

Redes neuronales artificiales en finanzas: evaluación de su utilidad en proyecciones

Artificial neural networks in finance: assessing their usefulness in projections

Darío Alejandro Segovia Hernández,^{*} Rosa Marina Madrid Paredones^{**}
y Luis Enrique Gómez Medina^{***}

^{*}Instituto de Investigaciones y Estudios Superiores de las Ciencias Administrativas. Universidad Veracruzana.
Correo electrónico: zS22024651@estudiantes.uv.mx. ORCID: <https://orcid.org/0009-0009-6977-5318>

^{**}Instituto de Investigaciones y Estudios Superiores de las Ciencias Administrativas. Universidad Veracruzana.
Correo electrónico: rmadrid@uv.mx. ORCID: <https://orcid.org/0000-0002-3579-0386>

^{***}Instituto de Investigaciones y Estudios Superiores de las Ciencias Administrativas. Universidad Veracruzana.
Correo electrónico: luisgomez04@uv.mx. ORCID: <https://orcid.org/0009-0009-1324-389X>

RESUMEN

Este trabajo analiza el papel de las redes neuronales artificiales (RNA) en las finanzas, centrándose en su capacidad para generar proyecciones financieras. Se revisan estudios teóricos y casos prácticos que demuestran la efectividad de las RNA en el procesamiento de grandes volúmenes de datos y en la adaptación a cambios, lo que las hace valiosas para pronósticos financieros. A través de un análisis exhaustivo de estudios recientes, se comparan diferentes enfoques de RNA con métodos tradicionales. Los casos de estudio incluyen la predicción de quiebras empresariales, la optimización de portafolios de inversión y la estimación de precios de activos como el petróleo. Se concluye que, a pesar de ciertos desafíos, las RNA ofrecen ventajas significativas en la generación de proyecciones financieras, mejorando tanto la precisión como la eficiencia en la toma de decisiones.

ABSTRACT

This article analyzes the role of artificial neural networks (ANN) in finance, focusing on their ability to generate financial projections. The study examines theoretical frameworks and practical cases that demonstrate the effectiveness of ANN in processing large amounts of data and adapting to change, making them valuable for financial forecasting. A comprehensive analysis of recent studies is used to compare different ANN approaches with traditional methods. Case studies include the prediction of corporate bankruptcies, the optimization of investment portfolios and the estimation of asset prices such as oil. The conclusion is that despite certain challenges, ANN offer significant advantages in financial forecasting and improve both the accuracy and efficiency of decision making.

Recibido: 16/abril/2024
Aceptado: 18/septiembre/2024
Publicado: 19/mayo/2025

Palabras clave:

| Redes neuronales artificiales | Pronósticos | Finanzas | Planeación |

Keywords:

| Financial inclusion | Financial policy | Economic growth | Public policy evaluation | Financial inclusion variables |

Clasificación JEL |

JEL Classification |
C53, C45, D53, G29

INTRODUCCIÓN

Las RNA han surgido como herramientas poderosas en el ámbito financiero, ofreciendo soluciones innovadoras para generar proyecciones financieras y facilitar procesos de toma de decisiones. En el panorama financiero actual, dinámico y complejo, la capacidad para pronosticar tendencias y anticipar movimientos del mercado es crucial para empresas e inversores. Sin embargo,



Esta obra está protegida
bajo una Licencia
Creative Commons
Reconocimiento-
NoComercial-
SinObraDerivada 4.0
Internacional

los métodos tradicionales para proyecciones financieras a menudo no logran capturar las complejidades de los mercados modernos, lo que motiva la exploración de enfoques alternativos como las RNA.

Este trabajo tiene como objetivo explorar el papel de las RNA en las proyecciones financieras, abordando el problema central de su efectividad y aplicabilidad en la generación de pronósticos precisos y confiables. Mediante una revisión detallada de la literatura existente y el análisis de estudios de casos relevantes, esta investigación busca arrojar luz sobre los fundamentos teóricos y las implicaciones prácticas de emplear RNA en finanzas.

La importancia de esta investigación radica en su potencial para mejorar nuestra comprensión de cómo las RNA pueden revolucionar las prácticas de pronóstico financiero. Al aprovechar su capacidad para procesar grandes cantidades de datos, adaptarse a condiciones de mercado cambiantes y descubrir patrones complejos, las RNA ofrecen vías prometedoras para mejorar la precisión y eficiencia de las proyecciones financieras.

Basándose en una variedad de fuentes bibliográficas, que incluyen marcos teóricos y estudios empíricos, este trabajo tiene como objetivo establecer una base sólida para su hipótesis: que las RNA representan una herramienta valiosa para generar proyecciones financieras con mayor precisión y confiabilidad, en comparación con los métodos tradicionales.

Estructurado en cuatro secciones, este trabajo comienza con una visión general del estado actual de la investigación sobre las RNA en finanzas, seguida de una exploración de los principios teóricos que subyacen a su funcionamiento. Posteriormente, el documento examina varios estudios de casos que demuestran las aplicaciones prácticas de las RNA en el pronóstico financiero. Finalmente, la investigación concluye con una síntesis de los hallazgos clave e implicaciones, junto con sugerencias para futuras direcciones de investigación. A través de este enfoque integral, el estudio busca ofrecer ideas valiosas sobre el potencial de las RNA para transformar las prácticas de pronóstico financiero e informar los procesos de toma de decisiones en la industria financiera.

I. VARIABLES ESTRATÉGICAS

Dentro del ámbito financiero, las variables más frecuentemente utilizadas en las proyecciones son esenciales para evaluar y prever el rendimiento y la salud financiera de una empresa. Estas variables se eligen cuidadosamente para reflejar tanto la situación financiera actual como las tendencias a largo plazo.

