



Universidad Nacional Autónoma de México
Programa de Posgrado en Ciencias de la Administración

Análisis del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de valores de EE.UU. a través de RNA: 2017-2022

T e s i s

Que para optar por el grado de:

Maestra en Finanzas
Campo de conocimiento: Finanzas Corporativas

Presenta:
Wendy Aracely Ek Dzul

Tutor:
Dr. Arturo Morales Castro
Facultad de Contaduría y Administración

Ciudad de México, Octubre de 2024



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

Gracias a mi madre, quien a pesar de la distancia me ha apoyado en todo momento. No fue una decisión fácil estar lejos pero ha valido totalmente la pena.

Gracias al Dr. Arturo Morales quien me orientó en todo este camino.

Le agradezco a mis sinodales: a la Mtra. Rosario Higuera, al Dr. Norman Wolf, a la Dra. Paola Vera y al Mtro. Jorge Aranda, por su apoyo durante todo este proceso.

Gracias Kevin, nunca me dejaste de apoyar y animar en todo este camino. Estuviste ahí en cada momento importante para mí y te lo agradezco inmensamente.

Gracias Saul por toda tu ayuda cuando lo necesitaba. La estancia fue más agradable gracias a ti.

Gracias a mis compañeros por compartir buenos momentos juntos.

Índice

Resumen	6
Introducción.....	7
Capítulo 1. Marco Metodológico	11
1.1 Planteamiento del problema	11
1.2 Pregunta de investigación	15
1.3 Objetivo de la investigación.....	15
1.4 Hipótesis	15
1.5 Justificación	15
1.6 Metodología.....	17
Capítulo 2. Marco Teórico.....	19
2.1 Desempeño financiero.....	19
2.1.1 Estudios enfocados al desempeño empresarial.....	19
2.1.2 Indicadores financieros como medida del desempeño financiero..	33
2.2 Redes Neuronales Artificiales aplicadas a las finanzas	35
Resumen.....	45
Capítulo 3. Diseño de arquitecturas de RNA	46
3.1 Técnica de análisis de datos.....	46
3.2 Selección de variables para la arquitectura de las RNA.....	49
Resumen.....	53
Capítulo 4. Análisis de resultados	54
4.1 Periodo 2017-2022.....	54
4.2 Periodo 2017-2019.....	62
4.3 Periodo 2020-2022.....	70
Resumen.....	80

Capítulo 5. Conclusiones y recomendaciones	81
Referencias bibliográficas	89
Anexo 1. Arquitecturas diseñadas en SPSS	94
Anexo 2. Actividades académicas realizadas	104
Anexo 3. Reporte de similitudes y coincidencias	111

Índice de diagramas

Diagrama 1. Funcionamiento de una RNA.....	47
Diagrama 2. RNA MLP 18-4-4-1. Periodo 2017-2022.....	58
Diagrama 3. RNA MLP 18-7-5-1. Periodo 2017-2019.....	66
Diagrama 4. RNA MLP 18-7-3-1. Periodo 2020-2022.....	74

Índice de gráficas

Gráfica 1. Residuos de RNA MLP 18-4-4-1. Periodo 2017-2022	59
Gráfica 2. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2022.....	62
Gráfica 3. Residuos de RNA MLP 18-7-5-1. Periodo 2017-2019	67
Gráfica 4. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2019.....	70
Gráfica 5. Residuos de RNA MLP 18-7-3-1. Periodo 2020-2022	75
Gráfica 6. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2020-2022.....	78

Índice de tablas

Tabla 1. Matriz de congruencia	15
Tabla 2. Empresas seleccionadas del sector de comercio electrónico	49
Tabla 3. Razones financieras seleccionadas	50
Tabla 4. Características de la RNA	52

