

Impacto del Deep Learning en finanzas: Revisión y perspectivas

Impact of Deep Learning in finance: Review and perspectives

Gustavo Ángel Cerezo Mamani

gustavoce789@gmail.com

<https://orcid.org/0009-0005-0409-1901>

**Universidad Adventista de Bolivia
Cochabamba, Bolivia.**

Recibido el 11 de marzo de 2024 / Arbitrado el 25 de marzo de 2024 / Aceptado el 05 de mayo de 2024 / Publicado el 01 de julio de 2024

RESUMEN

El artículo examina la interacción entre las finanzas y el aprendizaje profundo, abordando cómo esta tecnología ha influido en el campo financiero mediante un análisis detallado de investigaciones y tendencias actuales. Se empleó una revisión sistemática de la literatura con el método PRISMA para revisar tres artículos clave relacionados con el uso de Deep Learning en finanzas. Estos estudios destacan avances en la predicción de mercados, gestión de riesgos, detección de fraudes, análisis de sentimientos y decisiones automatizadas. Se observa que el Deep Learning ha mejorado la precisión y eficiencia de las predicciones financieras al capturar patrones complejos en los datos. La integración de estas técnicas en las finanzas se percibe como una oportunidad valiosa para potenciar la eficacia, precisión y rentabilidad en la toma de decisiones, respaldada por la efectividad y el potencial de aplicación en el sector financiero. Se enfatiza la necesidad de investigar continuamente y abordar desafíos como la interpretabilidad de los modelos y la ética en el uso de algoritmos de aprendizaje profundo en finanzas para una implementación responsable y efectiva.

Palabras claves: Inteligencia artificial, aprendizaje profundo, finanzas, gestión, presupuesto.

ABSTRACT

This article examines the interaction between finance and deep learning, addressing how this technology has influenced the financial field through a detailed analysis of current research and trends. A systematic literature review was conducted using the PRISMA method to review three key articles related to the use of Deep Learning in finance. These studies highlight advances in market prediction, risk management, fraud detection, sentiment analysis, and automated decision-making. It is observed that Deep Learning has enhanced the accuracy and efficiency of financial predictions by capturing complex patterns in data. The integration of these techniques in finance is seen as a valuable opportunity to enhance effectiveness, accuracy, and profitability in decision-making, supported by the effectiveness and potential for application in the financial sector. The need for continuous research and addressing challenges such as model interpretability and ethics in the use of deep learning algorithms in finance for responsible and effective implementation is emphasized.

Keywords: artificial intelligence, deep learning, finance, management, budget.

INTRODUCCIÓN

En poco más de tres años, el deep learning ha llegado a ocupar un papel relevante en econometría, y es utilizado en diversas aplicaciones financieras más allá del asset pricing. Este interés surge repentinamente en un contexto en el que el big data y las capacidades de proceso cada vez mayores han favorecido el papel de este tipo de algoritmos, y por dos motivos principales. El primero es su capacidad predictiva superando a otros algoritmos de clasificación y de series temporales en aplicaciones financieras; el esfuerzo computacional y la cantidad de datos necesaria no siempre compensaban el resultado. Segundo, el deep learning resulta atractivo para economistas y financieros por su capacidad para manejar datos no estructurados, usualmente despreciados por la modelización económica y financiera. Además, el deep learning fomenta el uso de una nueva herramienta, la variable latente o factor, utilizado ya en finanzas por ideologías previas, y hace posible replicar patrones en los datos, y no necesariamente utilizar conocimientos previos.

Vinogradov (2023) describe las redes neuronales como modelos basados en aprendizaje automático supervisado. Estas redes buscan estimar el valor de una función no lineal para predecir una variable endógena, utilizando combinaciones lineales de inputs. Para representar la no linealidad entre las capas de entrada y salida, se incorporan una o más capas ocultas con funciones de activación no lineales que devuelven valores distintos al superar cierto umbral. A pesar de los esfuerzos realizados, el análisis de datos estructurado se encontraba limitado por la necesidad de especificar todas las relaciones a modelar de antemano. Esto llevó a la adopción de estrategias más simples, como el análisis econométrico, para especificar sistemas y relaciones complejas sin garantía de ajustarse a los datos. Aunque las redes neuronales artificiales (ANN) fueron ampliamente estudiadas desde los años 60 hasta finales de los 80, no revolucionaron las finanzas como se esperaba, ya que sus aplicaciones arrojaban resultados inferiores a los métodos econométricos predominantes en ese momento. Un desafío adicional era la incapacidad de las ANN para generalizar a nuevos datos, lo que resultaba en un sobreajuste a los datos de entrenamiento. Estos problemas llevaron al desuso de las ANN en la década de 1990, siendo reemplazadas por algoritmos de regresión automatizados.