En este contexto, las variables más comúnmente utilizadas incluyen aspectos relacionados con los estados financieros básicos. Los estados financieros básicos, que incluyen el estado de situación financiera, el estado de resultados y el estado de flujos de efectivo, proporcionan información esencial para las proyecciones financieras (Escalona *et al.*, 2019). Estos estados constituyen la columna vertebral de la contabilidad financiera y reflejan la posición, el rendimiento y la liquidez de una empresa. La proyección de la evolución de activos, pasivos, ingresos, gastos y flujos de efectivo en el futuro depende de la proyección de estas cifras basadas en datos históricos y suposiciones futuras (Lara, 2003).

Las ventas y los ingresos son variables críticas en las proyecciones financieras, ya que representan la principal fuente de ingresos para una empresa (Romero, 2006). Las proyecciones de ventas se basan en datos históricos, patrones estacionales, ciclos económicos y otros factores relacionados con el mercado. La precisión en la estimación de las ventas es esencial para determinar los ingresos futuros y, por lo tanto, para la planificación financiera.

Asimismo, los indicadores financieros,¹ como la liquidez, rentabilidad, apalancamiento y eficiencia operativa, son herramientas valiosas en las proyecciones financieras, debido a que ofrecen una visión completa de la salud financiera de una empresa y le permiten evaluar su rendimiento en diferentes áreas (García, 2000). Estos indicadores son esenciales para proyecciones precisas, ya que permiten evaluar la fortaleza financiera, rentabilidad y eficiencia operativa de la empresa.

Castro *et al.* (2019) señalan que, además de estas variables fundamentales, otros factores también pueden desempeñar un papel importante en las proyecciones financieras. Estos pueden incluir variables macroeconómicas, regulaciones gubernamentales, eventos de mercado, cambios en la industria y factores específicos de la empresa. La elección de variables de proyección y su relevancia depende en gran medida del sector de la empresa y sus objetivos financieros. La integración de una variedad de variables en el proceso de proyección permite obtener una visión más completa y precisa del futuro financiero de una empresa.

II. PROYECCIONES FINANCIERAS

Las proyecciones financieras son un pilar fundamental en la toma de decisiones empresariales, proporcionando una visión anticipada y planificada del desempeño financiero futuro de una organización (Cedeño-Choez, 2020). Esenciales para la planificación estratégica, la asignación de recursos y la evaluación de oportunidades y riesgos, estas proyecciones ofrecen estimaciones cuantitativas y cualitativas, guiando a la dirección empresarial para decisiones fundamentadas (Escalona *et al.*, 2019).

Botero y Álvarez (2013) señalan que, en un entorno empresarial dinámico y competitivo, las proyecciones financieras permiten a las organizaciones prever escenarios posibles, abarcando aspectos como ingresos, costos, flujos de efectivo, presupuestos de capital y estados financieros. Esto les brinda la capacidad de evaluar su viabilidad financiera a largo plazo, identificar áreas de crecimiento y anticipar desafíos, siendo especialmente cruciales en la asignación eficiente de recursos para expandirse, desarrollar nuevos productos o servicios, realizar adquisiciones o gestionar las operaciones diarias (Núñez, 2020).

Además, estas proyecciones son vitales para evaluar la viabilidad de proyectos y la rentabilidad de las inversiones al anticipar flujos de efectivo futuro. Esto permite análisis de sensibilidad y escenarios para comprender mejor el impacto de cambios en el entorno empresarial, facilitando decisiones informadas en circunstancias favorables y desafiantes (Sinisterra *et al.*, 2011).

Asimismo, las proyecciones financieras desempeñan un papel crucial en la evaluación de riesgos al prever posibles resultados financieros, identificando y mitigando riesgos potenciales antes de impactar la salud financiera de la organización (Lozano *et al.*, 2018). En definitiva, son un aspecto esencial para la gestión empresarial, proporcionando una base sólida y orientada al éxito a largo plazo. Sin embargo, los métodos tradicionales utilizados en proyecciones financieras han sido fundamentales en la planificación financiera durante décadas, centrándose en métodos cuantitativos y cualitativos (Makridakis y Wheelwright, 1979). A continuación, se describen algunos de los métodos tradicionales más comunes:

- **Método de series temporales.** Este método se basa en el análisis de datos históricos para predecir el futuro. Utiliza patrones y tendencias pasadas para proyectar el comportamiento futuro. En este enfoque, se aplican técnicas estadísticas para analizar y extrapolar los datos pasados,

1. Indicadores financieros son medidas cuantitativas utilizadas para evaluar y analizar el desempeño económico y financiero de una empresa. Estos indicadores proporcionan información clave sobre la salud financiera, la eficiencia operativa y la rentabilidad de una entidad, facilitando la toma de decisiones informadas por parte de los gestores y otros interesados (Méndez *et al.*, 2009)

como promedios móviles, suavizamiento exponencial y análisis de regresión. Este método es útil para proyecciones a corto plazo, pero puede no capturar cambios drásticos o eventos imprevistos.

- Método de indicadores financieros. Los indicadores financieros (como el índice de liquidez, la rentabilidad, el apalancamiento, entre otros) se utilizan para evaluar la salud financiera de una empresa. Estos indicadores se aplican a datos financieros históricos para proyectar tendencias y estimar el rendimiento futuro. Por ejemplo, un aumento histórico en la rentabilidad podría indicar un rendimiento esperado similar en el futuro.
- Método de análisis de escenarios. Este enfoque implica crear múltiples escenarios hipotéticos que representan diferentes situaciones futuras. Estos escenarios pueden basarse en cambios en variables económicas, políticas, de mercado o de la industria que podrían impactar la empresa. Se proyectan resultados financieros para cada escenario, permitiendo a la empresa planificar y prepararse para diferentes situaciones.
- Método de presupuestos. Los presupuestos se utilizan para planificar los ingresos y gastos futuros de una empresa. Se basan en estimaciones detalladas de ingresos y gastos en función de las operaciones proyectadas. Estos presupuestos son ajustados a medida que avanza el tiempo y se comparan con los resultados reales para realizar ajustes y mejoras en futuras proyecciones.
- Método de análisis de tendencias. Este enfoque se centra en identificar y proyectar tendencias históricas en los estados financieros de una empresa, como el crecimiento anual promedio en ingresos o gastos. Estas tendencias se utilizan para estimar el comportamiento futuro y pueden ser ajustadas teniendo en cuenta factores externos que podrían afectar la evolución de esas tendencias.

