

Técnicas de aprendizaje automático para el análisis de datos en aplicaciones financieras

Machine learning techniques for data analysis in financial applications

Nicolas Rodríguez Gutiérrez¹

Citar este documento:

Rodríguez-Gutiérrez Nicolas. Técnicas de aprendizaje automático para el análisis de datos en aplicaciones financieras. Revista Technol.Investig.Academia TIA, ISSN: 2344-8288, 10 (2), pp. 168-184. Bogotá-Colombia.

¹ Ingeniero de sistemas, Bogotá, nicrodriguezg@correo.udistrital.edu.co

Resumen

En este artículo se presentarán algunas de las técnicas más relevantes del aprendizaje automático (*machine learning*) utilizadas en diferentes trabajos de investigación para tratar con aplicaciones financieras como evaluación crediticia, gestión de cartera, predicción de mercados, acciones o divisas y planificación financiera en general, la finalidad de este documento es el de presentar de manera general las técnicas de aprendizaje automático usadas para estas aplicaciones financieras, dando a conocer las conclusiones a las que se llegaron en los diferentes artículos de investigación acerca de las ventajas y los avances que se han tenido al utilizar dichas técnicas al solucionar problemas financieros, no se entrará al detalle de los resultados obtenidos en cada investigación en diferentes aspectos financieros, solo se busca obtener un panorama amplio del análisis del uso en dichos aspectos las siguientes técnicas de aprendizaje automático: redes neuronales, sistemas expertos, sistemas de inteligencia híbrida, minería de datos, técnicas de computación blandas y técnicas de aprendizaje profundo (*Deep learning*).

Palabras Clave: Inteligencia artificial, aprendizaje automático, aplicaciones financieras, computación blanda, aprendizaje profundo, minería de datos.

Abstract

This article will present some of the most relevant techniques of machine learning used in different research works to deal with financial applications such as credit evaluation, portfolio management, prediction of markets, stocks or currencies and financial planning in general.

The purpose of this document is to present in a general way the machine learning techniques used for these financial applications, making known the conclusions reached in the different research articles about the advantages and advances that have been made. When using these techniques when solving financial problems, the results obtained in each investigation in different financial aspects will not be entered into detail, it only seeks to obtain a broad panorama of the analysis of the use in these aspects of the following machine learning techniques: neural networks, expert systems, intelligence systems hybrid AI, data mining, soft computing techniques and deep learning techniques.

Key Words: *Artificial intelligence, machine learning, financial applications, soft computing, deep learning, data mining.*

I. Introducción

El presente documento presentara una visión general de las implementaciones de aprendizaje automático en el ámbito de las finanzas, evidenciando como mediante el diferente uso de técnicas de aprendizaje automático (*machine learning*) se han presentado en diferentes investigaciones y trabajos realizados a lo largo de los años, diferentes modelos que se pueden emplear para los diversos problemas financieros, que en la actualidad poseen comportamientos inciertos y no lineales.

Con el desarrollo de esta investigación se pretende dar a conocer algunas de las diferentes investigaciones realizadas con respecto al uso de algunas técnicas de aprendizaje automático en diferentes problemas financieros, esto con el fin de servir de guía a futuros investigadores o a los que precisan dar solución a algún problema de ámbito financiero mediante inteligencia artificial.

En este documento en le primera parte se van a describir diferentes técnicas de aprendizaje automático usadas para intentar resolver o pronosticar diferentes aspectos financieros, en cada técnica se muestran algunas de las investigaciones que se han realizado, analizando la utilidad de la técnica en aspectos financieros, en la segunda parte se mostraran algunas de las aplicaciones y las investigaciones respectivas en cuanto a que técnicas son las más óptimas para tratar con la aplicación financiera.

II. Marco teórico


1. Técnicas de aprendizaje automático

El aprendizaje automático (*machine learning*) se ha ocupado de resolver muchos aspectos de la vida cotidiana haciendo uso de sus numerosas técnicas, el caso de las finanzas no es la excepción, su uso en las finanzas a nivel general se puede encontrar en muchos estudios y trabajos realizados, en el estudio realizado por Arash Bahrammirzaee [1] se puede encontrar una revisión de investigación comparativa entre 3 técnicas de inteligencia artificial para diversas aplicaciones financieras, las cuales son: redes neuronales artificiales, sistemas expertos y sistemas de inteligencia híbrida.