Tabla 5. Arquitecturas con los mejores ajustes de datos. Periodo 2017-2022	54
Tabla 6. Información de la RNA. Periodo 2017-2022	56
Tabla 7. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2022	60
Tabla 8. Arquitecturas con los mejores ajustes de datos. Periodo 2017-2019	63
Tabla 9. Información de la RNA. Periodo 2017-2019	64
Tabla 10. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2019	68
Tabla 11. Arquitecturas con los mejores ajustes de datos. Periodo 2020-2022	71
Tabla 12. Información de la RNA. Periodo 2020-2022	72
Tabla 13. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2020-2022	76
Tabla 14. Resumen arquitecturas con los mejores ajustes de datos	79
Tabla 15. Arquitecturas de RNA. Periodo 2017-2022	94
Tabla 16. Arquitecturas de RNA. Periodo 2017-2019	97
Tabla 17. Arquitecturas de RNA. Periodo 2020-2022	100

Resumen

El objetivo de esta investigación es analizar el comportamiento del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de valores de EE.UU. en el periodo 2017-2022. Para ello, se consideró abordar un periodo general, tomando en cuenta los 5 años (2017-2022), así como periodos más cortos abarcando antes (2017-2019) y durante (2020-2022) la pandemia por COVID-19. La investigación será de tipo cuantitativo, descriptivo y no experimental. Se utilizarán las redes neuronales artificiales (RNA), una técnica de análisis basada en inteligencia artificial, para estudiar las empresas de comercio electrónico, y así determinar el modelo más eficiente para estimar los factores que impactan en el desempeño financiero. De manera general se observa que, hubo una variación en el comportamiento del desempeño financiero de cada periodo de estudio. Aunque algunas de las razones financieras que más impactaron se mantuvieron presentes en cada periodo, se logra apreciar que también presentaron ligeros cambios en el porcentaje de impacto. Los hallazgos hacen evidente la importancia de cuidar la generación de beneficios como resultado de la actividad económica de las empresas. Asimismo, hay que tener en cuenta la manera en cómo se gestionan los activos de la empresa, con el fin de tener una mayor productividad y que se garantice el buen funcionamiento de la compañía. Otro aspecto por considerar es el control eficiente de los costos de producción, administración y distribución ya que esto puede llegar a impactar en la rentabilidad de la empresa.

Palabras clave: Desempeño financiero, finanzas, redes neuronales, razones financieras, comercio electrónico.

Introducción

A lo largo del tiempo, el comercio ha evolucionado lo que le ha permitido adaptarse a los gustos y necesidades de los consumidores. Si bien algunos han mantenido su formato tradicional de ventas en tiendas físicas, algunos han decidido incursionar en el comercio electrónico, es decir, ventas por medios electrónicos, haciendo sus ventas únicamente por esos medios o realizando una combinación entre sus ventas físicas y digitales. El comercio electrónico ha permitido a las empresas ampliar su alcance de clientes por lo que la ubicación ya no resulta ser una limitante.

Con la llegada del COVID-19, se presentaron algunos cambios en el comportamiento de los consumidores ya que dejaron de comprar algunas cosas y muchas otras tuvieron una demanda exponencial debido a las medidas preventivas establecidas por los organismos de salud, lo que provocó primeramente una escasez de los productos así como un incremento de los precios. Por lo tanto, como resultado de las restricciones de circulación, las compras en línea fueron incrementando en comparación con la venta en tiendas físicas. Ante este panorama muchas tiendas se vieron obligadas a cerrar sus locales de manera indefinida o migrar al comercio electrónico para poder seguir operando.

Como toda empresa, aquellas dedicadas al comercio electrónico buscan maximizar sus beneficios, de manera que se requieren de técnicas o métodos estadísticos que permitan brindar información precisa del desempeño financiero que ha tenido con el fin de determinar aquellos factores que resultan relevantes.

