas en las métricas de rendimiento, sino que implican transformaciones estructurales en la forma en que se concibe, evalúa y ejecuta la toma de decisiones financieras, tanto a nivel macroeconómico y microeconómico como sectorial y de mercado.

Uno de los beneficios más claramente identificables es la mejora sustancial en la precisión, robustez y estabilidad de las previsiones financieras, especialmente cuando los modelos incorporan variables expandidas que superan los enfoques tradicionales.

En este sentido, Mirza et al. (2024) demuestra que la integración de las reservas internacionales como variable explicativa y enriquecida en los modelos de aprendizaje automático mejora significativamente la capacidad predictiva de la inflación en las economías emergentes.

Este resultado destaca que la inteligencia artificial no solo optimiza el proceso de estimación, sino que también permite redefinir el conjunto de variables relevantes para la toma de decisiones de política monetaria, ampliando el contexto en el que opera el modelo y reduciendo la incertidumbre asociada a decisiones críticas con graves consecuencias, como las tasas de interés.

Además, varios estudios demuestran que los modelos predictivos basados en inteligencia artificial ofrecen importantes beneficios al permitir la anticipación de escenarios macro financieros adversos, lo cual es

especialmente relevante en contextos de alta volatilidad e incertidumbre estructural.

Kanzari et al. (2023) muestran que la incorporación de variables de sentimiento del consumidor, productor e inversor en los modelos LSTM actúa como un importante indicador adelantado de inestabilidad sistémica, superando consistentemente a los modelos basados exclusivamente en datos financieros históricos.

Este beneficio es especialmente importante desde la perspectiva de la supervisión, ya que permite identificar señales tempranas de estrés financiero antes de que se materialicen plenamente en los mercados, lo que otorga a los responsables políticos mayor flexibilidad para implementar medidas preventivas.

Otro beneficio ampliamente documentado en la literatura se refiere a la capacidad de los modelos de inteligencia artificial para transformar grandes volúmenes de datos en información procesable, facilitando la toma de decisiones en contextos organizacionales y de mercado.

En el ámbito del marketing financiero y la adopción de tecnología, Bai (2024) demuestra que los modelos de aprendizaje automático pueden identificar perfiles de consumidores con alta probabilidad de adoptar servicios de asesoría automatizada (robo-advisory), optimizando las estrategias de adquisición, segmentación y diseño de productos financieros.

Este beneficio refleja cómo la inteligencia artificial contribuye a reducir la asimetría de información entre las instituciones financieras y los usuarios, permitiendo decisiones comerciales y estratégicas más eficientes.

Además, en sectores con uso intensivo de capital y caracterizados por dinámicas altamente cíclicas, la aplicación de modelos predictivos basados en inteligencia artificial ofrece beneficios asociados a una mejor representación de la realidad económica subyacente.

Syriopoulos et al. (2021) demuestra que el uso de la Regresión de Vectores de Soporte (SVR) en la previsión de precios de buques permite una captura más precisa de la ciclicidad del mercado marítimo en comparación con los modelos econométricos tradicionales. Este beneficio es particularmente relevante para las decisiones de financiamiento e inversión en activos reales, donde una mejor comprensión de los ciclos del mercado ayuda a reducir el riesgo asociado a las inversiones de largo plazo y mejorar la asignación eficiente de recursos en sectores estratégicos.

La literatura revisada destaca importantes beneficios relacionados con la optimización de la gestión de carteras, en concreto, el rendimiento ajustado al riesgo y la mejora de los procesos de asignación de activos. Barua et al. (2023) demuestra que la integración de señales de sentimiento, como los indicadores de miedo y codicia, en modelos de optimización híbridos basados en el enfoque Black-Litterman permite superar estrategias clásicas como la varianza mínima y la paridad de riesgo.

Este hallazgo sugiere que la inteligencia artificial no solo mejora la estimación de la rentabilidad esperada, sino que también incorpora dimensiones comportamentales que reflejan con mayor precisión el comportamiento real de los mercados financieros, lo que fortalece la toma de decisiones en contextos de incertidumbre.