1.1. Redes Neuronales Artificiales

Las redes neuronales artificiales son herramientas de modelado computacional inspiradas en sistemas nerviosos biológicos y la estructura cerebral, estas redes neuronales son sistemas de información que utilizan capacidades de aprendizaje de una forma adaptable, gracias a esta adaptabilidad representan poderosas soluciones para el procesamiento subjetivo de información y toma de decisiones, convirtiéndose así en una herramienta para ayudar a la toma de decisiones financieras [2,3,4]. Fig. 2 Se observa la analogía de una neurona biológica con el concepto de neurona artificial de la técnica de redes neuronales artificiales, se observa n neuronas biológicas con varias señales de intensidad x y fuerza sináptica w , que se alimentan de una neurona con un umbral de b y el equivalente al sistema de neuronas artificiales. Las redes biológicas y las redes neuronales artificiales aprenden ajustando gradualmente las magnitudes de pesos o las fortalezas de la sinapsis [2]

Figura 1. Interacción de señales de n neuronas y analogía con la suma de señales en una neurona artificial que comprende el perceptrón de capa única



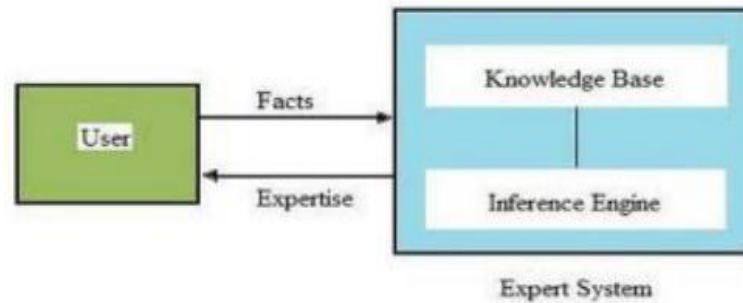
Fuente:[2].

1.2. Sistemas Expertos

Los sistemas expertos son sistemas informáticos que utilizan una base organizada de conocimiento que simulan habilidades de expertos en la resolución de problemas en un contexto determinado y

limitado, los sistemas expertos basados en reglas son capaces de usar información de una base de conocimiento para resolver problemas de gran dificultad que requerirían de una gran experiencia humana para su resolución, el conjunto de inferencias que usan los sistemas expertos son proporcionadas por expertos humanos en un área de interés particular y la base de conocimiento es una acumulación de datos, hechos, juicios y resultados relevantes [5,6].

Figura 2. Esquema básico de un sistema experto típico



Fuente:[7]

1.3. Sistemas de Inteligencia Híbrida

Los sistemas de inteligencia híbrida son sistemas que integran técnicas de inteligencia artificial para la resolución de problemas, pueden combinar diferentes técnicas de inteligencia con otras técnicas de inteligencia y con sistemas informáticos convencionales, por ejemplo, hojas de cálculo o bases de datos. Un sistema de inteligencia híbrida es un sistema de aprendizaje eficiente y robusto que combina características complementarias, superando las debilidades de las capacidades de procesamiento de los paradigmas de aprendizaje simbólicos y no simbólicos [8,9,10].

1.4. Comparación de Redes neuronales, Sistemas Expertos y de Inteligencia Híbrida

Como conclusión de la investigación de Arash Bahrammirzaee, se llegó a que después de comparar estas 3 técnicas de inteligencia artificial en aplicaciones del mercado financiero como lo fueron evaluación crediticia, gestión de cartera y predicción y planificación financiera, por un lado, los sistemas expertos no se han encontrado muchos trabajos donde comparen esos sistemas con otros modelos lineales y no lineales de uso común, sin embargo se encontró que esos sistemas expertos son más prácticos que los métodos estadísticos tradicionales, pero no pueden competir con otros métodos inteligentes como las redes neuronales o los sistemas inteligentes híbridos, esos sistemas

expertos al contar con la información de los expertos en el área de interés cuentan con características para poder sugerir un curso de acción a una meta determinada, pero no pueden predecir las consecuencias de un curso de acción seleccionado en condiciones experimentales, estos sistemas de expertos no pueden mejorar el resultado de la experiencia, solo pasar a la siguiente regla (si/entonces), comparándolo con otras técnicas de inteligencia como las redes neuronales, no pueden identificar relaciones no lineales.