Aunque existen diversas herramientas comúnmente utilizadas en las finanzas, estas presentan ciertas limitantes, sobre todo en periodos de crisis o de cambios, tales como la pandemia generada por el COVID-19, ya que el comportamiento financiero se ve alterado, de manera que no se sigue una distribución normal. Por lo tanto, resulta importante hacer uso de nuevas herramientas que permitan determinar modelos eficientes para la estimación del desempeño financiero.

Las redes neuronales artificiales, que si bien es cierto que no se desarrollaron inicialmente para el área de las finanzas, han demostrado ser una técnica con buenos resultados, en comparación con los métodos tradicionales. Esto se debe a que permiten entender los patrones de comportamiento de la información financiera, sin tener que cuidar que se cumplan ciertos criterios o supuestos para poder utilizarla.

Es por esta razón que en esta investigación se plantea el análisis del desempeño financiero de las empresas dedicadas al comercio electrónico haciendo uso de las redes neuronales, durante el periodo de 2017-2022, centrándose en aquellas que cotizan en la bolsa de valores de EE.UU.

En el capítulo 1 se presenta el marco metodológico en el cual se plantea el problema en torno al comercio electrónico y los métodos o técnicas empleados para el análisis del desempeño financiero. Asimismo, se plasma la pregunta de investigación así como el objetivo y la hipótesis de esta investigación. De igual manera, se desarrolla la justificación en la cual se aborda la falta de estudios en el sector del comercio electrónico, enfocados en el análisis del desempeño financiero, así como el uso de la técnica de redes neuronales artificiales en comparación con algunos otros métodos comúnmente utilizados. Adicionalmente, se presenta la metodología empleada, abordando el tipo de investigación que se realizará así como la temporalidad, los tipos de datos que se usarán y la técnica seleccionada.

En el capítulo 2 se realizará una revisión de la literatura referente al desempeño financiero, el cual ha sido un tema de interés en el área financiera al analizar aquellos factores que determinan que una empresa tenga un desempeño exitoso. Se abordarán trabajos enfocados en empresas pertenecientes a diversos sectores, tomando como referencia diversas razones financieras como medidas de desempeño, así como otras variables de tipo macroeconómico, ambientales o conductuales utilizadas como variables independientes.

De igual manera, se revisarán los distintos indicadores que permiten evaluar el desempeño financiero de una empresa, es decir que, se pueden utilizar para analizar la situación en la que se encuentra la organización y de esa manera evaluar

la eficiencia con la que maneja sus recursos, identificar posibles riesgos y así tomar acciones correctivas.

Asimismo, se presentan trabajos relacionados con la aplicación de las redes neuronales artificiales en el área de las finanzas, lo cual permite observar la evolución que ha tenido esta técnica a lo largo de los años así como sus diversas aplicaciones tanto para la clasificación como para los pronósticos de diversos activos financieros.

En el capítulo 3 se presenta el funcionamiento general de las redes neuronales, así como una descripción del proceso de selección de las empresas y las razones financieras que se utilizarían para esta investigación. De igual manera, se especifican las características técnicas para las arquitecturas de redes, las cuales se diseñarán con ayuda del Software SPSS, utilizando uno y dos capas ocultas.

En el capítulo 4 se realizará un análisis de los resultados obtenidos para cada uno de los periodos de estudio, partiendo del 2017-2022, siguiendo con el 2017-2019 y finalizando con el 2020-2022. Para cada periodo se presentarán las cinco arquitecturas con los mejores ajustes de datos así como la información técnica de la que presenta el mejor ajuste. Además, se presentan las razones financieras que impactan en el desempeño financiero así como el orden de importancia de cada una, de acuerdo con la arquitectura seleccionada.

En el capítulo 5 se plantean las conclusiones y recomendaciones de acuerdo con la literatura revisada y los resultados obtenidos de los periodos analizados, así como posibles investigaciones relacionadas con el estudio del desempeño financiero, las limitantes que se encontraron a lo largo de la investigación y un panorama general del comportamiento observado en la actualidad en el área del comercio electrónico, de acuerdo con la prensa económica y la opinión de los expertos.