A pesar de su relevancia, estos métodos tienen limitaciones al no capturar cambios drásticos en el entorno socioeconómico, ni considerar el impacto de eventos inesperados. Por ello, el avance tecnológico ha impulsado el uso de enfoques más avanzados, como técnicas de aprendizaje automático y RNA, con el objetivo de mejorar la precisión de las proyecciones financieras aprovechando conjuntos de datos más amplios.

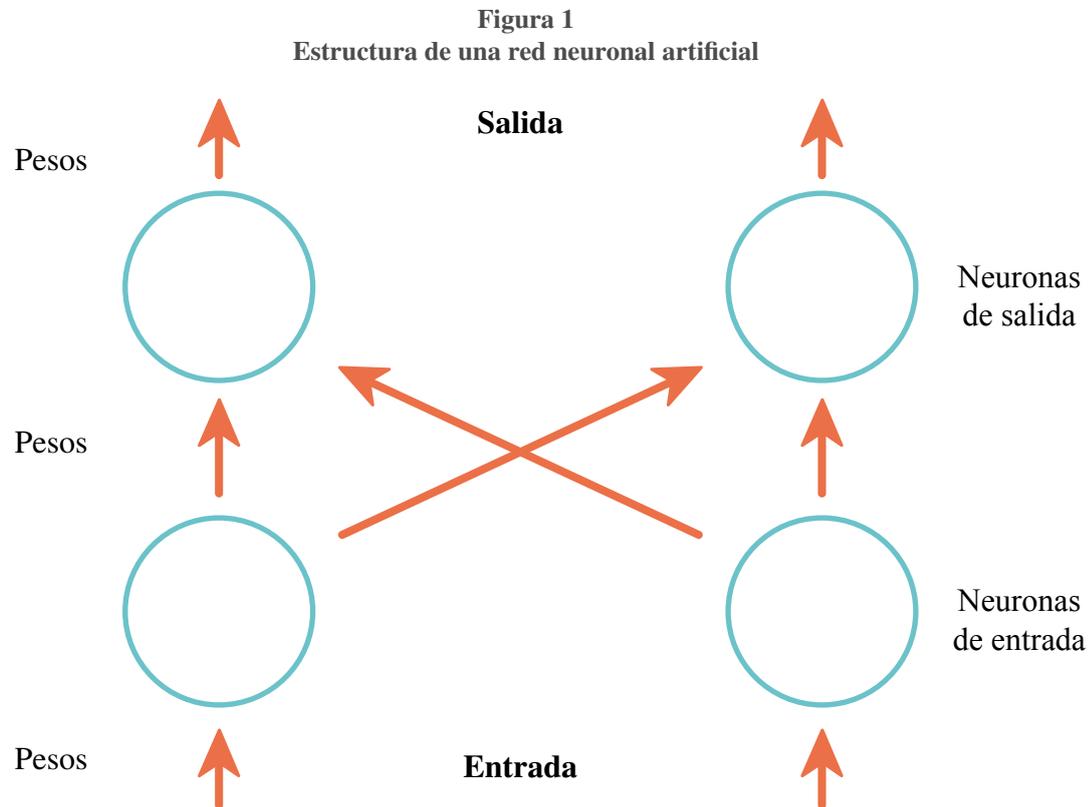
III. REDES NEURONALES ARTIFICIALES

Las RNA inspiradas en el funcionamiento del cerebro humano, son un componente clave dentro del amplio campo de la inteligencia artificial. Estas estructuras computacionales son capaces de aprender, adaptarse y realizar tareas complejas, desde el reconocimiento de patrones, hasta la toma de decisiones, de manera similar a la de los humanos (Gershenson, 2003). Su funcionamiento se basa en el procesamiento de información a través de nodos interconectados, imitando la forma en que las neuronas biológicas transmiten señales.

En esencia, una red neuronal artificial está compuesta por capas de nodos interconectados, cada uno de los cuales realiza operaciones matemáticas simples (TICPymes, 2023). Estos nodos, o neuronas artificiales, reciben múltiples entradas, las combinan mediante operaciones de ponderación y activación, y generan una salida. Cada conexión entre las neuronas tiene un peso que modifica la importancia de la señal de entrada en el cálculo de la salida (Gershenson, 2003). Este proceso se repite en toda la red, con la información fluyendo desde la capa de entrada a través de las capas ocultas hasta la capa de salida.

Por otro lado, la estructura de una red neuronal artificial (véase Figura 1) se compone de varias capas: la capa de entrada, que recibe datos crudos o información de entrada; una o más capas ocultas, responsables de procesar y aprender representaciones más complejas de los datos; y la capa de salida, que produce los

resultados finales o proyecciones (TICPymes, 2023). Cada neurona en una capa se conecta con todas las neuronas en la capa anterior y posterior, y estas conexiones contienen pesos que se ajustan durante el proceso de entrenamiento (Rojas, 1996).



Fuente: adaptado de Gershenson (2003).

Entrenar una RNA implica presentarle un conjunto de datos conocidos y permitir que la red aprenda, modificando los pesos de las conexiones entre las neuronas para minimizar la diferencia entre las proyecciones de la red y los resultados reales (Hilera y Martínez, 1995). Este proceso de aprendizaje se lleva a cabo a través de algoritmos de optimización que ajustan los pesos de las conexiones según la retroalimentación proporcionada por los datos de entrenamiento.