Según Martínez et al. (2023) esto resuena con la predicción realizada por la teoría matemática de la comunicación y en especial el de la cibernética, participantes ambos en el desarrollo temprano del modelado basado en el cerebro humano y, por tanto, de las bases teóricas de la inteligencia artificial desde sus más tempranos inicios, sumados a destacadas contribuciones en la articulación de las primeras redes neuronales.

En este sentido, Moreno Tamayo, (2023) señala que en el marco económico y financiero, se han utilizado redes neuronales, recurrentes, y más recientemente, las llamadas deep learning basadas en redes convolucionales y recurrentes. En este apartado, a continuación, se revisan algunas de las principales aplicaciones del deep learning en el sector financiero. Identificación de patrones de fraude en tiempo real. Uno de los principales problemas que enfrentan las entidades financieras alrededor del mundo es la detección de transacciones de fraude que se generan de forma diaria en sus diferentes plataformas.

Por su parte, Gallego Varela, (2023) indica que un aspecto distintivo del deep learning, comparado con los algoritmos de machine learning tradicionales, es la capacidad de sustracción

de características relevantes del input que facilitan la excelente tasa de generalización que presentan en un contexto donde se cuenta con escasa cantidad de acciones anómalas para el entrenamiento del modelo. Predicción de series de tiempo. El deep learning ha demostrado su capacidad para detectar patrones complejos en trazas temporales cortas y para extraer características importantes sin la necesidad de tener conocimientos sobre los datos. Algunos de los modelos estudiados en la literatura financiera que pertenecen a este tipo de paradigma de deep learning son las redes neuronales recurrentes, las cuales hemos dividido en dos tipos: de célula recurrente como es el caso de las long short-term memory y gated recurrent units, y excelente rendimiento en la predicción de series de tiempo financieras.

En el campo financiero, la construcción de modelos de aprendizaje es de vital importancia, tanto en el ámbito de inversión, brindando modelos predictivos para la rentabilidad de activos; para la banca y las compañías de financiamiento, herramientas que les permitan, entre otras aplicaciones, clasificar y otorgar créditos, gestionar adecuadamente el riesgo, pronosticar los riesgos crediticios y proyectar el riesgo de mercado; finalmente, para la gestión financiera empresarial, evaluar la rentabilidad de los activos, tomar decisiones de inversión y financiación, entre otras. La construcción de estos modelos se apoya en tres clases de algoritmos dentro del Machine Learning: supervisados, no supervisados, semi-supervisados.

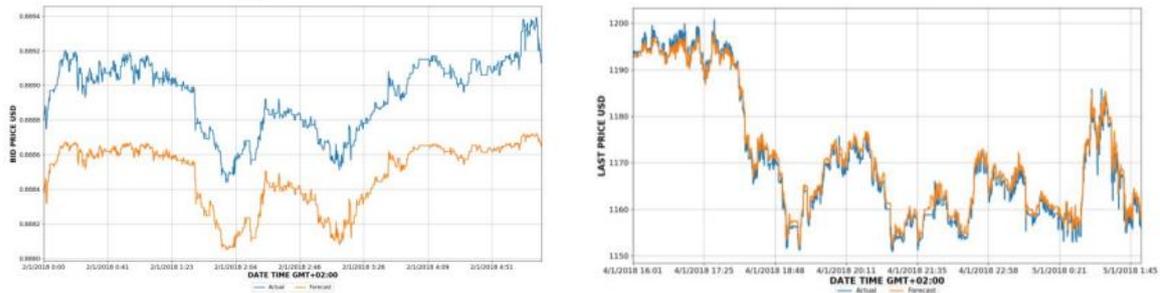
Asimismo, Luque et al. (2022) señalan que el aprendizaje profundo ofrece ventajas significativas sobre el aprendizaje tradicional en cuanto a la precisión de un modelo predictivo, especialmente al lidiar con un gran número de variables explicativas, lo que se traduce en un aprendizaje a partir de grandes volúmenes de datos (learning from big data). Tanto el uso de redes neuronales artificiales como el aprendizaje profundo requieren de pruebas fuera de la muestra para validar la precisión de diversos algoritmos. El proceso de entrenamiento implica dividir los datos en dos partes: una para ajustar el modelo y otra para, por ejemplo, compartir los coeficientes de dicho modelo una vez se ha estimado una categoría de activo objetivo, permitiendo así la participación de ambos grupos de estudiantes e investigadores. En esta última parte se evalúa el error y se determina la precisión (Hernández y Moreno, 2023).