Además, varios estudios coinciden en que una de las ventajas más relevantes de estos modelos es su flexibilidad para adaptarse a diferentes horizontes temporales y niveles de decisión.

La capacidad de los modelos de aprendizaje automático para operar en contextos de corto, medio y largo plazo amplía significativamente su aplicabilidad, permitiendo su uso en decisiones tácticas, operativas y estratégicas.

Esta versatilidad es especialmente valiosa en entornos financieros dinámicos, donde los responsables de la toma de decisiones deben evaluar múltiples escenarios simultáneamente y responder con rapidez a las condiciones cambiantes del mercado.

En conjunto, los beneficios identificados en la literatura evidencian que la aplicación de modelos predictivos basados en inteligencia artificial no se limita a la mejora de la precisión técnica de los pronósticos, sino que transforma de manera profunda la toma de decisiones financieras. Estos modelos permiten integrar información diversa, anticipar escenarios críticos, capturar dinámicas no lineales, optimizar la asignación de recursos y reducir la incertidumbre asociada a decisiones complejas.

### 2.3.2. Limitaciones y oportunidades de mejora

Aunque los avances en modelos predictivos basados en inteligencia artificial son significativos, estos presentan un conjunto relevante de limitaciones y brechas que tienen que ser analizadas de manera crítica. No invalidan los resultados que generan los modelos propuestos, pero sí limitan si alcance, aplicabilidad y capacidad de transferencia a contextos reales de decisión financiera, en este sentido es necesario comprender estos desafíos que enfrentan.

Una de las principales limitaciones identificadas es la generalización de los modelos, ya que una proporción considerable de los estudios se desarrollan para mercados, activos, sectores o países específicos. Este enfoque contextual implica que los resultados obtenidos no siempre pueden extrapolarse a otros entornos financieros con diferentes estructuras regulatorias, niveles de liquidez o dinámicas macroeconómicas.

En consecuencia, la validez externa de muchos modelos es limitada, especialmente al intentar aplicar un enfoque desarrollado en mercados desarrollados a economías emergentes, o viceversa. Esta dependencia contextual resalta la necesidad de validar los modelos en múltiples escenarios y bajo diferentes regímenes de mercado.

Otra brecha significativa se relaciona con la excesiva dependencia de los datos históricos, una característica común de muchos modelos de aprendizaje automático y aprendizaje profundo, aunque realmente es una dependencia de cualquier modelo que busque predecir algo, realizar un buen tratamiento de datos puede evitar esta limitación.

Si bien estos enfoques parecen muy eficaces para capturar patrones pasados, su rendimiento puede verse significativamente afectado ante cambios estructurales abruptos, crisis financieras, eventos geopolíticos o episodios de alta incertidumbre. Estos escenarios, los supuestos implícitos de estabilidad temporal y la repetición de patrones históricos han demostrado ser insuficientes, lo que limita la capacidad de los modelos para adaptarse a las nuevas dinámicas del mercado.

Desde un punto de vista operativo, muchos modelos avanzados también presentan una alta complejidad computacional y de implementación, especialmente aquellos que combinan redes neuronales profundas, modelos híbridos y técnicas de optimización. Estos enfoques suelen requerir infraestructuras computacionales robustas, largos tiempos de entrenamiento y complejos procesos de ajuste, lo que dificulta su adopción práctica en entornos financieros reales, especialmente en organizaciones con limitaciones tecnológicas o de recursos humanos.

Otra limitación crítica reside en la falta de una validación económica realista de los modelos propuestos. Una parte significativa de los estudios prioriza las métricas estadísticas tradicionales, como los errores de pronóstico, sin incorporar evaluaciones económicas exhaustivas que incluyan los costos de transacción, la liquidez del mercado, las restricciones operativas o simulaciones comerciales realistas. Esta brecha crea una desconexión entre el buen rendimiento estadístico del modelo y su

utilidad práctica para la toma de decisiones financieras en contextos reales.