Hilera y Martínez (1995) señalan que, una vez entrenada, la RNA puede hacer proyecciones o tomar decisiones basadas en datos nuevos o previamente no vistos. Además, las RNA se aplican en una amplia gama de campos, incluyendo visión por computadora, procesamiento de lenguaje natural, reconocimiento de voz, control de procesos y en el ámbito financiero, entre otros. Su habilidad para comprender y extraer patrones complejos a partir de datos sin procesar y realizar proyecciones precisas, las hace especialmente útiles en la generación de proyecciones financieras, donde interpretar grandes conjuntos de datos históricos y prever tendencias futuras son cruciales para la toma de decisiones estratégicas.

Aplicación de redes neuronales artificiales en proyecciones financieras

El uso de las RNA como herramientas para generar proyecciones financieras ofrece una serie de ventajas significativas que han transformado la forma en que se abordan las proyecciones en el ámbito financiero. Estas

ventajas se derivan de la capacidad intrínseca de las RNA para aprender patrones complejos a partir de grandes conjuntos de datos, lo que les permite ofrecer resultados más precisos y adaptables, en comparación con los métodos tradicionales (Alonso y Carbó, 2022).

En este sentido, una de las ventajas de las RNA en la generación de proyecciones financieras es su capacidad para manejar eficientemente grandes volúmenes de datos. Las RNA son capaces de procesar datos de diversas fuentes, incluidas series temporales, datos financieros históricos, indicadores económicos y otros factores relevantes para la proyección financiera (Martínez-González *et al.*, 2021). A través de sus capacidades de aprendizaje automático, estas redes pueden identificar patrones y correlaciones no lineales en estos datos, proporcionando una comprensión más profunda y precisa de las tendencias financieras (Russell y Norvig, 2004).

Del Carpio (2005) destaca que, otra ventaja clave radica en la capacidad de las RNA para adaptarse a cambios y variaciones en los datos. Dado que el entorno financiero está sujeto a fluctuaciones y cambios constantes, las RNA pueden ajustar sus pesos y conexiones durante el entrenamiento para reflejar estos cambios. Este dinamismo les permite adaptarse a condiciones imprevistas y capturar relaciones complejas entre múltiples variables, lo que resulta en proyecciones más realistas y actualizadas (Morales y García, 2013).

Por otro lado, la capacidad de generalización de las RNA también es una ventaja crucial en la generación de proyecciones financieras. Después de ser entrenadas con datos históricos, estas redes pueden aplicar el conocimiento adquirido para hacer proyecciones sobre datos nuevos y previamente no vistos (Gershenson, 2003). Esta capacidad de generalización les permite identificar patrones y tendencias subyacentes en los datos, dando como resultado proyecciones más precisas y robustas, incluso en escenarios no contemplados durante el entrenamiento (Mentzer y Kahn, 1997).

Asimismo, las RNA son capaces de manejar la no linealidad y complejidad de los datos financieros. A diferencia de muchos métodos tradicionales que asumen relaciones lineales o simplificadas, las RNA pueden capturar relaciones complejas y no lineales entre múltiples variables, permitiendo una modelización más precisa y detallada de los comportamientos financieros (Toro *et al.*, 2004).

El uso de RNA para generar proyecciones financieras permite una mejora continua a medida que se alimentan con más datos y se ajustan con comentarios adicionales (Alonso y Carbó, 2022). Esto proporciona un proceso de refinamiento constante, mejorando la calidad y precisión de las proyecciones con el tiempo.

En resumen, el uso de RNA en la generación de proyecciones financieras ofrece ventajas significativas en términos de manejo de grandes volúmenes de datos, adaptabilidad a cambios, capacidad de generalización, manejo de la complejidad de los datos y mejora continua. Estas ventajas han posicionado a las RNA como herramientas poderosas y cada vez más adoptadas en el mundo financiero para tomar decisiones más informadas y precisas.

Desafíos y limitaciones de las redes neuronales artificiales

A pesar de las notables ventajas que ofrecen las RNA en la generación de proyecciones financieras, también enfrentan una serie de desafíos y limitaciones que es importante tener en cuenta. Comprender estos aspectos es crucial para una implementación efectiva y para tomar decisiones informadas en el contexto financiero.

Uno de los desafíos más significativos al aplicar RNA en proyecciones financieras es la necesidad de grandes cantidades de datos de alta calidad.² Las RNA son consumidoras voraces de datos, y su rendimiento

2. La calidad de datos se centra en la excelencia de la información almacenada, que exhiba atributos como precisión, integridad, exhaustividad, actualización, coherencia, relevancia, accesibilidad y confiabilidad para ser efectiva en aplicaciones de procesamiento, análisis y cualquier otro propósito que pueda tener un usuario.

y precisión dependen en gran medida de la disponibilidad de conjuntos de datos grandes y bien preparados (Martínez-González *et al.*, 2021). En entornos financieros, obtener datos históricos limpios y completos puede ser complicado, y la calidad de los datos puede variar significativamente.

Por otro lado, la falta de datos, o datos incorrectos, puede llevar a proyecciones inexactas y sesgadas; además, la disponibilidad de datos de series temporales lo suficientemente largas para el entrenamiento de RNA puede ser limitada, lo que puede afectar la capacidad para capturar tendencias a largo plazo (Zhang, 2004).

Morel (2012) señala que otro desafío importante es la interpretación de los modelos de RNA. Estas redes, a menudo se consideran cajas negras, lo que significa que pueden ser difíciles de entender y explicar. En el ámbito financiero, la transparencia e interpretabilidad son esenciales para justificar decisiones y cumplir con regulaciones (Melchor, 2010). En este sentido, explicar cómo una red neuronal llegó a cierta proyección puede ser desafiante, lo que dificulta la comunicación de los resultados a partes interesadas y reguladores.

La selección de la arquitectura de la red y los hiperparámetros³ también puede ser un desafío crítico. Diferentes arquitecturas de RNA y configuraciones de hiperparámetros pueden ser más apropiadas para diferentes tipos de problemas financieros (Velázquez *et al.*, 2011). La elección incorrecta puede llevar a un rendimiento deficiente y proyecciones inexactas. Esto a menudo requiere ensayo y error o experiencia en ajustar estos parámetros, lo que puede ser un proceso laborioso y requerir un conocimiento profundo (Hilera y Martínez, 1995).

