

Aplicación de modelos predictivos basados en inteligencia artificial para la toma de decisiones
financieras: Estado del Arte

Mauren Javier Gamboa Mojica

Trabajo de Grado para Optar al Título de Ingeniero Industrial

Director

José Alonso Caballero Márquez

Doctor en Ciencias de la Administración

Codirector

Víctor Alfonso Sanabria Ruiz

Magister en Ingeniería Industrial

Universidad Industrial de Santander

Facultad de Ingenierías Físicomecánicas

Escuela de Estudios Industriales y Empresariales

Ingeniería Industrial

Bucaramanga

2026

Dedicatoria

Dedicado a los profesionales que llevan sobre sus hombros el peso del progreso.

*A mi gran amigo **Jeferson Caballero**, por más de una década de amistad.*

*A **Bri**, por su compañía y ayuda en tiempos difíciles.*

*A **mamá y papá**, por confiar.*

*A **mí**, por forjar el absoluto poder de mi suerte.*

Y a las cumbres nevadas de Colombia, por darme el propósito por el que hoy arde mi

espíritu.

Tabla de Contenido

Introducción	10
1. Planteamiento del problema.....	11
2. Objetivos	14
2.1 Objetivo General.....	14
2.2 Objetivos Específicos.....	14
2.3 Tabla de cumplimiento de objetivos	14
3. Marco de referencia	15
3.1 Marco de antecedentes	15
3.2 Marco teórico	17
3.2.1 Inteligencia Artificial	17
3.2.2 Aplicaciones de IA en las organizaciones	18
3.2.3 Categorías de modelos predictivos basados en IA.....	18
3.2.4 Indicadores de error	21
3.2.5 Toma de decisiones financieras	22
3.2.6 Proceso de toma de decisiones financieras	23
4. Marco metodológico	24
5. Resultados.....	25
5.1 Análisis bibliométrico.....	25
5.2 Modelos predictivos basados en IA para la toma de decisiones financieras	32
5.2.1 Tipos de modelos predictivos basados en inteligencia artificial.....	33
5.2.2 Horizontes de predicción en modelos basados en inteligencia artificial	41

5.3 Segmentos financieros y tipos de decisiones	44
5.3.1 Segmentos financieros	44
5.3.1 Tipos de decisiones	50
5.4 Documentación de beneficios, limitaciones y oportunidades de mejora	58
5.4.1 Beneficios	58
5.4.2 Limitaciones y oportunidades de mejora	63
6. Conclusiones	66
7. Recomendaciones	69
Referencias bibliográficas.....	71

Lista de Tablas

	Pag
Tabla 1 <i>Cumplimiento de objetivos</i>	14
Tabla 2 <i>Tipos de modelos basados en IA</i>	19
Tabla 3 <i>Modelos basados en IA</i>	20
Tabla 4 <i>Indicadores de error</i>	21
Tabla 5 <i>Metodología</i>	24
Tabla 6 <i>Ecuaciones de búsqueda empleadas en las bases de datos</i>	26
Tabla 7 <i>Cantidad de documentos encontrados en las bases de datos</i>	26
Tabla 8 <i>Modelos predictivos basados en redes neuronales identificados</i>	34
Tabla 9 <i>Modelos predictivos basados en aprendizaje automático identificados</i>	36
Tabla 10 <i>Modelos predictivos híbridos identificados</i>	39
Tabla 11 <i>Modelos predictivos enriquecidos identificados</i>	40
Tabla 12 <i>Horizontes de predicción en modelos basados en inteligencia artificial</i>	43
Tabla 13 <i>Segmentos financieros</i>	48
Tabla 14 <i>Tipos de decisiones financieras específicas</i>	57
Tabla 15 <i>Beneficios de los modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras</i>	61
Tabla 16 <i>Limitaciones de los modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras</i>	65

Lista de Figuras

Figura 1 <i>Proceso de toma de decisiones</i>	23
Figura 2 <i>Documentos Publicados por Año</i>	27
Figura 3 <i>Proceso de depuración de documentos duplicados</i>	28
Figura 4 <i>Diagrama de coocurrencia de palabras clave encontradas en Scopus</i>	29
Figura 5 <i>Diagrama de coocurrencia de palabras clave encontradas en WOS</i>	29
Figura 6 <i>Documentos publicados por país</i>	30
Figura 7 <i>Diagramas de coocurrencia de autores por Scopus</i>	31
Figura 8 <i>Diagramas de coocurrencia de autores por WOS</i>	32
Figura 9 <i>Segmentos financieros</i>	45

Lista de Apéndices

Apéndice A Tabla de literatura

Apéndice B Artículo de carácter publicable

“Los apéndices están adjuntos y puede visualizarlos en la base de datos de la biblioteca UIS”

Resumen

Título: Aplicación de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras*

Autor: Mauren Javier Gamboa Mojica**

Palabras Clave: Inteligencia artificial, modelos predictivos, toma de decisiones financieras

Descripción: La toma de decisiones financieras en contextos caracterizados por la velocidad e incertidumbre representa uno de los principales desafíos para los sistemas económicos actuales. Los modelos predictivos basados en inteligencia artificial se han consolidado en los últimos años como herramientas clave para el análisis, pronóstico y apoyo en la decisión de distintos segmentos financieros. Este estudio presenta un estado del arte cuyo objetivo es establecer los beneficios del uso de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras, identificando los principales segmentos abordados, horizontes de predicción y tipos de decisiones que respaldan. Hay tres grandes tipos de decisiones abordadas, inversión, gestión del riesgo y apoyo estratégico. Además, se identificaron tres grandes grupos de modelos predictivos, los correspondientes a aprendizaje automático, redes neuronales profundas, enriquecidos e híbridos, siendo estos últimos los más relevantes. Los resultados de esta revisión de literatura muestran que los modelos predictivos basados en inteligencia artificial ofrecen un alto potencial para fortalecer la toma de decisiones financieras, al mejorar la precisión en los pronósticos y apoyar procesos como la inversión, la gestión del riesgo y el apoyo estratégico. Sin embargo, la literatura también evidencia limitaciones relacionadas con la disponibilidad y calidad de los datos, la complejidad de los modelos y los desafíos en términos de interpretabilidad y generalización de los resultados. En consecuencia, se destaca la necesidad de continuar investigando en el desarrollo de enfoques más robustos, específicos y explicables que permitan una aplicación más efectiva de estos modelos en distintos contextos financieros.

* Trabajo de Grado

** Facultad de Ingenierías Físico-mecánicas. Escuela de Estudios Industriales y Empresariales. Ingeniería Industrial. Director: José Alonso Caballero Márquez. Doctor en ciencias de la administración. Codirector: Víctor Alfonso Sanabria Ruiz. Magíster en Ingeniería Industrial

Abstract

Title: Application of Artificial Intelligence–Based Predictive Models for Financial Decision-Making *

Author(s): Mauren Javier Gamboa Mojica **

Key Words: Artificial intelligence, predictive models, financial decision-making

Description: Financial decision-making in contexts characterized by speed and uncertainty represents one of the main challenges faced by modern economic systems. In recent years, 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, highlighting the main financial segments addressed, forecasting horizons, and the types of decisions they support. Three major types of decisions are identified: investment, risk management, and strategic support. In addition, three broad groups of predictive models are identified, namely traditional machine learning models, deep neural networks, enriched models, and hybrid models, with the latter being the most prominent. The results of this literature review show that artificial intelligence–based predictive models offer significant potential to strengthen financial decision-making by improving forecasting accuracy and supporting processes such as investment, risk management, and strategic planning. However, the literature also reveals limitations related to data availability and quality, model complexity, and challenges in terms of interpretability and generalization of results. Consequently, there is a clear need for further research focused on developing more robust, domain-specific, and explainable approaches that enable more effective application of these models across different financial contexts.

* Degree Work

** Faculty of Physical-Mechanical Engineering. School of Industrial and Business Studies. Director Jose Alonso Caballero Marquez. PhD in Management Sciences Codirector Victor Alfonso Sanabria Ruiz, MSc in Industrial Engineering.

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.

En el presente documento se realiza una revisión sistemática y un análisis de contenido web de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras, se destacan las tendencias actuales, los modelos más utilizados en la literatura, las oportunidades de mejora y beneficios.

1. Planteamiento del problema

Las herramientas de predicción son un apoyo fundamental para la gestión de las decisiones financieras, si estas funcionan correctamente, sus consecuencias pueden tener impacto en todos los niveles de una organización, desde realizar presupuestos con cierto porcentaje de seguridad hasta la creación de planes estratégicos que puedan alinearse con los posibles futuros. El avance

tecnológico ha evolucionado las herramientas tradicionales de predicción, permitiendo realizar análisis de sucesos no lineales e incluso identificar patrones que los creadores de estos algoritmos no pudieron identificar en un principio.