Además, persisten problemas de interpretabilidad y transparencia, especialmente en los modelos de aprendizaje profundo que operan como sistemas de "caja negra". A pesar de los avances en técnicas de inteligencia artificial explicables, la dificultad para comprender cómo y por qué un modelo genera ciertas predicciones limita su aceptación en entornos financieros regulados y reduce la confianza de los responsables de la toma de decisiones. Este aspecto es particularmente crítico en aplicaciones como la gestión de riesgos, la predicción de quiebras y la asignación de crédito.

La sensibilidad a la calidad, disponibilidad y frecuencia de los datos constituye otra brecha importante que limita, por ejemplo, los horizontes de predicción. Muchos modelos se basan en grandes volúmenes de datos limpios, equilibrados y actualizados, lo que no siempre es viable en mercados emergentes o contextos donde los datos presentan retrasos, ruido o problemas de consistencia. Esta dependencia refuerza la necesidad de estrategias robustas de preprocesamiento, validación y gestión de datos.

Finalmente, varios enfoques presentan supuestos metodológicos restrictivos, como el uso de distribuciones específicas, ventanas temporales rígidas o estructuras lineales-no lineales predefinidas. Si bien estos supuestos son útiles para simplificar el modelado, pueden limitar la capacidad de los modelos para capturar interdependencias dinámicas complejas y comportamientos inesperados del mercado.

### 3. CONCLUSIONES Y RECOMENDACIONES

Realizado el análisis de esta revisión se presentan las principales conclusiones resultantes de este ejercicio, evidenciando como en cada una de estas se llevó a cabo el cumplimiento de los objetivos planteados al principio de la investigación.

La revisión sistemática de la literatura proporcionó una caracterización clara de la aplicación de modelos predictivos basados en inteligencia artificial en la toma de decisiones financieras. Mediante un análisis estructurado de la literatura científica, fue posible identificar las principales tendencias metodológicas, los segmentos financieros más abordados y los tipos de decisiones con mayor frecuencia en la investigación.

Además, la clasificación de modelos, algoritmos y horizontes de pronóstico proporciona una visión general clara y organizada del estado actual del conocimiento, así como la identificación de beneficios, limitaciones y

brechas que permiten o reafirman tanto los avances logrados como los desafíos que aún persisten en la aplicación práctica de estas metodologías.

El análisis bibliométrico permite localizar y refinar la literatura relevante mediante la consulta de bases de datos científicas especializadas como Scopus y WOS, siguiendo un proceso de selección sistemático se garantizó una muestra de artículos que representara la necesidad de los.

Este análisis reveló la evolución temporal de la investigación, as. Asimismo, hemos identificado patrones en la distribución geográfica de la producción científica, lo que refleja un creciente interés global en el uso de técnicas avanzadas de aprendizaje automático y aprendizaje profundo en contextos financieros cada vez más complejos y volátiles.

Reveló los principales segmentos financieros en los que se aplican modelos predictivos basados en inteligencia artificial, incluyendo el mercado bursátil, las criptomonedas, la macroeconomía, la gestión de carteras, el riesgo financiero y los activos reales. Esta diversidad de aplicaciones demuestra la versatilidad de ambos modelos y su capacidad para adaptarse a diferentes contextos de toma de decisiones.

Además, la clasificación de los tipos de decisiones financieras reveló que, si bien predominan las relacionadas con la inversión, la gestión de riesgos y el apoyo estratégico, también están surgiendo decisiones menos comunes, aunque relevantes, como la política monetaria, la adopción de tecnologías financieras, la estabilidad sistémica y la optimización de carteras, lo que amplía el alcance de aplicación de estas herramientas.

En relación con la caracterización de dos modelos predictivos, se observó un claro predominio de enfoques basados en aprendizaje profundo, modelos híbridos y aprendizaje automático. Estos enfoques buscan capturar la naturaleza no lineal, dinámica y altamente volátil de los mercados financieros. Asimismo, se identifica una tendencia creciente hacia la integración de técnicas complementarias, como la optimización metaheurística, la simulación, el análisis de sentimiento, la reducción de dimensionalidad y la inteligencia artificial explícita.