Para concluir, se incluyen dos anexos: en el anexo 1 se encuentran las diversas arquitecturas de redes neuronales diseñadas con el software SPSS,

haciendo uso de una o dos capas para cada periodo analizado, con sus respectivos porcentajes de ajustes medidas a través del R^2 ; y en el anexo 2 se enlistan las actividades académicas realizadas durante el desarrollo de esta investigación.

Capítulo 1. Marco Metodológico

1.1 Planteamiento del problema

Las empresas realizan actividades encaminadas a tener un desempeño financiero exitoso y por ende la maximización de los beneficios. No obstante, en ocasiones se presentan crisis económicas, financieras, políticas y sociales, que llegan a modificar dichas actividades de forma considerable, lo que afecta el cumplimiento de las metas y objetivos de las empresas. Un ejemplo muy claro es la pandemia generada por el COVID-19, la cual tuvo sus inicios en diciembre de 2019, y fue declarada pandemia en marzo de 2020 (World Health Organization, 2023). Por lo tanto, es necesario que las empresas conozcan cuáles son los factores más sensibles al desempeño financiero, para que de esa manera puedan tomar adecuadas decisiones encaminadas al beneficio de la empresa.

García (2018) comenta que, derivado del progreso tecnológico, se han tenido avances en la industria, y por lo tanto en el comercio dando lugar al comercio electrónico, también conocido como e-commerce o e-business, es decir, comercio a través de medios electrónicos. El comercio electrónico, hace referencia a las actividades asociadas al uso de internet o dispositivos móviles, tales como computadores o teléfonos celulares, permitiendo la comercialización de productos y servicios a través de internet los cuales pueden ser visualizados por internautas de todo el mundo. Es por ello que, las empresas no tienen la limitación de ofrecer sus productos dentro de una región en específico.

La pandemia generada por el virus SARS-CoV2 (COVID-19) ha tenido considerables efectos sobre la economía mundial. Ante tal situación se vio la necesidad de implementar medidas preventivas que ayudaran a mitigar y controlar los riesgos para la salud.

Por tal motivo, en muchos países se aplicaron restricciones de circulación, lo que a su vez provocó un aumento en el comercio electrónico, en especial las ventas minoristas, pasando del 16% al 19% (United Nations Conference on Trade and Development, 2021).

A nivel mundial, las ventas de comercio electrónico, considerando las ventas de empresa a empresa (B2B) y de empresa a consumidor (B2C), alcanzaron los 26.7 billones de dólares durante el 2019, teniendo un incremento del 4% con respecto al año anterior (United Nations Conference on Trade and Development, 2021).

En el caso del comercio B2B, presenta un valor estimado de 21.8 billones de dólares, siendo el 82% de todo el comercio electrónico, mientras que el comercio B2C está estimado en 4.9 billones de dólares, siendo el 18% (United Nations Conference on Trade and Development, 2021).

Debido al aumento exponencial del comercio electrónico luego del COVID-19, se ha presentado un reto en las finanzas respecto a cómo abordar el desempeño financiero de las empresas dedicadas a esta actividad, con el fin de comprender de mejor manera su desempeño financiero.

De manera general, los financieros utilizan diversas técnicas o métodos para realizar análisis financieros, tomando como base, en la mayoría de los casos, estados financieros, con el fin de evaluar la situación en la que se encuentran las empresas o el desempeño que han tenido.

En el análisis de las razones financieras se realiza una comparación de las mismas, el cual puede ser analizando una muestra significativa o mediante series de tiempo. Al analizar una muestra significativa lo que se hace es comparar razones financieras de diversas empresas que operan en una misma industria, tomando un mismo periodo de tiempo. Con el enfoque de series temporales se evalúa el desempeño que ha tenido una empresa a lo largo del tiempo, es decir que, se compara el desempeño que hay tenido en el pasado y en la actualidad. Asimismo, se puede realizar un análisis combinado en el que se evalúan las razones de una empresa con respecto a la tendencia que ha tenido la industria a lo largo del tiempo (Gitman y Zutter, 2012).