Según Deep et al. (2024., p.3), los modelos predictivos basados en inteligencia artificial son capaces de identificar patrones no lineales en los datos financieros, característica que les permite mejorar en la precisión de los movimientos del mercado o de las criptomonedas. Esta habilidad permite generar diferentes escenarios y evaluar los posibles retornos dependiendo de la estrategia que implementen, si estos modelos se alinean la capacidad de retorno con, por ejemplo, objetivos de rentabilidad o una tolerancia al riesgo, ese ajuste puede mejorar al máximo. En un entorno económico caracterizado por su alto volumen de cambios inesperados y la necesidad de las personas para tomar mejores decisiones, estos modelos predictivos pasaron de ser una herramienta descriptiva, a un apoyo integral capaz de apoyar la inversión de los recursos.

En la literatura se abordan múltiples modelos y la comparación entre ellos en diferentes investigaciones, pero sigue existiendo un vacío relacionado al impacto que estos pueden generar al utilizar esas predicciones como recurso para formular y desarrollar estrategias alineadas con los múltiples escenarios que pueden surgir. Aunque a través de ellos es posible obtener resultados clave como la reducción de los errores y una tolerancia al riesgo mayor, existe poca claridad sobre estos, sus horizontes de predicción, su verdadero alcance y beneficios u oportunidades de mejora.

Estos modelos se ven limitados por múltiples características como la calidad y la cantidad previa de los datos que usen e incluso la capacidad computacional que tenga el usuario a la hora de utilizarlos. Se hace necesaria una revisión de la literatura que pueda agrupar estos modelos, sus características específicas, funcionamiento y horizontes de predicción. El objetivo de este estudio es establecer los beneficios del uso de inteligencia artificial en la toma de decisiones financieras

brindando un vistazo del estado actual de los modelos predictivos y el potencial de estos para mejorar la toma de decisiones financieras.

2. Objetivos

2.1 Objetivo General

Establecer los beneficios del uso de inteligencia artificial para el mejoramiento en la toma de decisiones financieras a través de una revisión sistemática y un análisis de contenido WEB

2.2 Objetivos Específicos

Realizar una revisión sistemática de la literatura científica sobre el uso de modelos predictivos basados en inteligencia artificial en la toma de decisiones financieras.

Realizar un análisis de contenido WEB sobre el uso de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras.

Identificar los principales beneficios y oportunidades de mejora relacionadas al uso e implementación de inteligencia artificial en la toma de decisiones financieras.

Elaborar un artículo de carácter publicable que sintetice los principales resultados de la investigación desarrollada.

2.3 Tabla de cumplimiento de objetivos

Tabla 1

Cumplimiento de objetivos

Objetivo Específico	Cumplimiento
Realizar una revisión sistemática de la literatura científica sobre el uso de modelos predictivos basados en inteligencia artificial en la toma de decisiones financieras.	Capítulo 5. Sección 5.1
Realizar un análisis de contenido WEB sobre el uso de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras.	Capítulo 3.

Identificar los principales beneficios y oportunidades de mejora relacionadas al uso e implementación de inteligencia artificial en la toma de decisiones financieras. Capítulo 5. Sección 5.4

Elaborar un artículo de carácter publicable que sintetice los principales resultados de la investigación desarrollada. Documento adjunto

3. Marco de referencia

3.1 Marco de antecedentes

Se analizan tres trabajos de grado pertenecientes a universidades de UNIRED que abordan temáticas relacionadas con el tema de esta revisión de literatura. Es clara la presencia de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras.

En el trabajo de investigación titulado Aplicaciones de la Inteligencia Artificial en la Ingeniería Financiera, desarrollado por Díaz y Tarazona (2024) en la Universidad Autónoma de Bucaramanga, se exploraron de manera amplia las aplicaciones de la inteligencia artificial en tres líneas de la ingeniería financiera: finanzas corporativas, inversiones, y riesgo-cobertura especulación.

El objetivo principal fue construir un ejemplo ilustrativo para demostrar la aplicabilidad de estos modelos en las áreas mencionadas anteriormente, realizando una revisión bibliométrica y construyendo un modelo predictivo basado en redes neuronales para hacer predicciones de precios de acciones, mencionan que la presencia de la inteligencia artificial mejora significativamente varios procesos incluyendo toma de decisiones y análisis en tiempo real. Dejan claro que más que un reemplazo de los humanos es una herramienta para potenciar los resultados finales, este trabajo es relevante ya que muestra la aplicación real de la inteligencia artificial en un modelo predictivo

y como se puede integrar para lograr mejores resultados, reforzando el análisis que se hará en esta investigación.

En el trabajo de grado Revisión sistemática de artículos científicos sobre inteligencia artificial y su aplicación en el sector de servicios financieros en Colombia escrito por Ávila Mogollón (2022) se aborda el tema del uso de inteligencia artificial como herramienta de apoyo para la toma de decisiones en el sector financiero, identificando mediante una revisión sistemática la forma en que ha sido implementada la inteligencia artificial en el sector financiero nacional, definiendo qué tecnologías usan y los impactos de las mismas, la autora agrupó las diferentes implementaciones en grupos dependiendo de donde eran usadas. Se concluye que el mayor impacto de la inteligencia artificial se da a nivel organizacional, generando mayor impacto en procesos internos e incremento de la productividad. Este trabajo es relevante para esta revisión ya que resalta los usos e implementaciones de la inteligencia artificial en las múltiples áreas del sector financiero nacional.

En el trabajo de grado titulado Modelo predictivo del movimiento en el precio de las acciones del mercado bursátil basado en un análisis de sentimiento y datos históricos de la BVC por Jesús David Méndez Pineda (2021) se diseña un modelo predictivo para anticipar el comportamiento del precio de las acciones de Ecopetrol, Bancolombia y el índice COLCAP usando aprendizaje automático y análisis de sentimiento. Estructura su metodología desde la recolección de los datos y limpieza de estos hasta la validación con los modelos predictivos. La investigación resulta en la definición del análisis de sentimiento como una herramienta complementaria a las predicciones si se logran afinar los datos utilizados, este trabajo es relevante ya que presenta una aplicación directa de modelos predictivos basados en inteligencia artificial al mercado de capitales colombiano.

3.2 Marco teórico

3.2.1 Inteligencia Artificial

El tema principal de este trabajo de investigación radica en la inteligencia artificial, de acuerdo con Rouhiainen (2018, p. 17), la inteligencia artificial puede definirse básicamente como “la habilidad de los ordenadores para realizar actividades que normalmente requieren inteligencia humana”. Dejando clara una dependencia apoyada en algoritmos que aprenden continuamente de los datos y que, a partir de ese mismo aprendizaje, toman decisiones como si fueran una persona.

Autores como Zubillaga Rego, Pastor López y García Bringas (2020) definen la inteligencia artificial como un conjunto de técnicas que automatizan actividades cognitivas del ser humano, en la carrera de la revolución digital, estas técnicas adquieren relevancia y empiezan a participar en las decisiones estratégicas de múltiples sectores teniendo bastante participación en las finanzas. Los modelos predictivos basados en inteligencia artificial permiten resolver problemas específicos y evitar la toma de decisiones a ciegas, pero cabe aclarar que acarrearán desafíos importantes relacionados a privacidades de datos, transparencia y, sobre todo, una necesidad de talento especializado.

Según Munárriz (1994), la inteligencia artificial es una rama de la informática que busca enseñar a las máquinas a pensar, imitando el pensamiento humano. Lo más curioso de esta analogía, es que al tratar de analizar como razonamos, se mejora nuestro propio proceso mental, traduciendo todo esto a pasos lógicos que demuestran que la inteligencia artificial, aparte de crear máquinas inteligentes, brinda un apoyo para comprender más profundamente lo que significa pensar.

Todas estas perspectivas convergen en un punto muy importante: la inteligencia artificial, aparte de tratar de replicar la inteligencia humana, expande los límites de esta al tener el poder de

procesar volúmenes de datos impensables y ofrecer respuestas de estos casi en tiempo real. Imitar y amplificar convierten a esta herramienta en un aliado estratégico para las personas que necesitan enfrentar decisiones complejas llenas de incertidumbre como las del sector financiero.