Estos enfoques reflejan un esfuerzo por mejorar tanto la precisión predictiva, la robustez y la comprensión de dos modelos, respondiendo a las demandas de entornos financieros complejos.

La revisión sistemática de documentos sobre los principales beneficios asociados a la aplicación de modelos predictivos basados en inteligencia artificial en

la toma de decisiones financieras. Estos beneficios incluyen mejoras significativas en la precisión y robustez de los pronósticos, la capacidad de gestionar la volatilidad y la incertidumbre, la integración de información no tradicional, la optimización de decisiones basadas en múltiples criterios y el fortalecimiento de la toma de decisiones basada en datos. Estos beneficios demuestran que la inteligencia artificial no es solo una herramienta predictiva, sino también un componente estratégico que transforma la forma en que se analizan y gestionan los sistemas financieros.

Sin embargo, un análisis crítico de la literatura identificó diversas limitaciones y lagunas que afectan la aplicabilidad de estos modelos en entornos reales. Entre los principales desafíos se encuentran la limitada generalización de los resultados, la excesiva dependencia de datos históricos, la insuficiente integración de variables externas relevantes, la alta complejidad computacional de los modelos, la falta de validación económica realista y los persistentes problemas de interpretabilidad y transparencia.

Además, son evidentes los desafíos relacionados con la calidad y disponibilidad de los datos, así como la presencia de presupuestos metodológicos restrictivos que pueden limitar la capacidad de dos modelos para adaptarse a las estructuras cambiantes del mercado.

En general, estos descubrimientos reflejan que el campo de la inteligencia artificial aplicada a la toma de decisiones financieras se encuentra en una etapa de creciente madurez, caracterizada por importantes avances metodológicos, pero también por desafíos relevantes que abren claras oportunidades para la investigación futura. La necesidad de modelos más interpretables, robustos, generalizados y económicamente validados surge como una prioridad para fortalecer la transferencia de metodologías académicas a la práctica financiera en el mundo real.

Una vez realizado el estado del arte, se recomienda explorar más a fondo la aplicación de estos modelos predictivos a contextos específicos como las criptomonedas, indicadores financieros o acciones, entre otros ya que pueden surgir investigaciones más detalladas en contextos más pequeños.

Tener claro que generar unas buenas prácticas de tratamiento de datos, tanto de disponibilidad como de calidad, es necesario, ya que los modelos dependen directamente de datos históricos para operar, es necesario impulsar iniciativas que faciliten la recopilación de datos, validación y el almacenamiento de datos.

El enriquecimiento es una práctica que recomiendo para mejorar sustancialmente las predicciones realizadas por los modelos, incluso reduciendo su horizonte de

predicción, ampliar el contexto de cualquier inteligencia artificial resulta en una mejor predicción y se vio en los modelos analizados durante el trabajo.

La mayoría de modelos predictivos fueron desarrollados para contextos muy específicos de trabajo, esto dificulta su adaptabilidad a otros contextos o a otras variables. La escalabilidad y la replicabilidad son esenciales para hacer de estas herramientas cada vez más comunes en la cotidianidad, se podrían generar modelos más generales que sirvan de base para ramificarse.

Si se quieren replicar estos modelos en contextos colombianos se tendrían que diseñar desde cero para abarcar toda la dinámica financiera del país, ya que, si simplemente replicamos los existentes, estos trabajarán sobre dinámicas de países más avanzados tecnológicamente.