De igual manera, existen técnicas utilizadas para la reducción de las dimensiones de las variables de tipo cuantitativo las cuales son el análisis de

componentes principales y el análisis factorial. De manera general, ambos análisis realizan la misma función pero el objetivo fundamental que persiguen es diferente.

En primer lugar se encuentra el análisis de componentes principales el cual permite obtener factores los cuales son resultado de una combinación de variables, basadas en diversos cálculos matemáticos. Para este análisis no necesariamente se tiene en cuenta la interpretación teórica o aplicada, de manera que los factores obtenidos pueden ser matemáticamente correctos pero teóricamente no tanto. Otro tipo de análisis es el factorial en el que se busca descubrir aquellas variables que se asumen podrían estar ocultas o poco percibidas y que están en espera de ser halladas, las cuales tienen una lógica dentro de la teoría o en las relaciones existentes entre las variables (López-Aguado y Gutiérrez-Provecho, 2019).

Por otra parte se encuentra el análisis Dupont, el cual permite analizar los estados financieros de la empresa y de esa manera evaluar la situación financiera en la que se encuentra. Con este análisis se resumen en dos medidas de rentabilidad el estado de pérdidas y ganancias y balance general; dichas métricas son el rendimiento sobre los activos totales y el rendimiento sobre el patrimonio. Para este análisis primero se obtiene el rendimiento sobre los activos totales, resultando de la multiplicación del margen de utilidad neta y la rotación de activos. Posteriormente, este rendimiento obtenido se multiplica por el multiplicador de apalancamiento financiero, lo que permite calcular el rendimiento sobre el patrimonio (Gitman y Zutter, 2012).

Asimismo, el análisis discriminante se considera como una técnica estadística predominante, aplicada por Altman (1968), la cual permite seleccionar y evaluar información financiera para poder clasificar las empresas que son financieramente exitosas y las que no, es decir, aquellas que se encuentran en riesgo de quiebra. Este análisis permite observar la correlación entre indicadores individuales, seleccionando aquellos que más contribuyen al valor discriminante, el cual se denomina como valor de Z.

Otro tipo de herramientas empleadas en el análisis financiero son los modelos de regresión los cuales permiten establecer la relación entre una o varias

variables dependientes y una serie de variables independientes también llamadas variables explicativas. En otras palabras, con este análisis se puede apreciar cómo cambia la variable dependiente cuando las variables independientes lo hacen (Bouza-Herrera, 2018).

Las regresiones pueden utilizar datos de sección cruzada, también llamados de corte transversal, en las cuales se estudian diversos individuos en un determinado momento en el tiempo; por otro lado, éstas pueden ser de series de tiempo es decir que, se analiza un determinado sujeto a lo largo del tiempo. Otro tipo de regresiones son de datos panel en las cuales se analiza el comportamiento de diversos individuos en el transcurso del tiempo (Gujarati y Porter, 2010).

Si bien estos métodos son comúnmente utilizados, sus resultados pueden ser algo limitados, ya sea por una restricción en la muestra, una mala especificación de variables, un determinado tipo de variable dependiente (cualitativa o cuantitativa), o es necesario cumplir ciertos supuestos para poder hacer válido el método, tales como la normalidad, que en muchas ocasiones no es posible cumplir debido a que el comportamiento de las variables financieras puede ser influenciado por aspectos externos y poco previsible como lo es una pandemia.

Autores como Šestanovic y Arneric (2021) y Li et al. (2023), coinciden en que los datos, sobre todo en periodos de cambios, no tienden a seguir una distribución normal, por lo que el uso de métodos clásicos, como lo son los modelos econométricos, no resulta tan eficaz, siendo necesario utilizar otro tipo de técnicas que se adapten a las características de los datos.