3.2.2 Aplicaciones de IA en las organizaciones.

Al interior del contexto corporativo, la inteligencia artificial ha ganado terreno como una herramienta clave para enfrentar los desafíos actuales relacionados a eficiencia, hiperproductividad y toma de decisiones informadas. Su presencia es importante y abarca la automatización de procesos administrativos, la mejora de atención a clientes mediante chatbots que no necesitan descansar, la capacidad para convertir herramientas de código en no código, predecir comportamientos de mercados, entre muchos otros usos. Según Goodell et al (2023), la inteligencia artificial ha migrado de tareas netamente operativas a estratégicas, transformando procesos y agregando valor a la innovación y gestión del conocimiento.

En el sector financiero, la inteligencia artificial ha sido adoptada por instituciones bancarias, aseguradoras, firmas de inversionistas y fintechs para mejorar la seguridad y eficiencia de sus operaciones. Las aplicaciones más frecuentes están relacionadas con detección de fraudes, scoring crediticio, predicción de precios de activos financieros, automatización de trading y análisis sentimientos, generando una holgura que permite anticipar el comportamiento del mercado (Villanueva et al 2022)

3.2.3 Categorías de modelos predictivos basados en IA.

Definir predicción es extremadamente importante antes de hablar sobre modelos predictivos, el concepto de predecir según Makridakis et al (2018), “la predicción implica el uso de datos históricos y presentes, para estimar valores o comportamientos futuros con el apoyo de técnicas estadísticas, matemáticas o de inteligencia artificial”.

El modelo predictivo es un diseño de métodos que permite realizar esa estimación. Su materia prima son datos históricos, y utiliza algoritmos para identificar dentro de este conjunto de datos, reacciones, variables y tendencias. Los modelos predictivos abarcan conceptos “básicos” como una regresión lineal hasta métodos avanzados como redes neuronales profundas, pero su objetivo sigue siendo el mismo, generar estimaciones confiables que permitan tomar decisiones futuras reduciendo la incertidumbre.

Teniendo en cuenta esto, existen ciertas categorías para modelos predictivos basados en inteligencia artificial, los que se presentan en la Tabla 2 son los más comunes y los que se abordan en la literatura de esta revisión.

Tabla 2

Tipos de modelos basados en IA

Tipo de modelo	Definición
Modelos de aprendizaje automático	Algoritmos que aprenden patrones usando datos previamente estructurados para optimizar una métrica específica, como la exactitud o el error de predicción. No requieren modelar explícitamente todas las relaciones, pero sus resultados dependen de la calidad de sus datos de entrenamiento.
Redes neuronales profundas	Modelos que poseen varias capas de procesamiento aprendiendo automáticamente de los datos suministrados, tienen la habilidad de capturar dependencias no definidas y no lineales, incluyendo relaciones de largo plazo. No requieren modelar explícitamente las relaciones.
Modelos híbridos	Combinan algoritmos tradicionales con técnicas de inteligencia artificial, complementando y fortaleciendo de ambos componentes para modelar y analizar los dos tipos de relaciones, lineales y no lineales.
Modelos enriquecidos	Modelos que incorporan variables más allá de las numéricas para realizar análisis detallados que tienen en cuenta análisis de sentimientos,

criterios éticos o datos textuales para contextualizar las predicciones y mejorarlas.

Aunque estas son categorías, es necesario definir también los modelos específicos que se utilizaron en la literatura, en la Tabla 3 se presentan los modelos más utilizados en la literatura revisada.

Tabla 3

Modelos basados en IA

Modelo	Categoría	Definición
LSTM / Bi LSTM/ CNN LSTM	Redes neuronales profundas	Modelos que aprenden de datos que cambian con el tiempo. LSTM recuerda información importante y olvida lo innecesario. Bi-LSTM mapea datos futuros y datos pasados para tener más contexto en la predicción y CNN-LSTM combina patrones con la memoria de LSTM para mejorar la precisión.
Random Forest	Aprendizaje automático	Grupo de árboles de decisión que trabajan en conjunto, dando individualmente una respuesta y eligiendo la que más se repite dentro de todas las opciones, generando más seguridad al no depender únicamente de un solo árbol.
ANN / MLP	Redes neuronales profundas	Redes formadas por capas que imitan de forma simplificada el cerebro, sirviendo para encontrar relaciones entre datos incluso cuando son muy complejas.
CNN (Convolutional Neural Network)	Redes neuronales profundas	Redes que se encargan de buscar patrones dentro del conjunto de datos para revisar los detalles más importantes, es muy usado para el análisis de imágenes.

SVR (Support Vector Regression)	Aprendizaje Automático	Modelo cuyo objetivo es encontrar una función que se desvíe lo menos posible de los datos reales, definiendo un margen de tolerancia maximizando la generalización del modelo.
---------------------------------	------------------------	--

3.2.4 Indicadores de error.

En el campo de los modelos predictivos, estos indicadores son una herramienta fundamental para evaluar la exactitud de las predicciones generadas. Medir la diferente entre el valor real y el valor pronosticado es extremadamente importante para estos modelos ya que permiten establecer comparaciones reales entre los diferentes modelos, brindando una conclusión de cuál podría llegar a ser mejor o cuál es más exacto.

Hyndman y Athanasopoulos (2021) mencionan que la selección del indicador de error debe responder a la variable que se está tratando de predecir, el horizonte de pronóstico y el impacto de errores grandes sobre la toma de decisiones. En un entorno financiero, un error de predicción puede resultar catastrófico, significando pérdidas millonarias. Al usar esta clase de métricas permite a la persona que toma decisiones validar y adoptar cierto modelo por encima de otro. Los indicadores de error más utilizados en la literatura revisada se encuentran en la Tabla 7

Tabla 4

Indicadores de error

Indicador	Definición
MAE	Promedio de las diferencias absolutas entre el valor real y el valor predicho, mide cuanto se equivoca el modelo independientemente de su movimiento.

MSE	Promedio de errores al cuadrado, enfocado en penalizar los errores más grandes, permite identificar si un modelo se equivoca en repetidas ocasiones.
RMSE	Raíz cuadrada del MSE, pero expresa el error en las unidades de la variable estudiada, penaliza errores grandes.
MAPE	Error absoluto medio como porcentaje, permite comparar el rendimiento en diferentes escalas
Theils U	Compara el rendimiento de un modelo específico contra un pronóstico simple, analizando si realmente las predicciones se mejoran.

3.2.5 Toma de decisiones financieras.

La toma de decisiones financieras es el proceso mediante el cual individuos, empresas e instituciones seleccionan entre diferentes alternativas de inversión, financiamiento y gestión de riesgos, con el objetivo de maximizar el valor económico y minimizar la exposición a la incertidumbre (Brigham & Ehrhardt, 2022). Este proceso se sustenta en el análisis de información cuantitativa y cualitativa, incorporando proyecciones, indicadores financieros, condiciones de mercado y factores regulatorios.

En general, las decisiones financieras se pueden clasificar en tres tipos, estratégicas, tácticas y operativas, todas con su respectivo plazo. Las decisiones estratégicas están orientadas al largo plazo, la definición de portafolios de inversión o la gestión del riesgo, las tácticas y operativas incluyen, por ejemplo, gestión de liquidez o asignación de capital de trabajo. Una decisión correcta y alineada con los objetivos organizacionales puede generar consecuencias extremadamente positivas para las organizaciones, de ahí que son tan importantes.

Con el auge de la inteligencia artificial y sus modelos avanzados de análisis de datos, estas decisiones se han transformado. Los modelos predictivos basados en redes neuronales permiten anticipar tendencias y hallar relaciones entre variables que un humano no podría definir, generando una mejora clara frente a los enfoques tradicionales de predicción (Khalil & Pipa, 2022)

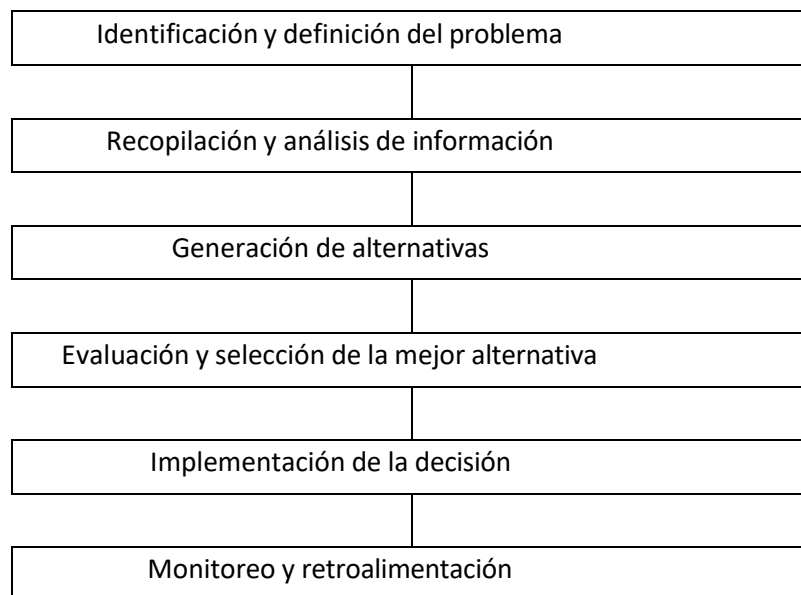
3.2.6 Proceso de toma de decisiones financieras.