Con respecto a las redes neuronales, los resultados de estudios comparativos indicaron un éxito en la predicción y planificación financiera, este éxito se debe a algunas características únicas de las redes neuronales en el mercado financiero como su naturaleza numérica, que no exigen supuestos de distribución de datos para entradas y estimadores de modelos, también a su capacidad de actualizar datos, a pesar de esto no se puede concluir que las redes neuronales sean técnicas muy precisas en el mercado financiero, dentro de los problemas de estas redes se encuentran la lentitud en el entrenamiento del sistema, la dificultad para determinar el tamaño y la estructura de la red neuronal para el problema determinado, a veces son incapaces de reconocer patrones y establecer relaciones relevantes entre varios factores, que son razones importantes para reducir su desempeño.

Una alternativa a las redes neuronales son los sistemas híbridos que permiten combinar las capacidades de diferentes sistemas, con esta integración se superan las limitaciones de las técnicas individuales, sin embargo, esta elección no puede garantizar un buen rendimiento del sistema porque la elección correcta de modelos de integración y la parametrización siguen siendo un problema importante. [1].

1.5. Minería de datos

Otra de las técnicas usadas para aplicaciones financieras es la minería de datos, se encuentra en investigaciones como la realizada por Dongsong Zhang y Lina Zhou [11], en donde analiza la minería de datos, incluyendo algoritmos genéticos, sistemas basados en reglas, así como redes neuronales preferidas en diferentes áreas de aplicaciones financieras.

La minería de datos se encarga de descubrir conocimiento oculto, patrones ocultos, y reglas de grandes bases de datos que son potencialmente útiles, que sirven para la toma de decisiones cruciales, La minería de datos aplica técnicas de análisis de datos y descubrimiento de conocimiento con algunas limitaciones de eficiencia computacional, produciendo una enumeración particular de patrones sobre los datos [12].


Dentro de las técnicas de minería de datos que se usan en finanzas, las más comunes son: redes neuronales, algoritmos genéticos, inferencia estadística, inducción de reglas y visualización de datos. Las redes neuronales se explicaron en el apartado 1.1 del presente documento, Los algoritmos genéticos se basan en la idea de que en un conjunto genético de una población específica se encuentra potencialmente la solución, el algoritmo genético modifica repetidamente una población de estructuras artificiales mediante inicialización, selección, cruce y mutación para obtener una solución evolutiva, este proceso evolutivo se repite muchas veces hasta determinada condición. La inferencia estadística proporciona una base teórica sólida para el problema del análisis de datos, apoyándose en validación de hipótesis o análisis de datos exploratorios, los métodos exploratorios estadísticos básicos incluyen técnicas como examinar la distribución de variables, revisar grandes matrices de correlación para los coeficientes que cumplen con ciertos umbrales y examinar tablas de frecuencia multidimensionales.

Se puede encontrar métodos como el de regresión lineal que se han utilizado con frecuencia para identificar variables influyentes en problemas financieros o relaciones entre diferentes variables en mercados financieros. Los modelos de inducción de reglas hacen parte del enfoque lógico basado en la destilación de patrones de minería de datos, estas técnicas producen un conjunto de reglas si/entonces para representar patrones significativos y crear modelos de predicción, estos modelos son transparentes y proporcionan explicaciones completas de predicciones, es una estructura recursiva simple para representar un procedimiento de decisión en el que una nueva instancia se clasifica en una de las clases predefinidas.

La visualización de datos es el proceso de analizar y convertir datos en gráficos, aprovechando a las personas en el proceso de exploración de datos combinando la flexibilidad, creatividad y conocimiento en general de las personas con la enorme capacidad de almacenamiento y poder de cómputo de las computadoras actuales, esta técnica permite a los tomadores de decisiones y analistas

obtener información sobre los datos, sacar conclusiones e interactuar directamente con los datos. Estas técnicas de minería de datos se pueden utilizar para aplicaciones financieras como: predicción del mercado de valores, Gestión de cartera, predicción de quiebras, mercado de divisas, detección de fraudes, entre otras aplicaciones financieras. Muchas aplicaciones combinan estas técnicas de minería de datos con modelos financieros y contables [11]. Como se aprecia en la Fig. 3 la minería de datos en las finanzas está involucrada con aplicaciones, datos y modelo de dominio

Figura 3. Tres dimensiones de la minería de datos en aplicaciones financieras



Fuente: [11].