La volatilidad e incertidumbre inherentes al mundo financiero también presentan un desafío. Las RNA pueden ser sensibles a cambios repentinos o eventos inesperados, lo que puede resultar en proyecciones inexactas en situaciones de crisis o mercados altamente volátiles (Pérez y Fernández, 2007).

En cuanto a los recursos, el entrenamiento y la implementación de RNA pueden requerir una potencia informática significativa, lo que puede ser costoso tanto en términos de *hardware* como de tiempo (Ortiz y Velázquez, 2002). La infraestructura informática adecuada es esencial para gestionar de manera efectiva las RNA en un entorno financiero.

En resumen, aunque las RNA ofrecen ventajas sustanciales en la generación de proyecciones financieras, enfrentan desafíos significativos relacionados con la calidad y cantidad de datos, la interpretación del modelo, la selección de arquitecturas y parámetros, la sensibilidad a eventos inesperados y los recursos requeridos. Superar estas limitaciones requiere un enfoque cuidadoso y una comprensión de las complejidades involucradas en su implementación en el contexto financiero.

IV. COMPARACIÓN DE CASOS

En esta sección, se aborda la revisión de casos de aplicación de RNA en proyecciones financieras. Para llevar a cabo esta revisión, hemos establecido criterios específicos que garantizan la relevancia y calidad de la literatura revisada. Estos criterios de selección se basan en factores clave, como la fecha de publicación, dándole prioridad a investigaciones recientes; la calidad de la investigación y su aplicabilidad en el campo financiero. Además, nos enfocamos en investigaciones que aborden una diversidad de enfoques, industrias y escalas de aplicación, con el objetivo de garantizar una representación integral de contextos y escenarios financieros.

El análisis de casos nos brinda la oportunidad de extraer lecciones valiosas sobre las oportunidades y desafíos involucrados en el uso de RNA en proyecciones financieras. A través de un análisis cuidadoso,

3. Los hiperparámetros son ajustes externos a un modelo de aprendizaje automático que se configuran antes del entrenamiento y afectan su rendimiento (Gershenson, 2003). Estos parámetros no se aprenden durante el proceso de entrenamiento, y su elección adecuada es crucial para optimizar el rendimiento del modelo.

identificaremos patrones comunes y factores impulsores que influyen en el rendimiento de estas redes. Estos hallazgos serán esenciales para guiar a profesionales y académicos en su búsqueda de comprender mejor cómo capitalizar el potencial de las RNA y cómo sortear obstáculos comunes que pueden llevar a resultados insatisfactorios.

Con esta base establecida, se procede ahora a presentar una serie de investigaciones y casos específicos que ejemplifican tanto el éxito notable como los desafíos enfrentados al utilizar RNA en la generación de proyecciones financieras. Cada caso será sometido a un examen detallado, en el que evaluaremos sus objetivos, metodología, datos, resultados y conclusiones clave.

Uso de la inteligencia artificial para la optimización de los procesos financieros y contables

El trabajo de Vélez *et al.* (2023) ofrece una valiosa contribución al campo de las finanzas al abordar el impacto de la Inteligencia Artificial (IA), específicamente a través de modelos basados en redes neuronales artificiales, en los procesos contables y financieros. Este enfoque es relevante y oportuno dado el creciente papel que la tecnología desempeña en la transformación digital de las empresas y los mercados financieros.

El uso de modelos basados en redes neuronales artificiales para pronósticos financieros también es destacado en el resumen. Este enfoque ofrece la capacidad de procesar grandes volúmenes de datos y detectar patrones complejos, lo que puede mejorar la precisión de las proyecciones financieras y ayudar a mitigar riesgos en la toma de decisiones de inversión y gestión de carteras.

Además, el análisis resalta la importancia de una implementación inteligente de la IA para garantizar el crecimiento sostenible y la adaptación empresarial en la era digital. Esto implica reconocer tanto las ventajas como las limitaciones de la IA, así como la necesidad de integrarla de manera estratégica con enfoques tradicionales de contabilidad y gestión financiera.

En términos de sus aportes a las finanzas, el estudio proporciona una perspectiva actualizada sobre cómo la IA está transformando los procesos contables y financieros, mejorando la eficiencia operativa y la competitividad empresarial. Al resaltar la relevancia de los modelos basados en redes neuronales artificiales para pronósticos financieros, el análisis subraya la importancia de la tecnología en la toma de decisiones financieras informadas y en la gestión de riesgos en un entorno empresarial cada vez más complejo y dinámico.

Predicción de la angustia financiera de empresas mediante modelos de redes neuronales artificiales y árboles de decisión

Aydin *et al.* (2022) abordan la relación entre fallas operativas en empresas y diversos grupos de interés, tanto internos como externos. Destaca los posibles riesgos financieros derivados de las condiciones del mercado y factores internos, subrayando la importancia de gestionar estos riesgos para evitar la quiebra. Para abordar esto, se propone la construcción de un modelo utilizando RNA y árboles de decisión, para estimar y clasificar las fallas financieras en empresas de diferentes sectores.

El objetivo del modelo es analizar la situación actual de las empresas, prever posibles fallas y tomar medidas correctivas. Se desarrollan modelos únicos para cada sector, comparando las tasas de clasificación correcta de empresas no fallidas por sector y determinando las variables más importantes que influyen en las fallas financieras dentro de cada sector.

En el contexto del estudio, se seleccionan 25 ratios financieros y 2 variables no financieras de 240 empresas en los sectores de manufactura, servicios y comercio listadas en el *Barcelona Institute of Science and Technology*. El modelo busca lograr un valor de error cercano a cero, asegurando que las empresas no quebradas y quebradas se clasifiquen correctamente.