Las redes neurales artificiales se han convertido en una herramienta muy importante en diversos campos de estudio, debido a su eficiente capacidad de manejar la información lo cual permite obtener resultados precisos. Esto se debe a que las redes neuronales tienen la capacidad de aprender a partir de datos, es decir que, la red puede entrenarse para que sea capaz de reconocer patrones, clasificar datos y en su caso, pronosticar eventos futuros (Castañeda et al., 2022).

1.2 Pregunta de investigación

¿Cuál fue el comportamiento del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de EE.UU. en el periodo 2017-2022?

1.3 Objetivo de la investigación

Analizar el comportamiento del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de EE.UU. en el periodo 2017-2022.

1.4 Hipótesis

El comportamiento financiero de las empresas vistas en el periodo podrá diferir según las razones financieras del grupo de análisis de margen, rotación de activos, liquidez a corto plazo, y solvencia a largo plazo.

Tabla 1. Matriz de congruencia

Problema	Objetivo	Hipótesis
¿Cuál fue el comportamiento del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de EE.UU. en el periodo 2017-2022?	Analizar el comportamiento del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de EE.UU. en el periodo 2017-2022.	El comportamiento financiero de las empresas vistas en el periodo podrá diferir según las razones financieras del grupo de análisis de margen, rotación de activos, liquidez a corto plazo, y solvencia a largo plazo.

Fuente: Elaboración propia

1.5 Justificación

A pesar de la importancia de medir el desempeño financiero hacia una unidad de negocios naciente como lo es el comercio electrónico, el cual ha ido evolucionando significativamente, no se han realizado estudios detallados de este sector que permitan ver el impacto en el desempeño financiero, durante el periodo de contingencia del COVID-19, mediante el uso de razones financieras. Lo anterior

se debe a que, al ser un acontecimiento reciente, la pandemia provocó cambios repentinos en la dinámica de los hogares, de las empresas, y de la economía en general, por lo que aún no se han desarrollado este tipo de investigaciones. Por lo tanto, esta investigación pretende llenar esa falta de estudios, bajo un enfoque de comercio electrónico, en el cual se busca comparar los resultados con las investigaciones centradas en el desempeño financiero que fueron realizadas antes de COVID-19.

En los últimos años, se han realizado estudios relacionados con el desempeño financiero en diversos sectores como por ejemplo, aquellos orientados a empresas de bienes de consumo (Haque y Afzal, 2017), a las sociedades manufactureras (Salazar-Mosquera, 2017), o al sector de bebidas no alcohólicas (Rivera et al., 2020). En dichos estudios se ha observado la aplicación de distintos métodos, como análisis de tendencias o modelos econométricos, empleando diversas razones financieras.

Sin embargo, en el campo de las ciencias computacionales ha surgido una técnica de análisis basada en inteligencia artificial, conocida como redes neuronales artificiales (RNA), la cual emplea variables de entrada y salida con el fin de establecer relaciones entre ellas. Las RNA se encuentran basadas en el funcionamiento del cerebro humano, específicamente en el comportamiento de las neuronas biológicas. Gracias al gran potencial que han demostrado tener para la automatización de tareas mediante procesos de entrenamiento, la aplicación de esta técnica se ha vuelto multidisciplinaria, utilizándola cada vez más en áreas como la salud, la robótica e incluso en las finanzas.

Por lo tanto, se utilizarán las RNA para estudiar las plataformas dedicadas al comercio electrónico, lo que permitirá determinar el modelo más eficiente para analizar el desempeño financiero y el impacto que tienen las razones financieras sobre este. Es por ello que, al entender los patrones de comportamiento de las razones financieras y el desempeño financiero, los agentes económicos podrán decidir de mejor manera para obtener mayores beneficios, de manera que, en este

caso, se tendrán mejores posibilidades de tomar decisiones con base en los resultados y en el impacto financiero observado.