De igual forma, el Aprendizaje profundo o Deep Learning (DL), es un subcampo del Machine Learning y a su vez este último de la inteligencia artificial. DL abarca una serie de técnicas de modelado y entrenamiento de datos. El área financiera maneja una gran cantidad de datos, los cuales son muy útiles para el entrenamiento de los modelos ya que casi es una regla empírica que a mayor volumen de datos mayor precisión del modelo entrenado. La necesidad de usar herramientas de DL para las finanzas, surgen mayoritariamente al enfoque predictivo y analítico de los datos.

Una de las técnicas que se usaran para la predicción fue el LSTM (Memoria a corto plazo), el cual fue usado en trading; este entrenamiento se realizó gracias a las API (Interfaz de programación de aplicaciones) tanto de Forex como de Bitfinex. En las cuales demuestran que los datos se aproximaron a los datos reales como vemos en las tablas a continuación (He et al, 2023)

Figura 1.

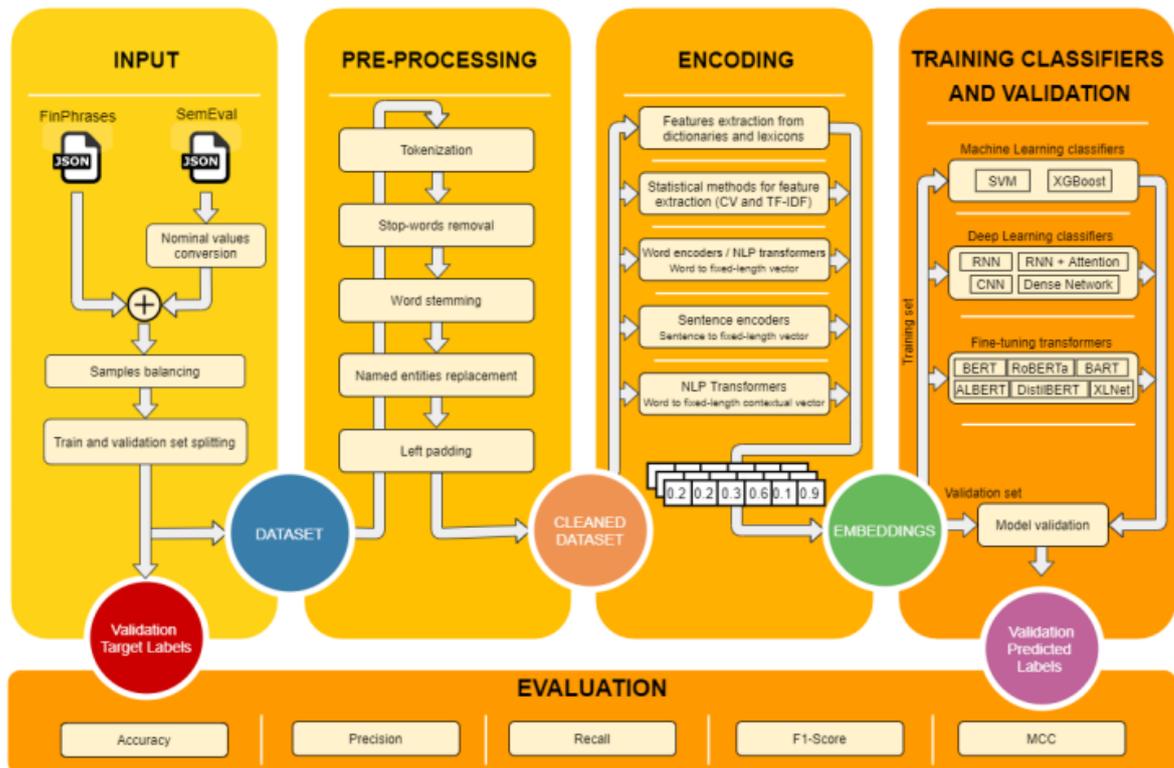
EUR/GBP -Actual vs. Forecast The run time of the test was approximately 10.33 hours, resulting in a NRMSE = 0.0010.



Desde el ámbito analítico, se realizaron estudios enfocados en la detección de sentimientos del público en afín, usando modelos NLP (Procesamiento del lenguaje natural), esta herramienta de análisis de sentimientos es muy importante para tomar decisiones en función de la opción del cliente y/o mercado, también para el análisis léxico se usó LSTM. Este estudio tuvo muy buenos resultados por lo que incluso se presume su extensión a campos nivel empresarial e incluso médicos. El estudio propone una arquitectura para el análisis de sentimientos (Mishev, 2020)

Figura 2.

Arquitectura de la plataforma de análisis de sentimientos



Estos ejemplos dan muestra del avance tecnológico para el ámbito financiero, por lo que día a día se van haciendo investigaciones de gran relevancia, para enfrentar diversos problemas que surgen a diario en afán de mejorar y estar a la vanguardia. Por lo antes expuesto, se busca explorar cómo el uso de técnicas de Deep Learning ha impactado y transformado el campo de las finanzas, analizando investigaciones relevantes y tendencias recientes en esta área

MÉTODO

Para llevar a cabo esta revisión literaria, se llevó a cabo una búsqueda extensa de documentos en tres bases de datos reconocidas: DOAJ (Directory of Open Access Journals), Nature y Google Scholar. El objetivo principal era identificar artículos tecnológicamente relevantes que se centren en el aprendizaje profundo (DL) y en los métodos más eficientes y novedosos en este campo.