La contribución de este enfoque radica en la aplicación de RNA y árboles de decisión⁴ para predecir y clasificar fallas financieras en empresas de diferentes sectores. Esto sugiere la viabilidad de utilizar estas herramientas en proyecciones financieras, proporcionando una metodología analítica avanzada para evaluar y gestionar riesgos en el entorno empresarial. La capacidad para lograr tasas de clasificación precisas y la identificación de variables clave refuerza la utilidad de estos modelos en la toma de decisiones financieras y estratégicas.

Optimización de portafolios de inversión en la bolsa mexicana de valores utilizando redes neuronales artificiales

Guerrero (2022) hace referencia al modelo propuesto por Harry Markowitz en la década de 1950, que sentó las bases para la optimización de portafolios de inversión al abordar la relación entre riesgo y rendimiento. Esta referencia histórica es fundamental para establecer el marco teórico en el que se basa el estudio y resalta la importancia continua de la teoría moderna de carteras en el análisis de inversiones.

Además, destaca la aplicación de redes neuronales artificiales como una extensión innovadora de los modelos tradicionales de selección de portafolios. Las redes neuronales ofrecen la capacidad de procesar grandes cantidades de datos de manera eficiente y aprender patrones complejos, lo que las convierte en herramientas poderosas para el análisis predictivo en el campo de las finanzas. Se destaca la importancia de comprender y gestionar adecuadamente el riesgo en las estrategias de inversión. Las redes neuronales pueden proporcionar perspectivas valiosas sobre el riesgo asociado con diferentes activos y ayudar a los inversores a tomar decisiones más informadas y fundamentadas.

Finalmente, se hace referencia al uso de *Python 3.6* como una herramienta de programación para implementar las estrategias de análisis propuestas. *Python* es ampliamente utilizado en el campo de la ciencia de datos y la inteligencia artificial debido a su facilidad de uso y la disponibilidad de bibliotecas especializadas, lo que lo convierte en una opción apropiada para la implementación de modelos basados en redes neuronales en el contexto financiero.

Predicción del precio del petróleo crudo utilizando una red neural artificial

El trabajo de Gupta y Nigam (2020) aborda la importancia crucial del petróleo en el mundo actual, destacando su impacto en el medio ambiente global, la economía y diversas actividades. La naturaleza volátil de los precios del petróleo subraya la necesidad de predecirlos con precisión, ya que esto afecta a industrias grandes y pequeñas, individuos y gobiernos.

La propuesta del trabajo consiste en utilizar RNA como un método contemporáneo e innovador para predecir los precios del petróleo. Se destaca la capacidad de estas redes para capturar continuamente patrones de precios inestables al determinar el retardo óptimo y el número de efectos de retardo que los influyen. Se realiza una variación del retardo con el tiempo para obtener resultados más precisos.

Para validar la efectividad del modelo propuesto, se utiliza la evaluación del error cuadrático medio, y los resultados obtenidos demuestran un rendimiento significativamente superior en comparación con otros métodos.

El trabajo contribuye al debate sobre la viabilidad de las RNA en proyecciones financieras. Presenta un enfoque innovador que muestra un rendimiento significativamente mejor en la predicción de los precios

4. Los árboles de decisión son modelos de aprendizaje supervisado en inteligencia artificial y aprendizaje automático. Guiados por reglas lógicas extraídas de datos de entrenamiento, estos árboles organizan decisiones en una estructura de árbol.

del petróleo. Este resultado sugiere que las RNA pueden ser una herramienta valiosa y efectiva en la desafiante tarea de prever los precios en un mercado tan complejo y volátil como el del petróleo.

Redes neuronales en predicción de mercados financieros: una aplicación en la bolsa mexicana de valores

Becerra *et al.* (2018) abordan el interés histórico en conocer los rendimientos de activos en el mercado de valores, con un enfoque particular en el contexto mexicano, que ha sido poco explorado en comparación con mercados más establecidos. Se presenta una aplicación que predice las variaciones diarias de una empresa listada en la Bolsa Mexicana de Valores a través de un enfoque de análisis híbrido.

La metodología utiliza redes *feedforward*⁵ y el algoritmo de retropropagación⁶ para abordar problemas de predicción. La selección de variables de entrada se realiza mediante el Análisis de Componentes Principales, y la precisión de las predicciones se evalúa mediante el error cuadrático medio. Los resultados ofrecen una contribución significativa a la discusión sobre la capacidad de prever activos a corto plazo, especialmente en el contexto de mercados emergentes como México. Este enfoque híbrido destaca la viabilidad de utilizar herramientas como las RNA para mejorar la precisión en la predicción de las variaciones diarias de activos en el mercado de valores mexicano.

Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales artificiales

Ortiz (2017) destaca las ventajas de utilizar RNA como un método eficiente en la predicción de los precios futuros de activos financieros, comparándolos con modelos de la familia GARCH.⁷ Se centra en prever los precios de cierre de los barriles de petróleo crudo WTI y Brent. Los resultados indican que las RNA tienen una precisión similar al modelo TGARCH (1,1) y superan al modelo GARCH (1,1) durante los períodos de descripción y pronóstico. Además, se señala que el esfuerzo requerido para obtener estos resultados con modelos GARCH es significativamente mayor en comparación con el uso de RNA.

La contribución clave radica en respaldar la viabilidad de RNA, en el análisis de series temporales financieras. Al demostrar una precisión comparable y una eficiencia superior en términos de esfuerzo computacional, el estudio sugiere que las RNA pueden ser una alternativa confiable y efectiva para las proyecciones financieras, proporcionando una herramienta valiosa para aquellos que trabajan en el análisis y predicción de activos financieros.

Gestión del riesgo de liquidez en una institución financiera utilizando un modelo híbrido entre la metodología ARIMA y redes neuronales artificiales

El trabajo de Casaliglla (2016) aborda la importancia de la gestión del riesgo de liquidez en instituciones financieras y su impacto en las pérdidas financieras, destacando la necesidad de monitorear la liquidez para el correcto funcionamiento de un banco. Propone una metodología proactiva que analiza la disminución de pasivos y el aumento de activos para prever futuros excedentes o déficits de liquidez, facilitando la toma de decisiones.