Este proceso constituye una secuencia estructurada de etapas que guían a las personas responsables en la selección de la alternativa más adecuada para atacar el problema, considerando ciertas variables relevantes, que en el caso de las finanzas pueden ser, rentabilidad, riesgo, liquidez y sostenibilidad (Gitman & Zutter, 2019). Es un proceso totalmente iterativo porque los resultados finales nunca lo son y generalmente requieren ajustes para mejorar la eficacia de las decisiones.

Su fase está listada en la **Figura 1**.

Figura 1

Proceso de toma de decisiones



4. Marco metodológico

Se definieron una serie de actividades para poder llevar a cabo la revisión de la literatura propuesta para el proyecto de grado. En la tabla 5 se pueden ver la secuencia planteada.

Tabla 5

Metodología

Indicador	Definición
Búsqueda y selección de literatura relevante	Revisión de literatura sobre la aplicación de modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras que integren pronósticos de mercados de valores para la toma de decisiones. Filtración de artículos duplicados, revisando títulos, abstracts y artículos completos para determinar una muestra relevante de documentos que tenga relación directa con el tema a estudiar. Extracción de información relevante de la muestra filtrada de artículos en una base de datos con una plantilla estructurada.
Descripción de la literatura	Descripción y clasificación de los segmentos financieros en los que se encuentran estos modelos. Descripción y clasificación de las categorías de modelos basados en inteligencia artificial en la literatura (Aprendizaje automático, redes neuronales profundas, modelos híbridos, modelos enriquecidos) Descripción y clasificación de los modelos utilizados en la literatura teniendo en cuenta su categoría y sus indicadores de error
Caracterización de modelos utilizados, horizontes de	Caracterización de los modelos predictivos descritos en la literatura, documentando su horizonte de predicción y categoría general.

predicción y categoría de modelo	
Caracterización de segmentos financieros donde se usan estos modelos predictivos.	Identificación de los principales sectores financieros en los que estos modelos son utilizados, identificando los que se usan y analizando si existen tendencias de uso.
Evaluación de beneficios, oportunidades de mejora y limitaciones	Sintetización de los principales beneficios de la aplicación de modelos predictivos basados en inteligencia artificial y análisis de su uso para la toma de decisiones financieras. Identificación de las principales limitaciones y oportunidades de mejora en la aplicación de estos modelos predictivos para la toma de decisiones financieras presentes en la literatura.
Elaboración de resultados esperados	Redacción de un artículo de carácter publicable que recopile los hallazgos y resultados principales de la revisión de literatura.

5. Resultados

5.1 Análisis bibliométrico

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, como se ve en la **Tabla 6**, 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.

Tabla 6

Ecuaciones de búsqueda empleadas en las bases de datos

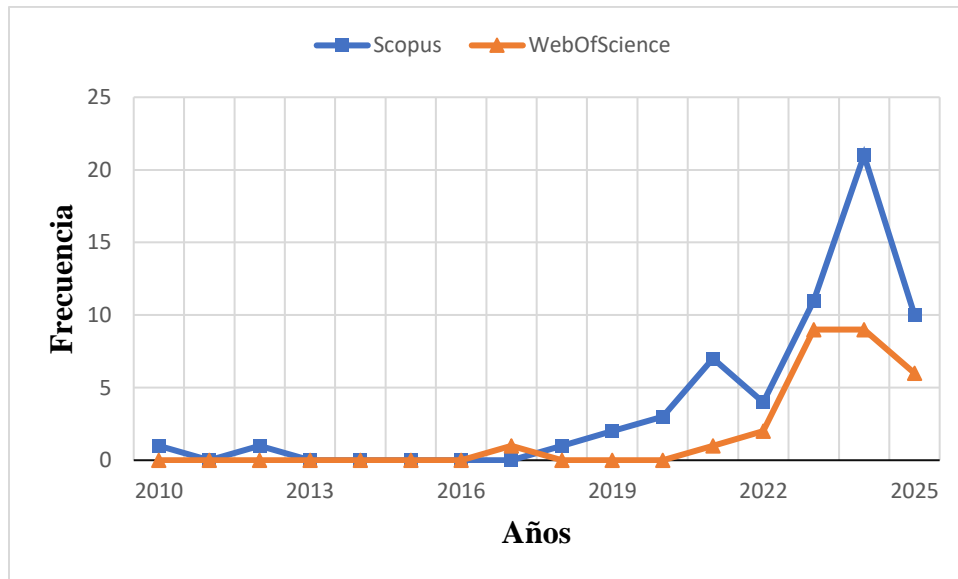
BASES DE DATOS	ECUACIÓN DE BÚSQUEDA
Scopus	TITLE-ABS-KEY (ai OR "Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND ("Predictive Models" OR "Forecasting Models" OR "Prediction Algorithms") AND ("Financial Decision Making" OR "Financial Forecasting" OR "Investment Analysis") Web of Science AND (LIMIT-TO (DOCTYPE,"ar")) AND (LIMIT-TO (LANGUAGE,"English"))
Web of Science	(AI OR "Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND ("Predictive Models" OR "Forecasting Models" OR "Prediction Algorithms") AND ("Financial Decision Making" OR "Financial Forecasting" OR "Investment Analysis")

Con el objetivo de reducir la dispersión de los datos fue necesario excluir las áreas que no estaban directamente relacionadas con el estudio en las bases de datos. La **Tabla 7** recopila el resultado de las ecuaciones de búsqueda utilizada en las bases de datos consultadas. La **Figura 2** indica la distribución de esa información a través de los años, demostrando que desde el año 2021 la temática ha generado interés en la comunidad científica y existe una intención por seguir profundizando en estos temas.

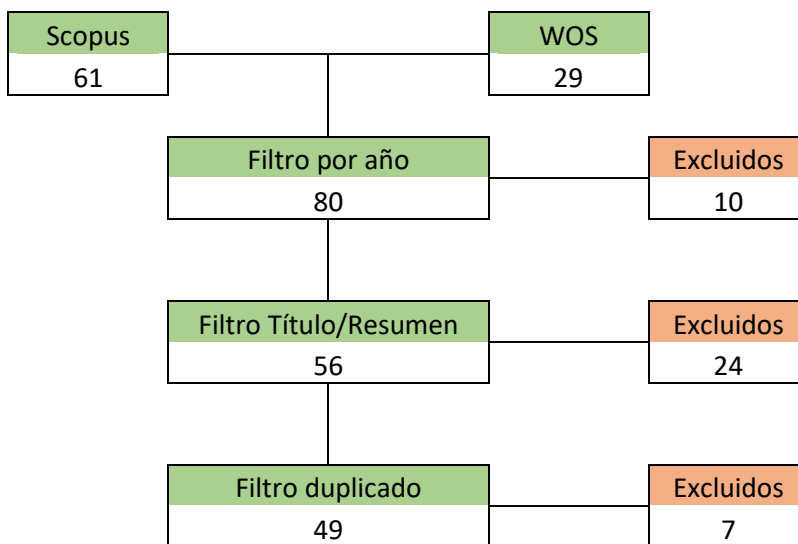
Tabla 7

Cantidad de documentos encontrados en las bases de datos

Base de datos	Cantidad de documentos	Más antiguo	Más nuevo
Scopus	61	2010	2025
Web of Science	29	2017	2025

Figura 2*Documentos Publicados por Año*

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 3 recopila el resultado de este proceso, con 49 artículos.

Figura 3*Proceso de depuración de documentos duplicados*

Concluida esta etapa es necesario iniciar con el análisis bibliométrico teniendo en cuenta las palabras claves, coautoría, país de afiliación. Iniciando con el análisis de palabras clave, la figura 3 nos presenta el diagrama de coocurrencia generado a partir de la base de datos extraída de Scopus utilizando VOSviewer, se identifican 3 clústeres que reflejan las temáticas principales, es de esperarse que en el clúster rojo el término “machine learning” resalte ya que esta es una rama de la inteligencia artificial relacionada al análisis de datos secuenciales como series de tiempo, análisis de sentimientos y predicciones, estando presente también el término LSTM, que muestra un enfoque orientado al uso de modelos de aprendizaje automático para predecir las tendencias de los estudios correspondientes. El clúster verde reúne términos relacionados con el comercio, extracción de datos e inversiones, indicando una línea de investigación enfocada en pronósticos usados para entornos comerciales y financieros que requieran el procesamiento de grandes volúmenes de datos. El clúster azul nos presenta el término “Deep learning”, su uso para predicciones de precio y análisis de componentes independientes, que nos indica la presencia de

las redes neuronales y métodos avanzados para realizar predicciones de precios. Una característica para destacar es la presencia compartida del término “long short-term memory”, una técnica que interrelaciona los diferentes clústeres.