En cuanto a la estrategia de búsqueda implementada, se comenzó con la base de datos DOAJ, la cual se empleó para descubrir artículos de acceso libre pertinentes. Esta búsqueda inicial arrojó un total de 170 resultados, que fueron evaluados en función de su relevancia para la revisión. Posteriormente, se realizó una búsqueda en la base de datos de la prestigiosa revista Nature, que reveló un total de 606 resultados, ampliando así el alcance de la búsqueda y la diversidad de fuentes consultadas.

Además, se utilizó Google Scholar, una plataforma ampliamente reconocida por su extensa cobertura de literatura académica, para llevar a cabo otra fase de la búsqueda. Los resultados obtenidos en Google Scholar fueron significativamente más amplios, con un total de 19,700 resultados, lo que proporcionó una amplia gama de artículos y recursos académicos para revisar y analizar en detalle en el contexto de esta revisión literaria sobre finanzas y Deep Learning.

Criterios de inclusión y exclusión:

1. Inclusión:

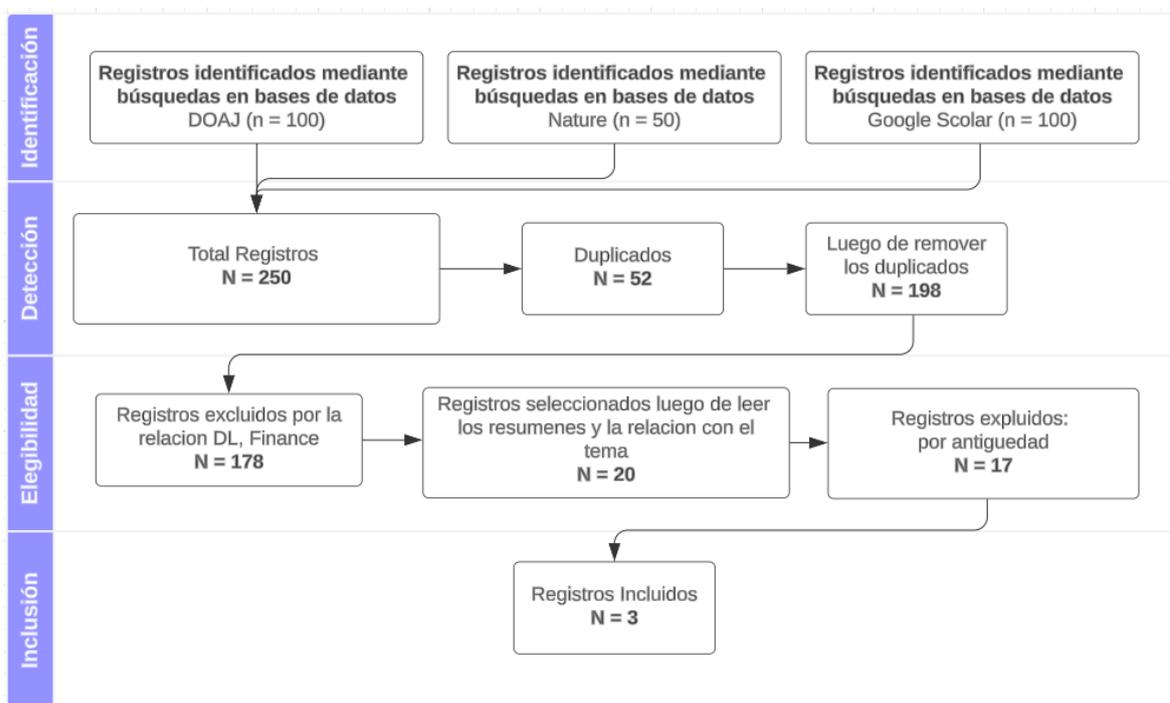
- Artículos completos.
- Artículos publicados entre enero de 2020 y mayo de 2024.
- Estudios que abordan el uso de la inteligencia artificial.
- Estudios que tengan una orientación financiera.
- Artículos que usen modelos de DL y ML.
- Artículos más recientes.

2. Exclusión:

- Artículos demasiado antiguos.
- Artículos que no estaban disponibles en texto completo.
- Estudios no relevantes para el objetivo específico de la revisión.
- Documentos duplicados entre las distintas bases de datos.
- Artículos que no relación la inteligencia artificial y las finanzas.
- Artículos de revisión literaria.