5. Las redes *feedforward*, también conocidas como redes neuronales de propagación hacia adelante, son un tipo común de arquitectura en aprendizaje profundo (Flórez & Fernández, 2008). En estas redes, la información se mueve en una sola dirección, desde la capa de entrada a través de una o más capas ocultas hasta la capa de salida.

6. El algoritmo de retropropagación es una técnica de entrenamiento utilizado en redes neuronales para ajustar los pesos de las conexiones entre las neuronas (Becerra *et al.*, 2018). Consiste en propagar hacia atrás el error calculado entre la salida deseada y la salida real de la red, ajustando los pesos de las conexiones en función de este error.

7. Modelo autorregresivo con heterocedasticidad condicional.

Su contribución significativa radica en la introducción de una metodología alternativa que combina modelos ARIMA⁸ y RNA para la predicción. El modelo híbrido, al estimar tanto la relación lineal como el componente no lineal de la serie temporal, demuestra una mayor precisión en comparación con las metodologías por separado. Esto respalda la viabilidad de las RNA en proyecciones financieras, sugiriendo que su integración con enfoques tradicionales puede mejorar la precisión de las predicciones, siendo una herramienta valiosa para gestionar el riesgo de liquidez en instituciones financieras.

CONCLUSIONES

Las conclusiones respaldan la efectividad de las RNA artificiales en la generación de proyecciones financieras al demostrar su capacidad para procesar grandes volúmenes de datos y detectar patrones complejos. Este respaldo se fundamenta en los resultados obtenidos, los cuales muestran que las RNA logran una mayor precisión en las proyecciones financieras en comparación con otros métodos tradicionales. La capacidad de las RNA para aprender de manera autónoma y adaptarse a diferentes conjuntos de datos les permite identificar relaciones no lineales y capturar tendencias subyacentes en los datos financieros. Por lo tanto, se argumenta que las RNA son herramientas poderosas y efectivas para mejorar la calidad de las proyecciones financieras y respaldar la toma de decisiones informadas en el ámbito financiero.

A pesar del respaldo significativo a la utilidad de las RNA en las proyecciones financieras, es crucial reconocer las limitaciones identificadas en este estudio. Entre estas limitaciones se encuentran la necesidad de grandes cantidades de datos de alta calidad y la complejidad en la interpretación de los modelos de RNA. Estos desafíos subrayan la importancia de abordar de manera proactiva los aspectos críticos de la implementación exitosa de las RNA en el ámbito financiero. Si bien las RNA ofrecen ventajas considerables, su efectividad real está intrínsecamente vinculada a la calidad y disponibilidad de los datos, así como a la capacidad de comprender y comunicar los resultados de manera efectiva. Por lo tanto, una adopción exitosa de las RNA requiere una consideración cuidadosa de estas limitaciones y un enfoque estratégico para abordarlas en el proceso de implementación.

Además de las conclusiones previas, es fundamental resaltar la importancia de investigaciones futuras para abordar aspectos no tratados en este estudio; en particular, la optimización de las arquitecturas de redes neuronales y la evaluación del impacto de eventos externos en las proyecciones financieras son áreas que merecen una atención más detallada. Estas investigaciones adicionales no solo enriquecerán nuestra comprensión de cómo mejorar la precisión y la robustez de las proyecciones financieras con RNA, sino que también podrían proporcionar información valiosa para adaptar estas herramientas a entornos financieros en constante cambio. En conjunto, este estudio constituye un paso significativo hacia el entendimiento del potencial de las RNA en el campo financiero y sienta las bases para futuras investigaciones que expandan aún más este conocimiento.

8. Modelo autorregresivo integrado de media móvil.

REFERENCIAS

- Aydin, N., Sahin, N., Deveci, M., & Pamucar, D. (2022). Prediction of financial distress of companies with artificial neural networks and decision trees models. *Machine Learning with Applications*, 10. 100432. <https://doi.org/10.1016/j.mlwa.2022.100432>
- Alonso, A., y Carbó, J. (2022). *Inteligencia artificial y finanzas: Una alianza estratégica*. Banco de España. <https://repositorio.bde.es/handle/123456789/23434>
- Becerra, M., Ortega, A., Montañez-Barrera, A., y López, S. (2018). Redes neuronales en predicción de mercados financieros: Una aplicación en la Bolsa Mexicana de Valores. *Pistas educativas*, 40(130), 2008-2104. <https://pistaseducativas.celaya.tecnm.mx/index.php/pistas/article/view/1778>
- Botero, J., y Álvarez, L. (2013). *Caracterización de la gestión de pronósticos de demanda empresarial* [Tesis de grado]. Universidad del Rosario.
- Casaliglla, P. (2016). *Gestión del riesgo de liquidez en una institución financiera utilizando un modelo híbrido entre la metodología ARIMA y Redes Neuronales Artificiales* [Tesis de maestría]. Universidad Andina Simón Bolívar. <http://hdl.handle.net/10644/4872>
- Castro, A., Reyes, E., y Albor, G. (2019). Pronóstico de ventas de las empresas del sector alimentos: Una aplicación de redes neuronales. *Semestre Económico*, 22(52), 161-177. <https://doi.org/10.22395/seec.v22n52a7>
- Cedeño-Choez, P. (2020). El procedimiento contable como herramienta de proyección de las finanzas empresariales. *Dominio de las Ciencias*, 6(4), 926-939. <https://doi.org/10.23857/dc.v6i4.1511>
- Del Carpio, J. (2005). Las redes neuronales artificiales en las finanzas. *Industrial Data*, 8(2), 28-32. <https://doi.org/10.15381/idata.v8i2.6180>
- Escalona, K., Paz, M., y Viloría, M. (2019). Proyección estados financieros básicos: La situación económica y financiera en las pequeñas y medianas empresas (PYMES). *Revista Enfoques*, 3(10), 126–134. <https://doi.org/10.33996/revistaenfoques.v3i10.60>
- Flórez, R., y Fernández, J. (2008). *Las redes neuronales artificiales. Fundamentos teóricos y aplicaciones prácticas*. Oleiros: Netbiblo.
- García, M. (2000). *Análisis e interpretación de la información financiera reexpresada* (3a ed.). Grupo Patria Cultural.
- Guerrero, G. (2022). *Optimización de portafolios de inversión en la Bolsa Mexicana de Valores utilizando redes neuronales artificiales* [Tesis de maestría]. Universidad Autónoma de Querétaro. <https://ri-ng.uaq.mx/handle/123456789/8672>
- Gershenson, C. (2003). *Artificial neural networks for beginners*. arXiv:cs/0308031v1. <https://doi.org/10.48550/arXiv.cs/0308031>
- Gupta, N., & Nigam, S. (2020). Crude oil price prediction using artificial neural network. *Procedia Computer Science*, 170, 642-647. <https://doi.org/10.1016/j.procs.2020.03.136>
- Hilera, J., & Martínez, V. (1995). *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones*. Rama Editorial.
- Lara, E. (2003). *Primer curso de contabilidad* (18a ed.). Trillas.
- Lozano, J., Garzón, M., y Zurdo, R. (2018). La gestión de pronóstico en las decisiones empresariales: Un análisis empírico. *Espacios*, 39(13), 6-12. <https://www.revistaespacios.com/a18v39n13/a18v39n13p01.pdf>
- Makridakis, S., & Wheelwright, S. (1979). *Forecasting: Studies in the Management Sciences*, 12.