#### 4. REFERENCIAS

Mirza, N., Rizvi, S. K. A., Naqvi, B., & Umar, M. (2024). Inflation prediction in emerging economies: Machine learning and FX reserves integration for enhanced forecasting. *International Review of Financial Analysis*, 94, Article 103238. <https://doi.org/10.1016/j.irfa.2024.103238>  
sciencedirect.com+12ouci.dntb.gov.ua+12ideas.repec.org+12

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Aljawazneh, H., Mora, A. M., García-Sánchez, P., & Castillo-Valdivieso, P. A. (2021). *Comparing the performance of deep learning methods to predict companies' financial failure*. *IEEE Access*, 9, 97010–97037. <https://doi.org/10.1109/ACCESS.2021.3093461>

Kuryłek, W. (2024). Artificial Neural Networks and Gradient-Boosting Decision Trees in time-series forecasting of earnings per share in Poland. *Eastern European Economics*. <https://doi.org/10.1080/00128775.2024.2345678>

Wei, X., Chen, S., & Xu, L. (2024). Evaluating ensemble learning techniques for stock index trend prediction: A case <https://doi.org/10.1007/s10258-024-00263-7>

Vitale, C., Bisaglia, L., & Romano, A. (2025). In-season price forecasting in cotton futures markets using ARIMA, neural network, and LSTM machine learning models. *Journal of Risk and Financial Management*, 18(3), 115. <https://doi.org/10.3390/jrfm18030115>

Fozap, F. M. P. (2025). *HybridMachineLearningModelsfor Long-*

- TermStockMarketForecasting: Integrating Technical Indicators. *Journal of Risk and Financial Management*, 18(4), 201. <https://doi.org/10.3390/jrfm18040201>
- Safari, A., & Badamchizadeh, M. A. (2024). DeepInvesting: Stock market predictions with a sequence-oriented BiLSTM stacked model – A dataset case study of AMZN. *Intelligent Systems with Applications*, 24, Article 200439. <https://doi.org/10.1016/j.iswa.2024.200439>
- Nguyen, D. T., Duong, D. H., & Le, T. L. (2024). Deep learning-based predictive models for forex market trends: Practical implementation and performance evaluation. *Science Progress*, 107(2), 1–15. <https://doi.org/10.1177/00368504241229560>
- Pokou, D. K., Chen, J., Liu, C., & Qu, J. (2024). Hybridization of ARIMA with learning models for forecasting of stock market time series. *Computational Economics*, 64(1), 303–329. <https://doi.org/10.1007/s10614-023-10363-1>
- Koo, E., & Kim, G. (2022). A hybrid prediction model integrating GARCH models with a distribution manipulation strategy based on LSTM networks for stock market volatility. *IEEE Access*, 10, 34743–34754. <https://doi.org/10.1109/ACCESS.2022.3163723>
- Jesus, D. M., Dos Santos, M. A., De Souza, R. M., & De Almeida, J. R. (2024). Forecasting Brazilian stock market using sentiment indices from textual data, ChatGPT-based and technical indicators. *Computational Economics*. <https://doi.org/10.1007/s10614-024-10572-9>
- Khalil, A., Ezzat, D., Hassan, M., & Dahou, A. (2021). Is deep-learning and natural language processing transcending the financial forecasting? Investigation through lens of news analytic process. *Computational Economics*, 59(3), 823–849. <https://doi.org/10.1007/s10614-021-10136-1>
- Acharya, D. B., Divya, B., & Kuppan, K. (2024). Explainable and fair AI: Balancing performance in financial and real estate machine learning models. *IEEE Access*, 12, 154022–154034. <https://doi.org/10.1109/ACCESS.2024.3484409>
- Amiri, M., Moradi, M., & Ghasemi, M. (2025). A novel hybrid GCN-LSTM algorithm for energy stock price prediction: Leveraging temporal dynamics and inter-stock relationships. *IEEE Access*, 13, 4923–4937. <https://doi.org/10.1109/ACCESS.2025.3505189>
- Goodell, J. W., Kumar, S., & Rao, A. (2023). Explainable artificial intelligence modeling to forecast bitcoin prices. *International Review of Financial Analysis*, 87, 102627. <https://doi.org/10.1016/j.irfa.2023.102627>
- Praveen, D., Ramalingam, M., & Jeyachitra, R. (2025). Financial time series forecasting: A comprehensive review of signal processing and optimization-driven intelligent models. *Computational Economics*, 65(2), 667–702. <https://doi.org/10.1007/s10614-024-10467-3>
- Bao, X., Huang, Q., Zhang, Y., & Wang, C. (2025). Data-driven stock forecasting models based on neural networks: A review. <https://doi.org/10.1016/j.inffus.2024.102357>
- Deep, A. (2024). Advanced financial market forecasting: Integrating Monte Carlo simulations with ensemble Machine Learning models. *Quantitative Finance and Economics*, 8(2), 286–314. <https://doi.org/10.3934/QFE.2024011>
- Méndez Pineda, J. D. (2021). Un modelo para la predicción del movimiento del precio de las acciones del mercado bursátil basado en un análisis de sentimiento y datos históricos de la BVC [Trabajo de grado de pregrado, Universidad Industrial de Santander]. Universidad Industrial de Santander .
- Ávila Mogollón, F. M. L. (2022). Revisión sistemática de artículos científicos sobre inteligencia artificial y su aplicación en el sector de servicios financieros en Colombia [Tesis de pregrado, Universidad Industrial de Santander].
- Rouhiainen, L. (2018). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Zubillaga Rego, A., Pastor López, I., & García Bringas, P. (Abril 2020). ARTIFICIAL INTELLIGENCE: AN APPROACH FROM FINANCE. *BOLETIN DE ESTUDIOS ECONOMICOS Vol. LXXV - N.º 229*, 99–117.
- Munárriz, L. (1994). *Fundamentos de Inteligencia*. Naciones Unidas . (2013). *Economía digital para el cambio estructural y la igualdad*. Santiago de Chile.
- Brigham, E. F., & Ehrhardt, M. C. (2022). *Financial management: Theory & practice* (17th ed.). Cengage Learning
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). <https://otexts.com/fpp3/>