1.6. Técnicas de computación blanda

En el trabajo de investigación realizado por Mochón et al [13], se muestra el uso de técnicas de computación blandas (Soft computing) como la de lógica difusa y razonamiento probabilístico sobre implementaciones financieras. Antes de entrar a ver el análisis y resultados de estas técnicas en aplicaciones financieras, se hará claridad del campo de la computación blanda; este campo cubre un conjunto de técnicas que pretenden simular la capacidad de la mente humana al emplear modos de razonamiento basados en aproximación en lugar de cálculos exactos, se diferencia con el campo de computación dura (*Hard computing*) o computación tradicional en la importancia que se le da a la precisión, la certeza o el rigor, estos elementos son el eje fundamental de la computación dura, mientras que en la computación blanda parte de que la precisión y la certeza tienen un costo, que el cálculo, el razonamiento y la toma de decisiones deben aprovechar siempre que sea posible la tolerancia a la imprecisión y la incertidumbre, la computación blanda tiene un papel relevante en situaciones en la que los modelos precisos son demasiado costosos en computación tradicional, no son prácticos o simplemente no existen [14].

La lógica difusa o borrosa se basa en un razonamiento aproximado en lugar de buscar la precisión en la lógica de predicados clásica, esta lógica difusa proporciona una manera de llegar a conclusiones basadas en información ambigua, imprecisa e incompleta, se basa a su vez en la teoría de conjuntos difusos que tratan con valores bien pensados de expertos del mundo real para un problema complejo [15].

Dentro del razonamiento probabilístico se encuentran técnicas que incluyen redes de creencias, redes causales o bayesianas, algoritmos genéticos, una heurística de búsqueda global basada en la evolución biológica y partes de la teoría del aprendizaje y sistemas caóticos, el interés de estas técnicas de razonamiento probabilístico es la incertidumbre. [13].

La aplicación de las técnicas de computación blandas está ampliamente recomendada para tratar con información desestructurada o incompleta, lo que es frecuente en el ámbito financiero en áreas como predicción de mercados, acciones y divisas, negociación, gestión de carteras, clasificación crediticia o predicción de divisas. En contraste con la computación dura, los métodos de computación blanda tratan de manera efectiva los problemas mal estructurados que encontramos en el mundo real, estas técnicas se pueden usar de una manera combinada en soluciones híbridas, para abordar cuestiones relacionadas a la imprecisión, el aprendizaje y la incertidumbre, en las finanzas los problemas a menudo presentan dichas condiciones, por ejemplo en la predicción de mercado de valores o divisas, en la gestión de carteras o la predicción de problemas financieros en la que los investigadores se enfrentan a información incompleta, datos corruptos o también cuando se tiene la necesidad de una respuesta rápida que no puede proporcionar un método de lógica clásica [13].

1.7. Aprendizaje profundo

El aprendizaje profundo (*Deep learning*) consiste en unos métodos de aprendizaje automático con múltiples niveles de representación o capas, obtenidas mediante la composición de módulos simples, pero no lineales que transforman la representación de un nivel en una representación a un nivel superior, mediante el uso de suficientes transformaciones entre capas se puede llegar a un aprendizaje de funciones muy complejas, las capas clasifican amplificando los aspectos de la entrada que son importantes para la discriminación y eliminan las variaciones irrelevantes [16]. A


continuación, se mostrarán algunas de las técnicas de aprendizaje profundo que pueden ser usadas para resolver problemas financieros.

1.7.1. Redes neuronales profundas

Dentro del aprendizaje profundo se encuentran unas técnicas de redes neuronales profundas, como las redes neuronales convolucionales que se utilizan principalmente para la clasificación de imágenes mediante el uso de múltiples matrices aprovechando las propiedades de señales naturales: conexiones locales, pesos compartidos, agrupación y uso de muchas capas. Otra de estas técnicas es la de redes neuronales recurrentes utilizadas comúnmente para procesar una secuencia de entradas como el habla y lenguaje, estas procesan una secuencia de entrada de un elemento a la vez, manteniendo unidades ocultas mediante un vector de estado que contiene información de todos los elementos pasados por la secuencia, las salidas de estas unidades ocultas en diferentes pasos de tiempo son salidas de diferentes neuronas en una red profunda de múltiples capas, como se puede observar en la Fig. 4 [16].

Las redes de creencias profundas son otro tipo de red neuronal profunda, estas son un modelo que genera mediante probabilidad un conjunto de entradas utilizando un enfoque no supervisado, estas redes se utilizan para encontrar características independientes y discriminatorias en el conjunto de entrada, las capas de la red empiezan a detectar estas características, después de la fase de aprendizaje, llevan a cabo un aprendizaje supervisado para realizar la clasificación [17].

Figura 4. Una red neuronal recurrente y el desarrollo en el tiempo de computación



Fuente: [16].