Figura 4

Diagrama de coocurrencia de palabras clave encontradas en Scopus

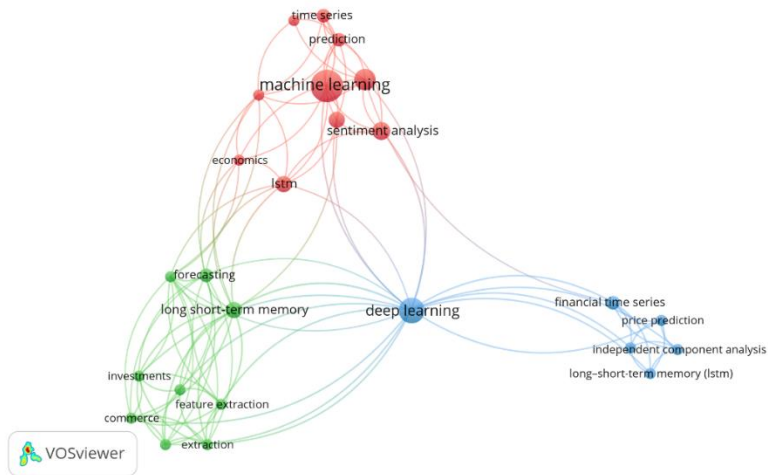
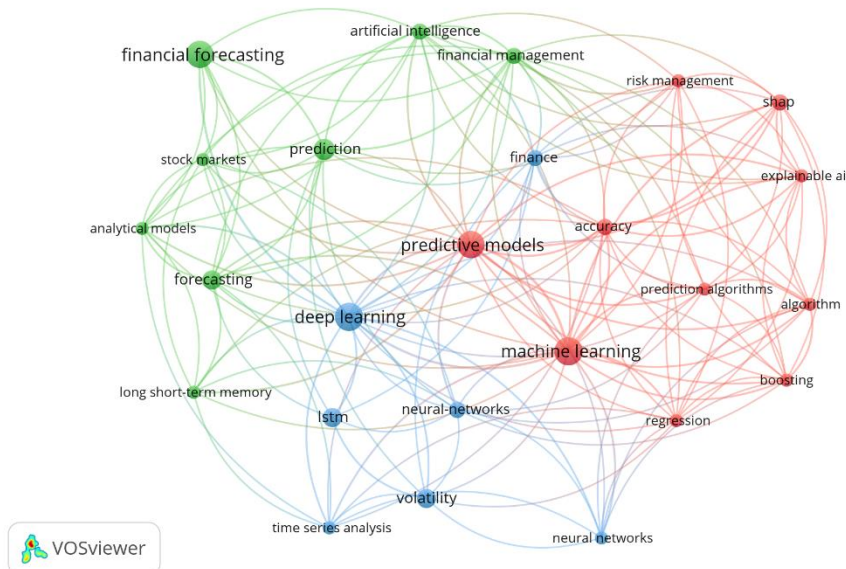


Figura 5

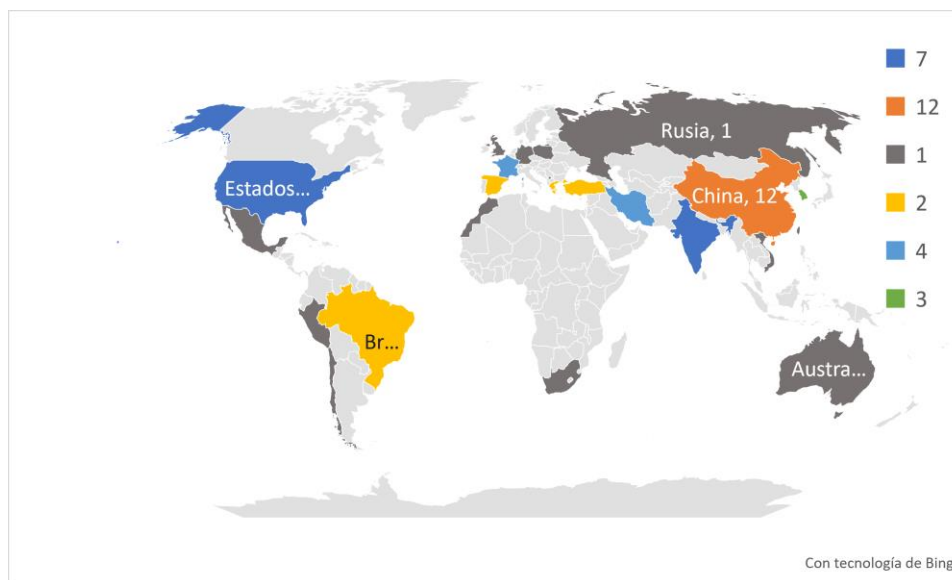
Diagrama de coocurrencia de palabras clave encontradas en WOS



Analizando el diagrama generado para WOS en la **Figura 4**, podemos identificar 3 clústeres principales y la presencia constante de “deep learning” y “machine learning”, el clúster rojo agrupa modelos predictivos y machine learning, asociando metodologías de aprendizaje automático como “boosting”, “regression” y “algorithms”, demostrando un interés en el mejoramiento de los modelos predictivos. El clúster verde se enfoca en las prácticas de estos modelos en finanzas, con términos como pronósticos financieros, modelos analíticos, y mercados bursátiles, teniendo una orientación hacia la gestión financiera, la predicción de los mercados bursátiles y en general la toma de decisiones estratégicas apoyadas por herramientas predictivas. El clúster azul refleja una tendencia por el uso de arquitectura de redes neuronales, que usan modelos LSTM (Long short-term model) término que tiene presencia en ambos análisis.

Figura 6

Documentos publicados por país




China presenta la mayor cantidad de publicaciones con 12 artículos, 6 de estos pertenecientes a la fundación de ciencias naturales de China, seguido de Estados Unidos e India,

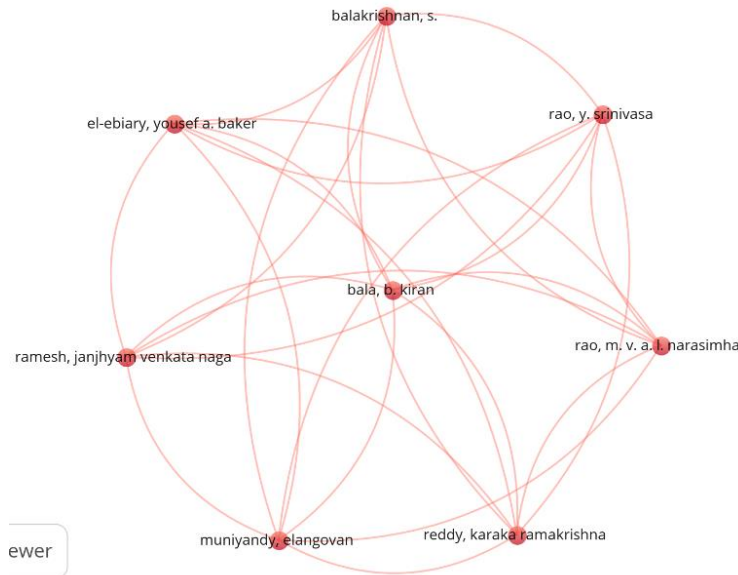
con 7 cada uno, la relevancia de estas grandes potencias afirman la presencia del uso de modelos predictivos para toma de decisiones financieras, en el segundo nivel de productividad se encuentran países como Francia e Irán, con 4 publicaciones cada uno, Corea del sur con 3 artículos, demostrando una participación relevante de naciones asiáticas en este tema; países como Brasil, Turquía, Grecia y España presentan producciones intermedias, al final tenemos países como México, Australia, vietnam, con una sola publicación, presentando una dispersión que demuestra la participación internacional alta en el tema de estudio

Figura 7

Diagramas de coocurrencia de autores por Scopus



El autor hunjra, Ahmed Imran es el nodo central de la red de coautoría de la Figura 7, este actúa como un puente entre dos grupos de investigadores, siendo el cluster rojo compuesto por un total de seis autores y por 4. La red general presenta vínculos realmente dispersos, hecho coherente teniendo en cuenta la naturaleza interdisciplinaria y emergente del tema abordado, deja ver que existe colaboración en el desarrollo de investigaciones pero que aún no es muy fuerte.