Figura 3.

Diagrama de flujo Prisma:



En cuanto a las fuentes de datos utilizadas, para la búsqueda en los repositorios bibliográficos se empleó una combinación específica de palabras clave. Inicialmente, se utilizó la combinación "Deep Learning - Budget", la cual no arrojó resultados en Nature y DOAJ, mostrando solo resultados en Google Scholar. Luego, se exploró la combinación "Deep Learning - Economy", que generó resultados limitados en DOAJ y Nature.

Finalmente, se se optó por la combinación de palabras clave "Deep Learning - Finance", la cual resultó ser la más relevante y productiva para los propósitos de este artículo. Esta combinación de palabras clave proporcionó los datos necesarios que se reflejan en el contenido del presente artículo, permitiendo así obtener información significativa relacionada con la intersección entre finanzas y Deep Learning.

RESULTADOS

Los estudios revisados se centran en tres áreas clave relacionadas con la predicción de problemas financieros, la influencia de los sesgos conductuales en los modelos de aprendizaje automático (ML), DL y el uso de inteligencia artificial (IA). A continuación, se presenta una descripción detallada de cada estudio, junto con sus principales hallazgos.

Se inició con la investigación realizada por Sabek y Horák (2023), la cual se centra en la optimización de hiperparámetros de regresión del proceso gaussiano (GPR) para predecir problemas financieros en empresas. El objetivo principal consiste en mejorar la precisión del modelo GPR mediante la optimización de sus hiperparámetros. En términos metodológicos, el estudio emplea un modelo GPR no paramétrico basado en la distribución de probabilidad gaussiana, lo que le permite adaptarse a diversas situaciones al no asumir una forma específica para los datos. Se llevó a cabo la evaluación de diferentes funciones Kernel, utilizadas para medir

la similitud entre los datos, seleccionando aquellas combinaciones que optimizaban el rendimiento del modelo.

Los datos utilizados provienen de una base de datos de Kaggle que incluye 83 ratios financieros y múltiples variables no financieras. En cuanto a los resultados obtenidos, se destaca que el modelo GPR logró una precisión de clasificación del 81%, superando a la regresión lineal que obtuvo un 74% de precisión. Esto evidencia la efectividad del modelo GPR en la predicción de problemas financieros. La optimización de hiperparámetros identificó al modelo RQ-Cero como el más adecuado, lo que indica que esta combinación específica de funciones Kernel y parámetros resultó en un rendimiento óptimo del modelo. Se observó una mejora significativa en la precisión del modelo después de la optimización, lo que indica que el modelo GPR fue capaz de predecir problemas financieros de manera más precisa y eficiente tras el ajuste de los hiperparámetros.

En una revisión posterior, se analizó la investigación de He et al. (2023) titulada "Sesgos Conductuales en el Aprendizaje Automático para la Toma de Decisiones Financieras", con el propósito de examinar cómo los sesgos conductuales impactan en los modelos de aprendizaje automático utilizados en la toma de decisiones financieras y proponer estrategias para mitigar estos efectos. El objetivo central del estudio fue explorar los diferentes tipos de sesgos conductuales, como el exceso de confianza y la aversión a las pérdidas, y comprender cómo estos sesgos pueden ser amplificados en los modelos de aprendizaje automático si no se gestionan de manera adecuada.

Los resultados obtenidos resaltan que los modelos de aprendizaje automático tienen el potencial de amplificar los sesgos conductuales si no se implementan estrategias efectivas de mitigación. Se discutieron diversas técnicas para identificar y corregir estos sesgos, lo que conlleva a una mejora en la toma de decisiones financieras al reducir la influencia negativa de los sesgos. Además, se presentaron estudios de caso con ejemplos concretos que ilustran cómo los sesgos conductuales han afectado decisiones financieras críticas, subrayando la importancia de abordar estos sesgos de manera proactiva en el contexto del aprendizaje automático aplicado a las decisiones financieras.

El tercer estudio, llevado a cabo por Lee et al. (2023), se enfoca en la "Inteligencia Artificial en el Contexto del Riesgo Empresarial y la Detección de Fraudes Financieros", con el propósito de explorar el uso de la inteligencia artificial (IA) en la detección de fraudes financieros y la gestión de riesgos empresariales. El objetivo principal de esta investigación es analizar cómo la IA puede utilizarse de manera efectiva en la detección de fraudes financieros y en la gestión de riesgos en entornos empresariales.