1.7.2. Memoria a corto plazo

Otra de las técnicas usadas en el aprendizaje profundo es la de memoria a corto plazo, es un tipo de red diseñada para el análisis secuencial de datos, presentan como ventaja el poder recordar los valores de la red tanto a corto como a largo plazo, es utilizada principalmente para el análisis de datos secuenciales como reconocimiento automático de voz, traducción en idiomas, reconocimiento de caracteres escritos a mano, predicción de datos de serie en tiempo, entre otros [18].

1.7.3. Maquinas restringidas de Boltzmann

Las máquinas restringidas de Boltzmann son otra de las técnicas de aprendizaje profundo, esta técnica se utiliza principalmente para la reducción de dimensionalidad, clasificación y aprendizaje de características, esta técnica es un modelo grafico no dirigido que consta de dos capas, una capa visible y otra oculta, las unidades de capas no están conectadas entre sí, cada unidad toma decisiones estocásticas sobre su trasmite o no los datos de entrada, el aprendizaje se realiza varias veces en la red [19,20], en la Fig. 5 se puede apreciar el modelo de capas.

Figura 5. Diagrama esquemático de una máquina de Boltzmann restringida



Fuente: [19].

1.7.4. Codificadores automáticos

Dentro de los modelos de aprendizaje profundo también se encuentran los codificadores automáticos (*autoencoders*), los cuales utilizan procesos de aprendizaje de funciones sin supervisión, en estos se reasignan entradas o características de modo que las entradas sean más representativas para la clasificación, los *autoencoders* constan de una capa de entrada, una capa de salida y una o más capas ocultas, cuentan con 2 componentes, los codificadores y los

decodificadores, las ventajas de usar los *autoencoders* son la reducción de la dimensionalidad y el aprendizaje de características [21].

El uso de estas técnicas de aprendizaje profundo ha sido analizado en la aplicación a problemas financieros como evaluación de riesgos, detección de fraudes, gestión de la cartera, mercado de precios de activos y derivados, estudios de criptomonedas, entre otros, con buenos resultados, dentro de las comparaciones realizadas por estudios como los de Ahmet Murat et al [22], se puede apreciar dentro de su investigación y en sus conclusiones como los modelos de aprendizaje profundo tienen mucho potencial en resolver problemas del aspecto financiero, brindando un mayor desempeño a métodos más clásicos de aprendizaje automático, aunque en ciertos aspectos destacaban más que los de aprendizaje profundo, por lo general el rendimiento de las técnicas de aprendizaje profundo son superiores.

2. Aplicaciones financieras con aprendizaje automático

Dentro del amplio catálogo de aplicaciones financieras, se abordarán algunas de las más importantes, como a través de técnicas de aprendizaje automático (*machine learning*) se han realizado investigaciones, presentando modelos y dando resultados acerca del uso de estas técnicas en un problema financiero determinado.

2.1. Evaluación de riesgos

En el trabajo realizado por Ahmet Murat et al [22], se muestran algunas investigaciones que se han realizado para tratar con la evaluación de riesgos financieros, dentro de estas se encuentran: estudios de aprendizaje automatizado realizadas por Efstathios Kirkos et al [23] y por V. Ravi et al [24], estudios de evaluación de desempeño bancario basados en modelos de aprendizaje automático, mediante el trabajo de Meryem Duygun et al [25], estudios de calificación crediticia y evaluación del riesgo crediticio basados en técnicas de computación blanda hechos por Adel Lahsasna et al [26] y Ning Chen et al [27], estudios realizados por AI Marques et al [28] que se centraron en los modelos de computación evolutiva para implementaciones de puntuación de crédito, estudios realizados por Ravi Kumar et al [29] y Antanas Verikas et al [30] en los cuales se revisó la implementación de aprendizaje automático en estudios de predicción de quiebras, también se encuentra una

investigación de problemas financieros y fallas corporativas realizada por Jie Sun et al [31], también se encuentran los estudios de predicción de crisis financieras basados en modelos de aprendizaje automático realizado por W. Lin et al [32]. Muchas de estos estudios se centraron en el uso de técnicas de aprendizaje profundo como las redes neuronales profundas o las Maquinas restringidas de Boltzmann, estas técnicas de aprendizaje profundo proveen una mayor precisión a la hora de evaluar riesgos financieros.