Figura 8*Diagramas de coocurrencia de autores por WOS*

La red de coautoría de WOS presenta un clúster altamente conectado, formando una red completamente densa, esto indica el trabajo mutuo que estos han realizado y la fuerte cohesión en las actividades investigativas, alrededor de Bala, B Kiran se sitúan la mayoría de conexiones, pero cabe resaltar que no sus conexiones tienen pesos iguales entre sí, en general, ambas figuras de coautoría nos una poca relación entre autores de este tema.

5.2 Modelos predictivos basados en IA para la toma de decisiones financieras

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.

5.2.1 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).

Con el fin de sintetizar de una mejor forma y organizar los principales enfoques de esta categoría general, se realizó la **Tabla 8**, donde se presenta una clasificación de los modelos

predictivos que están basados en redes neuronales, junto con una descripción general y los autores que utilizaron estos en sus investigaciones.

Tabla 8

Modelos predictivos basados en redes neuronales identificados

Tipo de modelo	Algoritmos representativos	Descripción general	Autores
Redes neuronales artificiales y recurrentes	ANN, RNN, LSTM, GRU, BiLSTM	Modelos neuronales utilizados para capturar relaciones no lineales y dependencias temporales en series financieras, ampliamente aplicados en tareas de predicción de precios, rendimientos y volatilidad.	Nguyen et al. (2019), Khalil et al. (2022), Kanzari et al. (2023), Jin et al. (2023), Zhang et al. (2021), Chen et al. (2023)
Redes neuronales profundas	DNN, DBN, CNN, DNN-FE	Arquitecturas profundas que incorporan múltiples capas ocultas y mecanismos avanzados de extracción de características para mejorar la capacidad predictiva en entornos financieros complejos.	Lin et al. (2025), Aljawazneh et al. (2021), Chen et al. (2023), Chahuán-Jiménez et al. (2024)
Modelos neuronales recurrentes avanzados	LSTM, GRU, SimpleRNN, BiLSTM	Enfoques neuronales especializados en el modelado secuencial de series de tiempo financieras, orientados a capturar patrones dinámicos y dependencias de largo plazo.	Nguyen et al. (2024), Safari et al. (2024), Kanzari et al. (2023), Zhang et al. (2021)
Modelos neuronales combinados	LSTM-CNN, CNN-ANN, LSTM-DNN	Modelos que combinan diferentes arquitecturas neuronales para aprovechar capacidades complementarias de representación y aprendizaje en la predicción financiera.	Chahuán-Jiménez et al. (2024), Aljawazneh et al. (2021), Chen 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.

Con el propósito de sintetizar los principales enfoques de aprendizaje automático utilizados, se construyó la **Tabla 9**, presentado una clasificación de los modelos predictivos, destacando los algoritmos representativos, características generales y autores que los emplean.

Tabla 9

Modelos predictivos basados en aprendizaje automático identificados

Tipo de modelo de aprendizaje automático	Algoritmos representativos	Descripción general	Autores
Modelos de regresión y clasificación supervisada	Support Vector Machine, Logistic Regression	Modelos supervisados empleados para identificar relaciones entre variables financieras y realizar predicciones a partir de datos estructurados, destacándose por su simplicidad y capacidad de generalización.	Kuryłek et al. (2020), Kılıç et al. (2022), Kim et al. (2021)
Modelos de ensamble basados en árboles	Random Forest, Gradient Boosting, XGBoost	Enfoques que combinan múltiples modelos de decisión para mejorar la estabilidad y el desempeño predictivo en contextos financieros complejos.	Aruleba et al. (2023), Acharya et al. (2024), Mirza et al. (2021), Wei et al. (2022)
Modelos de aprendizaje automático aplicados a big data financiero	Algoritmos de clasificación supervisada	Modelos diseñados para analizar grandes volúmenes de datos financieros de alta frecuencia, orientados a la identificación de patrones y	Vitale et al. (2020), Bai et al. (2021)

		comportamientos del mercado.	
Modelos de aprendizaje automático para análisis financiero y macroeconómico	Árboles de decisión y modelos supervisados	Enfoques aplicados al análisis de variables macroeconómicas y financieras, utilizados para capturar relaciones complejas sin recurrir a arquitecturas neuronales profundas.	Syriopoulos et al. (2022), Aruleba et al. (2023)

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.

En la **Tabla 10** se presenta un resumen de los principales modelos híbridos encontrados en la literatura, en donde se muestra las principales técnicas integradas, junto con una descripción general y los autores correspondientes que las abordaron en sus estudios. El análisis del uso que les dieron no corresponde a esta caracterización, es parte del análisis posterior, donde se hablará del uso en entornos financieros.

Tabla 10*Modelos predictivos híbridos identificados*

Tipo de modelo de aprendizaje automático	Algoritmos representativos	Descripción general	Autores
Modelos de aprendizaje automático híbrido LSTM	Algoritmos de clasificación supervisada	Modelos diseñados para analizar grandes volúmenes de datos financieros de alta frecuencia, orientados a la identificación de patrones y comportamientos del mercado.	Vitale et al. (2020), Bai et al. (2021)
Modelos de ensamble basados en árboles	Random Forest, Gradient Boosting, XGBoost	Enfoques que combinan múltiples modelos de decisión para mejorar la estabilidad y el desempeño predictivo en contextos financieros complejos.	Aruleba et al. (2023), Acharya et al. (2024), Mirza et al. (2021), Wei et al. (2022)
Modelos de regresión y clasificación supervisada	Support Vector Machine, Logistic Regression	Modelos supervisados empleados para identificar relaciones entre variables financieras y realizar predicciones a partir de datos estructurados, destacándose por su simplicidad y capacidad de generalización.	Kuryłek et al. (2020), Kılıç et al. (2022), Kim et al. (2021)
Modelos de ensamble basados en árboles	Random Forest, Gradient Boosting, XGBoost	Enfoques que combinan múltiples modelos de decisión para mejorar la estabilidad y el desempeño predictivo en contextos financieros complejos.	Aruleba et al. (2023), Acharya et al. (2024), Mirza et al. (2021), Wei et al. (2022)

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, traduciéndose 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.

El resumen de estos se encuentra en la **Tabla 11**, donde se muestra la relación que existe entre los tipos de enriquecimiento integrados y los enfoques de modelos que se utilizaron, permite evidenciar el papel de datos de contexto como insumo para mejorar los resultados predictivos y el alcance que estos podrían tener.

Tabla 11

Modelos predictivos enriquecidos identificados

Tipo de modelo enriquecido	Tipo de enriquecimiento	Descripción general	Autores
Modelos enriquecidos con reducción de dimensionalidad	Reducción de dimensionalidad (PCA) e integración de	Integran técnicas de reducción de dimensionalidad con información externa no financiera, permitiendo mejorar la	Liu et al. (2024)

y variables externas	variables ambientales	representación de los datos y la precisión predictiva en mercados accionarios.	
Modelos enriquecidos con integración de factores macroeconómicos	Variables macroeconómicas	Integran factores macroeconómicos globales para contextualizar la dinámica de los activos financieros y reducir el error de predicción en mercados altamente especulativos.	Giri et al. (2025)
Modelos enriquecidos con explicabilidad	XAI (SHAP, LIME) y análisis causal	Incorporan técnicas de explicabilidad que permiten interpretar el comportamiento del modelo y comprender la influencia de las variables en el proceso predictivo.	Goodell et al. (2023)
Modelos enriquecidos con selección avanzada de características	Selección de características (annealing, LASSO)	Utilizan métodos avanzados de selección de variables para reducir ruido y dimensionalidad, mejorando la estabilidad y precisión de los modelos predictivos.	Pabuccu et al. (2024)
Modelos enriquecidos con sentimiento basado en modelos de lenguaje	Índices de sentimiento y modelos de lenguaje	Integran información textual procesada mediante modelos de lenguaje para evaluar su impacto en la predicción de mercados financieros.	Jesus et al. (2025)
Modelos enriquecidos para gestión de riesgos	Dependencias estadísticas y clustering	Incorporan medidas de dependencia estadística y técnicas de análisis avanzado para identificar límites de riesgo en mercados de commodities y minerales críticos.	Choi et al. (2024)

5.2.2 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.

De manera similar, los modelos que integran sentimientos de mercado y variables conductuales tienden al cortoplacismo e incluso a horizontes inmediatos, Barua et al. (2023) desarrolla un enfoque híbrido para estimar señales de miedo y codicia utilizadas posteriormente para la optimización de portafolios. En este caso el estudio decide basarse en el corto plazo, dado que los indicadores de sentimiento son altamente transitorios y pierden su capacidad explicativa conforme avanza el horizonte temporal.