En cuanto a los métodos empleados, el estudio describe diversas técnicas de IA, como el aprendizaje profundo y los algoritmos de clasificación, detallando su aplicación en la detección de fraudes financieros y en la gestión de riesgos empresariales. Además, se examinaron casos prácticos que ilustran la implementación exitosa de tecnologías de IA en distintos sectores industriales. Entre los resultados destacados se encuentran las ventajas de la IA en el análisis de grandes volúmenes de datos, permitiendo detectar patrones que sugieren actividades fraudulentas. Se observó que las técnicas de IA mejoraron tanto la precisión como la velocidad en la detección de fraudes financieros, lo que subraya su eficacia en este ámbito.

No obstante, se discutieron también los desafíos actuales en la implementación de IA, como la necesidad de contar con datos de alta calidad y la importancia de una supervisión humana adecuada para garantizar la efectividad y la ética en la aplicación de estas tecnologías en la detección de fraudes financieros y la gestión de riesgos empresariales.

Los tres estudios analizados ofrecen una perspectiva integral sobre la aplicación de técnicas avanzadas, como el aprendizaje automático y la inteligencia artificial, en el ámbito financiero. Sabek y Horák (2023) se centran en la optimización de hiperparámetros del proceso gaussiano para prever dificultades financieras, demostrando que el modelo GPR con la combinación adecuada de funciones Kernel logra una precisión del 81%, superando a métodos más tradicionales como la regresión lineal. He et al. (2023) exploran cómo los sesgos conductuales pueden influenciar los modelos de aprendizaje automático en la toma de decisiones financieras, proponiendo estrategias para mitigar estos efectos y mejorar la toma de decisiones. Por último, Lee et al. (2023) abordan la aplicación de la inteligencia artificial en la detección de fraudes financieros y la gestión de riesgos empresariales, destacando la efectividad de la IA en analizar grandes conjuntos de datos y mejorar la precisión y eficiencia en la detección de actividades fraudulentas.

En conjunto, estos estudios subrayan el potencial transformador de las tecnologías emergentes en el sector financiero, desde la predicción de dificultades financieras hasta la detección de fraudes y la gestión de riesgos. La combinación de enfoques innovadores como el proceso gaussiano optimizado, la consideración de sesgos conductuales en los modelos de aprendizaje automático, y la implementación de inteligencia artificial en la detección de fraudes, resalta la importancia de la adaptación continua a entornos financieros complejos y cambiantes. Aunque se destacan los beneficios de estas tecnologías, también se señalan desafíos como la necesidad de datos de alta calidad y la supervisión humana adecuada para garantizar la eficacia y la ética en la aplicación de estas herramientas en el sector financiero.

DISCUSIÓN

La revisión detallada de los tres estudios proporciona una visión integral sobre cómo mejorar los modelos predictivos en finanzas a través de la optimización de hiperparámetros, la gestión de sesgos conductuales y la aplicación de técnicas avanzadas de inteligencia artificial. En primer lugar, la optimización de hiperparámetros en la regresión del proceso gaussiano (GPR) ha demostrado un impacto significativo en la precisión predictiva, elevando esta métrica al 81%, superando claramente el rendimiento de la regresión lineal. Este hallazgo subraya la importancia de ajustar cuidadosamente la configuración del modelo para lograr mejoras sustanciales en la capacidad de predecir problemas financieros específicos. La selección del modelo RQ-Cero como el más idóneo destaca la necesidad de evaluar diversas funciones Kernel y combinaciones de hiperparámetros para encontrar la configuración óptima adaptada a cada conjunto de datos.

Por otra parte, la exploración de sesgos conductuales en modelos de aprendizaje automático revela que estos pueden ser amplificadas si no se gestionan adecuadamente, lo que puede resultar en decisiones financieras erróneas y perjudiciales. Para contrarrestar este efecto, la implementación de estrategias específicas para identificar y corregir sesgos se vuelve crucial, garantizando que los modelos de ML arrojen resultados justos y precisos. Entre las técnicas propuestas se incluye la utilización de datos de entrenamiento más equilibrados y algoritmos diseñados para mitigar sesgos

conocidos, promoviendo así la integridad en la toma de decisiones financieras. Por último, el uso de inteligencia artificial en la detección de fraudes y la gestión de riesgos resalta las ventajas y la eficiencia de las técnicas de IA, como el aprendizaje profundo, en analizar grandes conjuntos de datos y descubrir patrones que señalan posibles fraudes financieros. A pesar de estas ventajas, la implementación de IA presenta desafíos como la necesidad de datos de alta calidad y la supervisión humana, destacando la importancia de la ética y la transparencia en el uso de tecnologías automatizadas para mantener la confianza en los sistemas empleados.

Para entender la importancia y el desarrollo del Deep Learning en las finanzas, según Montoya Herrera (2023) algunos hitos relevantes para el desarrollo del Deep Learning son los siguientes. Tras la consolidación, en los años ochenta, de los modelos del Deep Learning, en la literatura financiera comienzan a aparecer referencias al uso de las Redes Neuronales Artificiales como herramientas para la modelización de la dinámica de los índices financieros o la predicción financiera. Se estudió el uso de Redes Neuronales Artificiales en la predicción de los índices bursátiles con resultados estadísticamente significativos.