1.6 Metodología

La investigación será de tipo cuantitativo, descriptivo y no experimental. Se abordará un enfoque cuantitativo debido a que se emplearán datos numéricos que permitirán realizar el análisis. De igual manera, es descriptiva ya que se busca determinar los factores que impactan el comportamiento del desempeño financiero de las empresas dedicadas al comercio electrónico. Será no experimental ya que las variables no presentan ningún tipo de manipulación, las cuales serán obtenidas directamente de la plataforma de S&P Capital IQ.

Con relación a la temporalidad de la investigación, esta será de tipo longitudinal, puesto que el análisis de las empresas abarcará un periodo de 5 años, partiendo del 2017 al 2022. Lo anterior permitirá observar el comportamiento del sector, abordando un periodo general, así como periodos específicos que abarcan antes (2017-2019) y durante (2020-2022) la pandemia.

Para la investigación se realizará una selección de empresas dedicadas al comercio electrónico, las cuales no solo proporcionen bienes sino también servicios a través de medio electrónicos. Se tomarán en cuenta aquellas que coticen en la bolsa de valores de EE.UU y tengan operaciones de por lo menos 5 años, tomando datos trimestrales a partir del 2017 al 2022. De igual forma, otro aspecto a considerar es que tengan un grado similar de capitalización, omitiendo aquellas que tuvieran un mayor o menor nivel.

Los datos que se utilizarán serán las razones financieras correspondientes al grupo de rentabilidad, análisis de margen, rotación de activos, liquidez a corto plazo, y solvencia a largo plazo. Dichas razones serán filtradas tomando como un criterio de selección la cantidad de datos que tengan, con el fin de que se cuente con suficiente información para poder realizar el análisis correspondiente.

Posteriormente, se emplearán redes neuronales artificiales para determinar los factores que impactan el comportamiento del desempeño financiero del grupo

de empresas de estudio, utilizando como variables de entrada las razones financieras y teniendo como variable de salida el desempeño financiero medido a través del Rendimiento sobre Activos (ROA). Para ello, se diseñarán diversas arquitecturas de redes con el fin de determinar aquellas que presenten un mejor ajuste de los datos. Lo anterior permitirá observar los cambios que ha tenido el comportamiento del desempeño financiero durante los periodos de estudio y así realizar un comparativo entre estos.

Capítulo 2. Marco Teórico

2.1 Desempeño financiero

El desempeño financiero de las empresas ha sido un tema de interés para diversos investigadores quienes se han enfocado en el análisis de los factores que permiten que una empresa tenga un desempeño financiero exitoso. El desempeño financiero puede conceptualizarse como el conjunto de actividades destacadas para que se puedan cumplir las metas y objetivos de las empresas con el fin de complacer las demandas tanto de los accionistas, como de los clientes y el mercado (Mejia, 2019). Este resulta ser un factor muy importante ya que refleja la posición financiera en la que se encuentra la empresa, así como el crecimiento de la industria (Haque y Azfal, 2017).

2.1.1 Estudios enfocados al desempeño empresarial

Haque y Azfal (2017) se enfocan en la evaluación del desempeño financiero de la industria de bienes de consumo en la India, centrándose en las empresas que cotizan en la Bolsa Nacional de Valores de la India. Se establecieron tres hipótesis para la investigación:

- 1) no existe un impacto significativo de las ventas en la posición de liquidez de las empresas de bienes de consumo que se seleccionaron;
- 2) no existe un impacto significativo de las ventas en la posición de solvencia de las empresas de bienes de consumo de las empresas que se seleccionaron;
- 3) no existe un impacto significativo de las ventas en la posición de rentabilidad de empresas seleccionadas de bienes de consumo.

Para dicha investigación se tomaron en consideración los índices de solvencia, liquidez, rentabilidad y ventas, además de que se realizó un análisis de regresión simple con el fin de medir el impacto que tienen las ventas en la liquidez, la solvencia y la rentabilidad de las empresas seleccionadas (Haque y Azfal, 2017).