Los trabajos que integran análisis de sentimientos y procesamiento de lenguaje natural se destacan por privilegiar horizontes cortos de predicción. Li et al. (2024) se basa en modelos estructurados con LSTM que combinan análisis de sentimientos extraídos de redes sociales, sitios webs de noticias financieras y comentarios de expertos, con el objetivo de construir estrategias

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 sentimiento en diferentes roles de mercado (inversionista, consumidor, productos) logrando demostrar la mejora predictiva a comparación de métodos tradicionales que únicamente utilizan información histórica. La capacidad de procesamiento avanzada de estos modelos da puerta a capturar patrones no lineales y dinámicas temporales complejas que serían difíciles de obtener con métodos tradicionales.

El análisis de los estudios seleccionados permitió una identificación de los horizontes de predicción utilizados por los modelos basados en inteligencia artificial presentes en la literatura, la **Tabla 12** sintetiza esta clasificación en horizontes intradía, diario, mediano y multi horizonte.

Tabla 12

Horizontes de predicción en modelos basados en inteligencia artificial

Horizonte de predicción	Características principales	Autores
Intradía	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)

Corto plazo	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); Sarıkoç 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)
Mediano plazo	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)
Largo plazo	Predicciones estructurales asociadas a quiebra financiera, estabilidad sistémica y planificación estratégica.	Yu-Cheng Lin et al. (2025); Aljawazneh et al. (2021); Fozap (2025)
Multihorizonte	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)

5.3 Segmentos financieros y tipos de decisiones

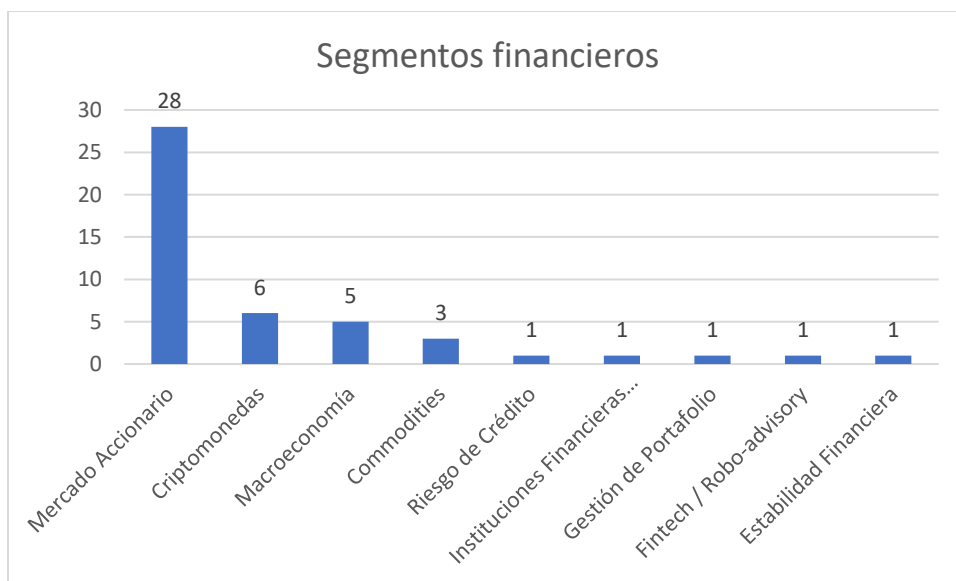
5.3.1 Segmentos financieros.

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 8**, la literatura tiene un enfoque alto en las predicciones aplicadas a mercados accionarios, criptomonedas y macroeconomía.

Figura 9

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 combinó 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.

En esta sección se exploran las categorías identificadas en la literatura estudiada, para lograr una comprensión más amplia de los diferentes artículos que componen las categorías, la Tabla 13 contiene un resumen del segmento financiero, sus aplicaciones, el alcance de impacto que pueden lograr y sus correspondientes autores.

Tabla 13

Segmentos financieros

Segmento financiero	Aplicación de modelos predictivos	Alcance	Autores
Mercado accionario	Predicción de precios, tendencias direccionales, volatilidad y rendimientos en acciones e índices bursátiles, con aplicaciones en inversión, trading algorítmico, asignación de activos y gestión del riesgo	Muy alto	Almeida et al. (2021); Amiri et al. (2025); Koo (2022); Khattak et al. (2023); Deep (2024); Liu y Lai (2024); Yang et al. (2023); Li et al. (2024); Lin y Hsu (2024); Kılıç et al. (2023); Bao et al. (2025); Safari y Badamchizadeh (2024); Wei et al. (2024); Pitta de Jesus et al. (2025); Zhang et al.

			(2025); Pokou et al. (2024); Peujio Fozap (2025); Balakrishnan et al. (2025); Khalil et al. (2022); Chahuán-Jiménez (2024); Safari y Ghaemi (2025); Sarıkoç et al. (2025); Jin (2023); Zhang et al. (2021); Kim (2025); Chen et al. (2023)
Criptomonedas	Predicción de precios, volatilidad y rendimientos en criptoactivos altamente volátiles (Bitcoin, Ethereum, NFTs y pares de divisas cripto), orientada a estrategias de inversión, trading y gestión del riesgo	Alto	Nagdiya et al. (2024); Giri et al. (2025); Nguyen et al. (2024); Behera et al. (2024); Goodell et al. (2023); Praveen et al. (2025)
Commodities	Pronóstico de precios y volatilidad en materias primas (petróleo, algodón, metales industriales) y activos reales (transporte marítimo), orientado a gestión de riesgo e inversión sectorial	Alto	Xu y Wang (2023); Vitale y Robinson (2025); Choi y Kim (2024); Syriopoulos et al. (2021)
Macroeconomía y estabilidad financiera	Predicción de inflación, estrés financiero, quiebras empresariales y volatilidad sistémica para apoyo a políticas económicas y estabilidad financiera	Alto	Kuryłek (2024); Lin et al. (2025); Mirza et al. (2024); Chung et al. (2023); Kanzari et al. (2023)
Gestión de portafolio	Optimización de carteras internacionales mediante integración de sentimiento, modelos híbridos y enfoques bayesianos	Alto	Barua et al (2023)
Riesgo de crédito y real estate	Evaluación del riesgo de incumplimiento crediticio y predicción de precios inmobiliarios con énfasis en explicabilidad y equidad algorítmica	Medio	Aruleba et al (2024); Acharya et al. (2024)
Fintech / Robo-advisory	Predicción del comportamiento del consumidor financiero y adopción de asesores automatizados para estrategias de marketing financiero	Medio	Bai (2024)
Instituciones financieras	Pronóstico de flujos de efectivo, cuentas por cobrar y pagar, y apoyo a la planeación financiera y estratégica en entidades bancarias	Medio	Almeida et al. (2021)

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.

5.3.1 Tipos de decisiones.

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 que se 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.

Aunque la mayor parte de la literatura revisada corresponde a esas tres grandes categorías de decisión, el análisis muestra evidencia de otras decisiones financieras, que no son mayoritarias pero que resultan relevantes de mencionar, estas se encuentran en la tabla **Tabla 14**.

Tabla 14*Tipos de decisiones financieras específicas*

Tipo de decisión financiera	Elementos involucrados	Autores
Política monetaria y macroeconómica: Decisiones orientadas al pronóstico de variables macroeconómicas clave para apoyar la formulación y evaluación de políticas económicas en economías emergentes.	Inflación (IPC), PIB, oferta monetaria (M2), tasas de interés, tipo de cambio, reservas internacionales, modelos de aprendizaje automático.	Mirza <i>et al.</i> (2024)
Marketing financiero y adopción de tecnología: Decisiones enfocadas en identificar perfiles de consumidores con alta probabilidad de adopción de servicios financieros digitales, optimizando estrategias de captación y segmentación.	Datos demográficos, alfabetización financiera, tolerancia al riesgo, uso de tecnología, modelos de clasificación y selección de variables.	Bai (2024)
Estabilidad sistémica y política económica: Decisiones dirigidas a la detección temprana de inestabilidad macro financiera mediante el análisis predictivo de indicadores de estrés y variables de sentimiento económico.	Índice de estrés financiero, sentimiento del consumidor, productor e inversor, series temporales macroeconómicas, modelos LSTM.	Kanzari <i>et al.</i> (2023)
Financiamiento e inversión en activos reales: Decisiones relacionadas con la valoración y financiamiento de activos físicos a partir del pronóstico de precios, apoyando inversiones sectoriales de largo plazo.	Precios históricos de activos reales, tarifas de flete, precios de insumos (acero), tasas de interés, modelos SVR.	Syriopoulos <i>et al.</i> (2021)
Optimización de cartera: Decisiones orientadas a la asignación y rebalanceo óptimo de portafolios internacionales mediante la integración de modelos predictivos y enfoques de optimización.	Rendimientos históricos, indicadores técnicos, sentimiento de mercado (miedo/codicia), modelos híbridos ML, enfoque Black-Litterman.	Barua y Sharma (2023)

5.4 Documentación de beneficios, limitaciones y oportunidades de mejora

5.4.1 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) demuestran 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. Con el fin de sintetizar y estructurar estos beneficios de manera clara y sistemática, en la **Tabla 15** se presenta una agrupación de los principales beneficios identificados, junto con su descripción y los elementos relacionados, proporcionando una visión integrada del aporte de la inteligencia artificial a los procesos de toma de decisiones financieras.