Así mismo, según Astorgano Antón (2022) varios autores plasmaron piezas de desarrollo que culminaron en implementaciones de alto impacto. Se explica que el estudio permitió concluir que el gradiente o derivadas parciales de la mayoría de las funciones de costes más usadas en redes neuronales artificiales resultan sencillas de calcular. Estas derivadas son necesarias para realizar el cálculo del incremento en las capas ocultas y posteriormente los pesos o límites sinápticos. Por tanto, han sido este tipo de redes las que han permitido la popularización en campos aplicados del entrenamiento basado en propiedades de primer orden de las soluciones de un modelo de Mínimos Cuadrados, permitiendo a los altos costes computacionales del siglo XX usar, y sobre todo estudiar, la actualización de los pesos y así generar el concepto de aprendizaje. Once aclarados una serie de conceptos relevantes, ahora se procederá a calcular la traza de las actividades a lo largo del tiempo de este campo de estudio que se han rescatado en forma de hitos investigativos.

Recientemente, se desarrolló el Batch Normalization que ofrece estabilidad en el entrenamiento, ya que permite utilizar una tasa de aprendizaje mayor. Se aplica a una capa en cascada con su función de activación. Además, reduce la influencia del problema de la inicialización de la red y es computacionalmente eficiente al soportar la regularización L2 (González-Almansa Laredo, 2023)

La técnica de Deep Learning es un conjunto de técnicas relacionadas con el "Learning Representation". Los algoritmos presentan múltiples capas de representación, las cuales están influenciadas por algún tipo de aprendizaje y permiten que los algoritmos abstraigan y descubran características de los datos. Uno de los desafíos principales en el ámbito de Big Data es la recuperación de patrones y modelos en grandes volúmenes de datos, como lo son aquellos que se mueven en contextos de dinámica social y económica. En este escenario, diversos mecanismos de Deep Learning han sido propuestos como técnicas adecuadas de modelación, siendo adoptados gracias a su eficacia como modelos de abstracción y jerarquía tanto en datos desestructurados y sin procesar como en otros con niveles sucesivos de descripción (Aurich Mio y Miguel Flores, 2023)

Que los algoritmos de Deep Learning sean capaces de aprender y descubrir representaciones directamente desde los datos sin la necesidad de procesos de ingeniería manual constituye una inmensa ventaja, ya que generalmente la generalización se dirige al rendimiento en tareas de bajo nivel, aspectos que la ingeniería manual no es capaz de abarcar. Así mismo, dependiendo de los datos, cantidad y

calidad de ellos, y las tareas que vayan a ser llevadas a cabo, la ingeniería manual tomaría mucho tiempo, esfuerzo y experiencia que generalmente no se tiene o es costosa. Entre aquellos campos donde existen buenas muestras y resultados favorables se encuentra el campo de finanzas.

CONCLUSIONES

Los resultados de esta revisión destacan la importancia de la optimización de modelos, la mitigación de sesgos conductuales y la implementación de tecnologías de inteligencia artificial para mejorar la precisión y eficiencia en la predicción de problemas financieros y la detección de fraudes. Las empresas pueden beneficiarse significativamente de la adopción de estas prácticas, siempre y cuando aborden los desafíos asociados y aseguren la supervisión adecuada. Futuros estudios deben centrarse en desarrollar técnicas más avanzadas para la optimización de modelos y la gestión de sesgos, así como en explorar nuevas aplicaciones de la IA en el ámbito financiero.

Se le ha dado cobertura a la mayoría de aplicaciones del Deep Learning en las finanzas, así como de los beneficios de este en comparación con otros modelos. Existen aplicaciones en las cuatro áreas fundamentales que son el análisis sectorial, análisis microeconómico, análisis macroeconómico y el análisis financiero. Por el lado de beneficios, destacamos la posibilidad que estos métodos ofrecen para manejar información en base no estructurada, especificar técnicas con muy pocas hipótesis, flexibilidad respecto a dependencias no lineales y potencialidad para extraer características.

En el segundo eje de la revisión, comentamos las restricciones o limitaciones fundamentales del Deep Learning en las finanzas, entre las que destacamos el sobreajuste, la interpretabilidad de los resultados y la necesidad de gran cantidad de datos. Por último, desde el ámbito microeconómico, en principio parece interesante modelizar a través del enfoque Deep Learning tres aspectos fundamentales que son la detección de fraude, el clasificador de clientes retail y las predicciones de series temporales de acciones, tipo de cambio, clientes potenciales, incumplimiento de pagos, tipo de contrato, entre otros.