2.2. Detección de fraudes

El tema de detección de fraudes financieros es de gran interés especialmente para gobiernos y autoridades, así como entidades bancarias, existen muchos estudios e investigaciones para tratar con diferentes tipos de fraudes como pueden ser fraudes de créditos, de tarjetas de crédito, de seguros, evasión de impuestos, lavado de dinero, entre otros, estos estudios se centran en detección de anomalías y son generalmente problemas de clasificación que intentan ser resueltos mediante técnicas de aprendizaje automático [22], dentro de estos estudios se pueden encontrar los realizados por E. Kirkos et al. [33], Dianmin Yue et al. [34], Shiguo Wang et al [35], Clifton Phua et al [36], Ngai et al. [37], Anuj Sharma et al [38] y Jarrod West et al [39], en estos estudios se centran en técnicas como la computación flexible y minería de datos, también se encuentran estudios centrados en identificar fraudes con tarjeta de crédito como el de Yaya Heryadi et al [40] en el cual se desarrollan varios modelos de aprendizaje profundo para la detección con tarjetas de crédito, también se analizaron los efectos del desequilibrio entre los datos fraudulentos y los no fraudulentos [22]

2.3. Comercio algorítmico

El comercio algorítmico consiste en la toma de decisiones de compra y venta basándose en modelos algorítmicos, estos modelos se pueden basar en reglas simples, modelos matemáticos, procesos optimizados, aproximación de funciones complejas o en aprendizaje automático: debido a la aparición de plataformas de comercio electrónico en línea, se comenzaron a implementar técnicas de aprendizaje automático, especialmente aprendizaje profundo [22].

Dentro de los trabajos de investigación de técnicas de aprendizaje automático usadas para el análisis de modelos de comercio algorítmico se puede encontrar los siguientes: la investigación presentada por Wei Bao et al [41], en esta se utilizaron indicadores técnicos como entrada en funciones matemáticas y en Codificadores automáticos para pronosticar el valor de las acciones, en el trabajo realizado por Liheng Zhang et al [42], se propone una nueva red recurrente de estado de memoria frecuente para la predicción de las acciones con patrones de negociación de frecuencia múltiple en la cual se lograron resultados de predicción y negociación, en el trabajo de Yue Deng et al [43], se utilizó una técnica de aprendizaje difuso de refuerzo directo profundo para la predicción de los precios de las acciones y la generación de señales comerciales.

En el trabajo de David W. Lu [44] se utilizó el aprendizaje de refuerzo profundo y la técnica de Memoria a corto plazo para implementar y probar el comercio inspirado por agentes, en el trabajo de Francis Dixon et al [45] se implementó la técnica de Perceptrón profundo multicapa profunda para la predicción de los precios de comercio de divisas y materias primas, otro estudio realizado por Jerzy Korczak y Marcin Hernes [46] implemento un modelo de comercio de divisas utilizando varios parámetros de entradas diferentes en un entorno comercial basado en múltiples agentes, uno de estos agentes uso redes neuronales convolucionales, técnica de aprendizaje profundo, superando los demás modelos.

2.4. Gestión de cartera

La gestión de cartera se ocupa de la elección de activos de una cartera en un periodo de tiempo determinado, la gestión de cartera cubre la optimización, selección y optimización de cartera, la gestión de carteras es en realidad un problema de optimización [22].

En estudios como el de Bin Li aynd Steven Hoy [47] se revisaron los estudios de selección de carteras en línea utilizando varios modelos basados en aprendizaje automático, en trabajo como el de Metaxiotis y Liagkouras [48] contrastaron los algoritmos evolutivos multiobjetivo implementados únicamente en problemas de optimización de cartera, sin embargo otros investigadores obtuvieron un rendimiento superior al utilizar técnicas de aprendizaje profundo, también en el trabajo de Anthony Grace [49] las acciones se evaluaron con respecto a su índice de

referencia para clasificar si tendrían un rendimiento superior o inferior al utilizar la técnica de aprendizaje profundo, el perceptrón profundo multicapa.

III. CONCLUSION

Existe un amplio interés en la comunidad por determinar la utilidad de modelos presentes en las diferentes técnicas de aprendizaje automático (*machine learning*) dentro de diferentes ámbitos, como en el analizado en este documento mediante las diferentes investigaciones previas, el ámbito financiero, muchas de las aplicaciones financieras cuentan con un comportamiento no lineal e incierto que cambia con el tiempo.

Las técnicas clásicas basadas en modelos matemáticos convencionales pueden ser eficaces para problemas lineales e invariantes en el tiempo, pero para los problemas financieros pueden ser limitados, es acá cuando las técnicas de aprendizaje automático tienen el potencial de ser usados en el ámbito financiero, especialmente se evidencia la superioridad de los métodos de aprendizaje profundo como los basados en redes neuronales.