Tabla 15

Beneficios de los modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras

Beneficio	Descripción	Elementos relacionados
Evaluación integral del sistema financiero	Análisis amplio y multidimensional de mercados, activos y procesos financieros que surge de la convergencia de múltiples modelos predictivos y fuentes de información, permitiendo comprender simultáneamente el comportamiento temporal, la volatilidad, la incertidumbre y el contexto macroeconómico para fortalecer la toma de decisiones financieras.	Tipos de decisiones financieras, modelos predictivos, series temporales, variables financieras y macroeconómicas, horizontes temporales.
Mejora de la precisión y robustez predictiva	Incremento consistente en la exactitud, estabilidad y confiabilidad de los pronósticos financieros mediante modelos avanzados capaces de capturar dependencias temporales de corto y largo plazo, relaciones no lineales y patrones complejos, incluso en entornos altamente volátiles o ruidosos.	Series temporales financieras, precios históricos, volatilidad, arquitecturas de deep learning, modelos híbridos y de ensamble.
Gestión avanzada de la volatilidad, el ruido y la incertidumbre	Capacidad de los modelos para mitigar el ruido inherente a los datos financieros, corregir sesgos estadísticos y representar	Volatilidad financiera, datos ruidosos, colas pesadas, heterocedasticidad,

	adecuadamente comportamientos extremos como colas pesadas, heterocedasticidad y fluctuaciones abruptas del mercado.	técnicas de descomposición y normalización.
Integración de información no tradicional y señales adelantadas	Incorporación de variables externas como sentimiento del mercado, atención del inversor, factores macroeconómicos, ambientales y textuales, ampliando el marco analítico clásico y mejorando la capacidad explicativa y predictiva de los modelos financieros.	Sentimiento de mercado, atención del inversor, variables macroeconómicas, datos ambientales, información textual y alternativa.
Optimización de decisiones financieras bajo múltiples criterios	Evaluación simultánea de objetivos como rentabilidad, riesgo, estabilidad y desempeño ajustado, mediante modelos híbridos, enfoques probabilísticos y algoritmos de optimización que permiten alcanzar soluciones más equilibradas y eficientes frente a la incertidumbre financiera.	Algoritmos de optimización, metaheurísticas, simulaciones, métricas de desempeño financiero, modelos híbridos.
Fortalecimiento de la toma de decisiones basada en datos	Transformación de grandes volúmenes de información financiera en conocimiento accionable, permitiendo decisiones más informadas, justificables y reproducibles en contextos macroeconómicos, organizacionales y de mercado.	Big data financiero, analítica predictiva, sistemas de apoyo a decisiones, interpretación de resultados.
Mejora de la interpretabilidad, transparencia y confianza en los modelos	Incremento de la explicabilidad y comprensión de modelos predictivos complejos, facilitando la identificación de variables clave, el cumplimiento regulatorio y la aceptación de sistemas basados en inteligencia artificial en entornos financieros sensibles.	Transparencia algorítmica, interpretabilidad, confianza en modelos.
Anticipación temprana de eventos críticos y condiciones extremas	Capacidad de identificar de forma anticipada episodios de estrés financiero, crisis, quiebras o cambios estructurales del mercado mediante señales latentes y variables adelantadas.	Estrés financiero, crisis económicas, quiebra, límites de riesgo, indicadores adelantados.

5.4.2 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 su 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.

Para sintetizar estas limitaciones de forma estructurada, la **Tabla 16.** presenta una agrupación de las principales limitaciones y oportunidades de mejora, junto con los elementos relacionados, lo que permite una visión crítica e integrada de los desafíos que aún persisten en la aplicación de modelos predictivos basados en IA para la toma de decisiones financieras.

Tabla 16

Limitaciones de los modelos predictivos basados en inteligencia artificial para la toma de decisiones financieras

Limitación	Descripción	Elementos relacionados
Limitada generalización y dependencia del contexto	Muchos modelos son evaluados en mercados, activos, países o instituciones específicas, lo que restringe su capacidad de generalización a otros contextos financieros con diferentes regímenes regulatorios, niveles de liquidez o estructuras económicas.	Segmento financiero, activo analizado, contexto geográfico, régimen económico, validez externa.
Dependencia excesiva de datos históricos	Una parte significativa de los modelos se basa principalmente en datos históricos de precios o retornos, lo que limita su capacidad de adaptación ante cambios estructurales, crisis financieras, eventos geopolíticos.	Series temporales históricas, supuestos de estacionariedad, cambios estructurales, eventos extremos.
Insuficiente integración de	Persisten brechas en la incorporación sistemática de variables macroeconómicas, regulatorias,	Variables macroeconómicas,

variables externas relevantes	fundamentales, sentimentales o cualitativas, lo que reduce la capacidad explicativa y anticipatoria de los modelos.	sentimiento de mercado, noticias, factores regulatorios y geopolíticos.
Alta complejidad computacional y costos de implementación	Muchos enfoques híbridos y modelos profundos presentan elevados requerimientos computacionales, tiempos de entrenamiento prolongados y dificultades de implementación práctica, especialmente en entornos con restricciones de recursos.	Arquitecturas profundas, modelos híbridos, metaheurísticas, infraestructura computacional.
Falta de validación económica y realista	Numerosos estudios priorizan métricas estadísticas de error, sin incorporar backtesting robusto, costos de transacción, liquidez o restricciones operativas reales, lo que limita la evaluación del impacto económico de los modelos.	Métricas de evaluación, costos de transacción, backtesting, rentabilidad ajustada por riesgo.
Problemas de interpretabilidad y transparencia	A pesar de los avances, muchos modelos continúan funcionando como “cajas negras”, dificultando la comprensión de los factores que influyen en las predicciones y limitando su aceptación en entornos financieros regulados.	Interpretabilidad, confianza del usuario, regulación financiera.
Sensibilidad a la calidad, disponibilidad y frecuencia de los datos	El desempeño de los modelos depende fuertemente de la calidad, volumen y frecuencia de los datos, lo que genera problemas cuando existen datos incompletos, desbalanceados, con ruido o con rezagos en su publicación.	Calidad de datos, desbalanceo, latencia, big data financiero, ingeniería de características.
Supuestos metodológicos restrictivos	Algunos modelos incorporan supuestos estructurales que pueden simplificar excesivamente la dinámica financiera, como distribuciones específicas, relaciones lineales-no lineales fijas o ventanas temporales rígidas.	Supuestos estadísticos, funciones de distribución, ventanas temporales, estructura del modelo.

6. Conclusiones

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 representativa. Asimismo, se identificaron 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.

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 los 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 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 los 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.

Finalmente, como resultado de este proyecto se llevó a cabo la elaboración de un artículo científico que recopila los hallazgos más importantes encontrados durante esta revisión de literatura que proporciona una vista más detallada a la actualidad y futuro de la aplicación de modelos predictivos basados en inteligencia artificial.

7. Recomendaciones

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.

Los 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 tecnológica.

Referencias bibliográficas

- 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>
- 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>
- 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>
- 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>
- 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].
- 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>
- 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>

- 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>
- 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>
- Brigham, E. F., & Ehrhardt, M. C. (2022). *Financial management: Theory & practice* (17th ed.). Cengage Learning.
- 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>
- 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>
- 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>
- Gitman, L. J., & Zutter, C. J. (2019). *Principles of managerial finance* (15th ed.). Pearson.
- 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>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- 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>
- 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>
- 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>
- 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
- 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>
- 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>
- 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.
- 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](https://www.sciencedirect.com)+12ouci.dntb.gov.ua+12ideas.repec.org+12
- Munárriz, L. (1994). *Fundamentos de Inteligencia*. Naciones Unidas. (2013). *Economía digital para el cambio estructural y la igualdad*. Santiago de Chile.
- 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>
- 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>
- Rouhiainen, L. (2018). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- 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>
- 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>
- 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>
- 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>
- 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>
- 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>
- 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.