A través de este análisis, pretendemos incitar a los futuros estudiosos a abrir nuevas líneas de investigación en la medida en que la bibliografía en Deep Learning en finanzas aún resulta relativamente corta comparado con lo que este campo representa a nivel global, con lo cual la oportunidad de contribuir es muy amplia.

REFERENCIAS

- Astorgano Antón, M. (2022). Diagnóstico de fallos de rodamientos en motores de inducción en estado estacionario mediante técnicas boosting y redes neuronales. <https://uvadoc.uva.es/bitstream/handle/10324/57935/TFG-G5948.pdf?sequence=1>
- Aurich Mio, L. Y. y Miguel Flores, M. A. (2023). Aplicación de machine learning para clasificar el rendimiento académico del área de matemática en el colegio CIMA-Lambayeque 2021. https://repositorio.unprg.edu.pe/bitstream/handle/20.500.12893/11907/Aurich_Mio_Leys_i_Yarely%20y%20Miguel_Flores_Mois%20C3%A9s_Alvin.pdf?sequence=1

- Gallego Varela, A. (2023). Predicción de la cotización de las acciones mediante técnicas de Deep Learning. <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/69007/TFG-%20Gallego%20Varela%2C%20Ainhoa.pdf?sequence=2>
- González-Almansa Laredo, Á (2023). Sistema de identificación de emociones independiente del hablante basado en redes neuronales convolucionales. https://oa.upm.es/75003/1/TFG_ALVARO_GONZALEZ_ALMANSA%20LAREDO.pdf
- He, K., Yang, Q., Ji, L., Pan, J., y Zou, Y. (2023). Financial time series forecasting with the deep learning ensemble model. *Mathematics*, 11(4), 1054. <https://www.mdpi.com/2227-7390/11/4/1054>
- Hernández, J. M. G., y Moreno, W. N. T. (2023). Predicción de riesgo de impago en institución financiera usando modelos de Machine Learning (Doctoral dissertation, Universidad Tecnológica Centroamericana UNITEC).
- Lee, J. C., Tang, Y., y Jiang, S. (2023). Understanding continuance intention of artificial intelligence (AI)-enabled mobile banking applications: an extension of AI characteristics to an expectation confirmation model. *Humanities and Social Sciences Communications*, 10(1), 1-12. <https://www.nature.com/articles/s41599-023-01845-1>
- Luque, R. I. C., Torres, R. D. R. Z., Pintado, M. S. A., y Arellano, T. M. C. (2022). Implementación de la Propuesta BCC: Aplicación de la práctica contable desde la virtualidad en el proceso de enseñanza-aprendizaje en la asignatura de contabilidad. *593 Digital Publisher CEIT*, 7(4), 157-174. <https://dialnet.unirioja.es/descarga/articulo/8561169.pdf>
- Martínez, K. C., Rodríguez, J. A. A., Hernández, J. G. R., y Mercado, R. S. V. (2023). Implementación de una inteligencia artificial para la interpretación de la prueba proyectiva "MACHOVER" basada en redes neuronales artificiales. *Revista Digital de Tecnologías Informáticas y Sistemas*, 7(1), 86-93. <http://redtis.org/index.php/Redtis/article/download/139/142>
- Mishev, K., Gjorgjevikj, A., Vodenska, I., Chitkushev, L. T., y Trajanov, D. (2020). Evaluation of sentiment analysis in finance: from lexicons to transformers. *IEEE access*, 8, 131662-131682. <https://ieeexplore.ieee.org/abstract/document/9142175/>
- Montoya Herrera, A. (2023). Desarrollo de un modelo de predicción usando redes neuronales artificiales de los precios de los futuros del dolar para la industria colombiana. <https://repository.eafit.edu.co/bitstreams/36f25dde-fa50-4e14-85a4-33e68101fe3b/download>
- Moreno Tamayo, I. (2023). Impacto del Covid-19 en el crecimiento del PIB de países de la OECD: Una aplicación de técnicas de pronóstico tradicionales y de machine learning. https://diposit.ub.edu/dspace/bitstream/2445/212641/1/TFG_EST_Moreno_2023.pdf
- Sabek, A., y Horák, J. (2023). Gaussian Process Regressions Hyperparameters Optimization to Predict Financial Distress. RETOS. *Revista de Ciencias de la Administración y Economía*, 13(26), 273-289. http://scielo.senescyt.gov.ec/scielo.php?pid=S1390-86182023000200273&script=sci_abstract&tlng=en

Vinogradov, I. (2023). El “Título del barrio de Santa Ana”: el manuscrito del siglo XVI que dio inicio a la tradición literaria maya-poqomchi’. *Estudios de cultura maya*, 62, 251-271. <https://revistas-filologicas.unam.mx/estudios-cultura-maya/index.php/ecm/article/download/1305/1907>