IV REFERENCIAS

- [1] Arash Bahrammirzaee, A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing and Applications*, 19(8):1165–1195, 2010.
- [2] Basheer IA, Hajmeer M, Artificial neural networks: fundamentals, computing, design, and application. *J Microbiol Meth* 43:3–31, 2010.
- [3] Haykin S (1988) *Neural networks—a comprehensive foundation*. McMillan College Publishing, New York, 1988.
- [4] Touzet CF, Neural reinforcement learning for behaviour synthesis. *Robotics Autonom Sys* 22:251–281, 1997.
- [5] Harmon P, King D, *Artificial intelligence in business—expert systems*. Wiley, New York, 1985.
- [6] Ellis C, Willson P, Expert system portfolios of Australian and UK securitized property investments. *Pacific Rim Property Res J* 12(1):107–127, 2005.
- [7] Razieh A, Zahra A, A Review on Expert Systems and Their Usage In Management 7(8): 1460-1465, 2013.
- [8] Taha IE, A hybrid intelligent architecture for revising domain knowledge. Ph. D. Report. University of Texas at Austin, 1997.
- [9] Lertpalangsunti N, An implemented framework for the construction of hybrid intelligent forecasting systems. Ph. D. Report. University of Regina, 1997.

- [10] Goonatilake S, Khebbal S, Intelligent hybrid systems: issue, classifications and future directions in intelligent hybrid systems. Wiley, London, 1995.
- [11] D. Zhang and L. Zhou. Discovering golden nuggets: Data mining in financial application. *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, 34(4):513–522, 2004.
- [12] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, “From data mining to knowledge discovery in databases,” *AI Mag.*, vol. 17, pp. 37–54, 1996.
- [13] Mochón, A., Quintana, D., Sáez, Y. et al. Soft computing techniques applied to finance. *Appl Intell* 29, 111–115 (2008).
- [14] Zadeh LA, Fuzzy logic, neural networks, and soft computing. *Commun ACM* 37(3):77–84, 1994.
- [15] Klir GJ, Yuan B, Clair USt Fuzzy set theory: foundations and applications. Prentice Hall, New York, 1997.
- [16] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *Nature*, 521(7553):436–444, 2015.
- [17] Geoffrey E. Hinton, Simon Osindero, and Yee-Whye Teh. A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7):1527–1554, 2006.
- [18] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735– 1780, 1997.
- [19] Xueheng Qiu, Le Zhang, Ye Ren, P. Suganthan, and Gehan Amaratunga. Ensemble deep learning for regression and time series forecasting. In *2014 IEEE Symposium on Computational Intelligence in Ensemble Learning (CIEL)*, pages 1–6, 2014.
- [20] Yoshua Bengio. Deep learning of representations for unsupervised and transfer learning. In *Proceedings of ICML workshop on unsupervised and transfer learning*, pages 17–36, 2012
- [21] Qinxue Meng, Daniel Catchpoole, David Skillicom, and Paul J Kennedy. Relational autoencoder for feature extraction. In *2017 International Joint Conference on Neural Networks (IJCNN)*, pages 364–371. IEEE, 2017.
- [22] Ahmet Murat Ozbayoglu, Mehmet Ugur Gudelek and Omer Berat Sezer. *Deep Learning for Financial Applications: A Survey*, pages 1–52. IEEE, 2020.
- [23] Efstathios Kirkos and Yannis Manolopoulos. Data mining in finance and accounting: A review of current research trends. In *Proceedings of the 1 st International Conference on Enterprise Systems and Accounting (ICESAcc)*, pages 63–78, 2004.
- [24] V. Ravi, H. Kurniawan, Peter Nwee Kok Thai, and P. Ravi Kumar. Soft computing system for bank performance prediction. *Applied Soft Computing*, 8(1):305–315, January 2008.
- [25] Meryem Duygun Fethi and Fotios Pasiouras. Assessing bank efficiency and performance with operational research and artificial intelligence techniques: A survey. *European Journal of Operational Research*, 204(2):189–198, 2010.
- [26] Adel Lahsasna, Raja Noor Ainon, and Ying Wah Teh. Credit scoring models using soft computing methods: A survey. *Int. Arab J. Inf. Technol.*, 7:115–123, 2010.
- [27] Ning Chen, Bernardete Ribeiro, and An Chen. Financial credit risk assessment: a recent review. *Artificial Intelligence Review*, 45(1):1–23, 2015.
- [28] AI Marques, Vicente García, and José Salvador Sánchez. A literature review on the application of evolutionary computing to credit scoring. *Journal of the Operational Research Society*, 64(9):1384– 1399, 2013.