- Martínez-González, M., Saavedra, M., y Sánchez, M. (2021). Modelo de proyección financiera para el sector construcción. *Lúmina*, 22(1), 1-32. <https://doi.org/10.30554/lumina.v22.n1.4092.2021>
- Melchor, A. (2010). *Uso de redes neuronales artificiales para el pronóstico de la inflación* [Tesis de grado]. Universidad Nacional Autónoma de México. <https://ru.dgb.unam.mx/handle/20.500.14330/TES01000659036>
- Méndez, M., Del Rey, T., Mínguez, R., Requena, L., Menéndez, L., Sánchez, I., Rodríguez, P., Picaporte, J., y López, M. (2009). *Matemáticas y economía*. Cultural.
- Mentzer, J., & Kahn, K. (1997). State of sales forecasting in corporate America. *Journal of Business Forecasting Methods and Systems*, 16(1), 6-13. <https://ibf.org/knowledge/jbf-articles/state-of-forecasting-systems-in-corporate-america-255>
- Morales, A., y García, O. (2013). Las redes neuronales artificiales como una herramienta de análisis en la determinación de las empresas que permanecen listadas o deslistadas dentro de la Bolsa Mexicana de Valores. *Revista Ciencia*, 5(3), 1-11. https://www.uaq.mx/investigacion/revista_ciencia@uaq/ArchivosPDF/v5-n3/art3.pdf
- Morel, G. (2012). *Predicción de crisis financieras utilizando redes neuronales artificiales: Un ejercicio para la economía mexicana* [Tesis de maestría]. Universidad Nacional Autónoma de México. <https://ru.dgb.unam.mx/handle/20.500.14330/TES01000685868>
- Núñez, A. (2020). La planificación financiera: Una herramienta clave para el logro de los objetivos empresariales. *Revista Universidad y Sociedad*, 12(3), 160-166.
- Ortiz, F. (2017). Pronóstico de precios de petróleo: Una comparación entre modelos GARCH y redes neuronales diferenciales. *Investigación Económica*, 76(300), 105–126. <https://doi.org/10.1016/j.inveco.2017.06.002>
- Ortiz, R., y Velázquez, C. (2002). *Aplicación de redes neuronales artificiales (RNA) en el pronóstico de ventas* [Tesis de grado]. Universidad Nacional Autónoma de México. https://repositorio.unam.mx/contenidos/aplicacion-de-redes-neuronales-artificiales-rna-en-el-pronostico-de-ventas-3466852?c=n9X1M6&d=fals&q=*&i=9&v=1&t=search_0&as=0
- Pérez, F., y Fernández, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías*, 6(10), 71-91. <http://www.scielo.org.co/pdf/rium/v6n10/v6n10a07.pdf>
- Romero, J. (2006). *Principios de contabilidad* (3a ed.). McGraw Hill.
- Rojas, R. (1996). *Neural networks: A systematic introduction*. Springer.
- Russell, S., y Norvig, P. (2004). *Inteligencia artificial: Un enfoque moderno*. Pearson Education.
- Sinisterra, G., Polanco, L., & Henao, H. (2011). *Contabilidad: sistemas de información para las organizaciones* (6a ed.). McGraw-Hill.
- TICPymes. (2023). *Red neuronal artificial: ¿Qué es?* <https://www.ticpymes.es/a-fondo/red-neuronal-artificial-que-es/>
- Toro, E., Mejía, D., y Salazar, H. (2004). Pronóstico de ventas usando redes neuronales. *Scientia et Technica*, 26(10), 25-30. <https://www.redalyc.org/pdf/849/84911640006.pdf>
- Velázquez, J., Zambrano, C., & Vélez, L. (2011). ARNN: Un paquete para la predicción de series de tiempo usando redes neuronales autorregresivas. *Revista Avances en Sistemas e Informática*, 8(2), 177-181. <https://repositorio.unal.edu.co/bitstream/handle/unal/38753/26744-93664-1-PB.pdf?sequence=1>
- Vélez Vélez, A., Marín Barrera, J., Monsalve Echavarría, J. D., Trejos Pérez, E., & Duque Bedoya, J. (2023). *Uso de la inteligencia artificial para la optimización de los procesos financieros y contables* [Tesis de pregrado]. Tecnológico de Antioquia. <https://dspace.tdea.edu.co/handle/tdea/4470>
- Zhang, G. (2004). *Neural networks in business forecasting*. Idea Group Publishing.