Xu, K., & Wang, W. (2023). *Limited information limits accuracy: Whether ensemble empirical mode decomposition improves crude oil spot price prediction?* International Review of Financial Analysis, 87, 102625. <https://doi.org/10.1016/j.irfa.2023.102625>

Gitman, L. J., & Zutter, C. J. (2019). Principles of managerial finance (15th ed.). Pearson.

Khattak, M. A., Khalid, R., Rehman, Z. U., Alenezi, F., & Rubaiee, S. (2023). A systematic survey of AI models in financial market forecasting for profitability analysis. IEEE Access, 11, 79231–79251. <https://doi.org/10.1109/ACCESS.2023.3300439>

Kitchenham, B., & Charters, S. (2013). Guidelines for performing systematic literature reviews in software engineering (Version 2.3). EBSE Technical Report, Keele University and University of Durham

Aruleba, I., & Sun, Y. (2024). *Effective credit risk prediction using ensemble classifiers with model explanation*. IEEE Access, 12, 115015–115025. <https://doi.org/10.1109/ACCESS.2024.3445308>

Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. British Journal of Management, 14(3), 207–222. <https://doi.org/10.1111/1467-8551.00375>

Kim, I., & Kuljis, J. (2010). Applying content analysis to web-based content. Journal of Computing and Information Technology, 18(4), 369–375. <https://doi.org/10.2498/cit.1001924>

Bauer, C., & Scharl, A. (2000). Quantitative evaluation of Web site content and structure. Internet Research, 10(1), 31–43. <https://doi.org/10.1108/10662240010312137>

Giri, S., Du, D., & Beruvides, M. (2025). *A systematic approach to predicting NFT prices using time series forecasting and macroeconomic factors in digital assets*. Cogent Economics & Finance, 13(1), 2336426. <https://doi.org/10.1080/23322039.2024.2336426>

Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., & Wen, S. (2025). *Data-driven stock forecasting models based on neural networks: A review*. Expert Systems with Applications, 247, 123343. <https://doi.org/10.1016/j.eswa.2024.123343>

Zhang, X., Kong, F., liu, X. *et al.* Forecasting future trends: a comprehensive analysis of korea composite stock price index using advanced predictive models. *Int*

*J Syst Assur Eng Manag* **16**, 1945–1962 (2025). <https://doi.org/10.1007/s13198-025-02759-8>