- [29] P. Ravi Kumar and V. Ravi. Bankruptcy prediction in banks and firms via statistical and intelligent techniques – a review. *European Journal of Operational Research*, 180(1):1–28, July 2007.
- [30] Antanas Verikas, Zivile Kalsyte, Marija Bacauskiene, and Adas Gelzinis. Hybrid and ensemble-based soft computing techniques in bankruptcy prediction: a survey. *Soft Computing*, 14(9):995–1010, 2009.
- [31] Jie Sun, Hui Li, Qing-Hua Huang, and Kai-Yu He. Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. *KnowledgeBased Systems*, 57:41–56, 2014.
- [32] W. Lin, Y. Hu, and C. Tsai. Machine learning in financial crisis prediction: A survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(4):421–436, 2012.
- [33] E Kirkos, C Spathis, and Y Manolopoulos. Data mining techniques for the detection of fraudulent financial statements. *Expert Systems with Applications*, 32(4):995–1003, 2007.
- [34] Dianmin Yue, Xiaodan Wu, Yunfeng Wang, Yue Li, and Chao-Hsien Chu. A review of data miningbased financial fraud detection research. In *2007 International Conference on Wireless Communications, Networking and Mobile Computing*. IEEE, 2007.
- [35] Shiguo Wang. A comprehensive survey of data mining-based accounting-fraud detection research. In *2010 International Conference on Intelligent Computation Technology and Automation*. IEEE, 2010.
- [36] Clifton Phua, Vincent C. S. Lee, Kate Smith-Miles, and Ross W. Gayler. A comprehensive survey of data mining-based fraud detection research. *CoRR*, abs/1009.6119, 2010.
- [37] E.W.T. Ngai, Yong Hu, Y.H. Wong, Yijun Chen, and Xin Sun. The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision Support Systems*, 50(3):559–569, 2011.
- [38] Anuj Sharma and Prabin Kumar Panigrahi. A review of financial accounting fraud detection based on data mining techniques. *International Journal of Computer Applications*, 39(1):37–47, February 2012.
- [39] Jarrod West and Maumita Bhattacharya. Intelligent financial fraud detection: A comprehensive review. *Computers & Security*, 57:47–66, 2016.
- [40] Yaya Heryadi and Harco Leslie Hendric Spits Warnars. Learning temporal representation of transaction amount for fraudulent transaction recognition using cnn, stacked lstm, and cnn-lstm. In *2017 IEEE International Conference on Cybernetics and Computational Intelligence*. IEEE, 2017.
- [41] Wei Bao, Jun Yue, and Yulei Rao. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7):e0180944, 2017.
- [42] Liheng Zhang, Charu Aggarwal, and Guo-Jun Qi. Stock price prediction via discovering multifrequency trading patterns. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD17*. ACM Press, 2017.
- [43] Yue Deng, Feng Bao, Youyong Kong, Zhiquan Ren, and Qionghai Dai. Deep direct reinforcement learning for financial signal representation and trading. *IEEE Transactions on Neural Networks and Learning Systems*, 28(3):653–664, March 2017.
- [44] David W. Lu. Agent inspired trading using recurrent reinforcement learning and lstm neural networks, 2017.

- [45] Matthew Francis Dixon, Diego Klabjan, and Jin Hoon Bang. Classification-based financial markets prediction using deep neural networks. *SSRN Electronic Journal*, 2016.
- [46] Jerzy Korczak and Marcin Hernes. Deep learning for financial time series forecasting in a-trader system. In *Proceedings of the 2017 Federated Conference on Computer Science and Information Systems*. IEEE, 2017.
- [47] Bin Li and Steven C. H. Hoi. Online portfolio selection: A survey. *ACM Comput. Surv.*, 46(3): 35:1–35:36, 2014.
- [48] K. Metaxiotis and K. Liagouras. Multiobjective evolutionary algorithms for portfolio management: A comprehensive literature review. *Expert Systems with Applications*, 39(14):11685–11698, 2012.
- [49] Anthony Grace. Can deep learning techniques improve the risk adjusted returns from enhanced indexing investment strategies. Master's thesis, 2017.

Publicación Facultad de Ingeniería y Red de Investigaciones de Tecnología Avanzada – RITA

**REVISTA
TIA**