De acuerdo con los resultados obtenidos por Haque y Azfal (2017), se puede apreciar una sólida rentabilidad para el accionista de la empresa o, en otras

palabras, una posición de rentabilidad satisfactoria. Asimismo, los resultados demostraron que, las razones de liquidez fueron más bajas que los estándares, aunque aún se tenía una posición satisfactoria de liquidez de manera que pudieron cubrir sus obligaciones en el corto plazo. De igual manera, la relación deuda-capital ha demostrado que las empresas no han utilizado, o en dado caso, han empleado poca deuda de su estructura de capital.

Por otra parte, se obtuvo una fuerte relación positiva entre las ventas y la liquidez, así como de la rentabilidad con el incremento de las ventas. Por último, los hallazgos demostraron que las ventas de las empresas de estudios tuvieron efectos significativos en la liquidez y la rentabilidad, aunque no en su solvencia (Haque y Azfal, 2017).

Salazar-Mosquera (2017) analiza las sociedades manufactureras de la Provincia del Tungurahua, Ecuador centrándose en determinar los factores que inciden en la rentabilidad, tomando como base la información proporcionada por la Superintendencia de Compañías. En dicho estudio se empleó un análisis de correlación a una muestra compuesta por empresas activas del sector manufacturero de la provincia del Tungurahua.

El análisis de correlación es una técnica de dependencia, la cual tiene por objetivo explicar o predecir un fenómeno, conformada por dos tipos de variables: dependientes e independientes, siendo estas últimas, factores relacionados con las primeras variables (Salazar-Mosquera, 2017).

Se emplea el coeficiente de correlación de PEARSON para determinar los factores que influyen en la rentabilidad, obteniendo resultados entre -1 y +1, siendo la correlación fuerte positiva cuando el valor se aproxima a +1 y, por el contrario, una correlación fuerte negativa cuando se aproxima a -1. En caso de que el resultado sea 0 hay una ausencia de correlación (Rodríguez y Rodríguez, 2016).

Por lo tanto, para fines de dicha investigación, Salazar-Mosquera (2017) empleó una muestra de 140 sociedades de la provincia de Tungurahua, tomando como variable dependiente el indicador de rentabilidad sobre el activo (ROA), así

como aquellos indicadores que explican su aportación con la rentabilidad. De igual manera, se analizó la correlación de la rentabilidad sobre el patrimonio, conocida también como rentabilidad financiera (ROE).

Para dicho estudio se emplearon los siguientes indicadores: liquidez-corriente, prueba ácida, endeudamiento sobre el activo, endeudamiento sobre el patrimonio, endeudamiento sobre el activo fijo neto, apalancamiento operativo, apalancamiento financiero, rotación de cartera, rotación del activo fijo, rotación de ventas, rentabilidad neta sobre el activo, margen bruto en ventas y rentabilidad sobre el patrimonio. Estos indicadores permitieron obtener el coeficiente de correlación entre cada uno de los indicadores que se obtuvieron por las empresas con el indicador más representativo del desempeño empresarial, es decir, la rentabilidad sobre el activo (Salazar-Mosquera, 2017).

De acuerdo con los resultados obtenidos, Salazar-Mosquera (2017) identificó que el factor determinante de la rentabilidad sobre el activo (ROA) es la rotación de ventas, demostrando una fuerte correlación durante el año 2014 y 2015, de manera que mientras haya una mayor velocidad en la rotación de ventas, mayor será la rentabilidad sobre el activo.

Por otra parte, Salazar-Mosquera (2017) observa que, la liquidez presenta una correlación inversa en la rentabilidad en el año 2014, confirmando así la teoría de que, a mayor grado de liquidez generada, menor rentabilidad habrá. No obstante, para el año 2015, se aprecia una incidencia directa debido al decremento de los indicadores de endeudamiento ya que había la necesidad de preservar altos márgenes de liquidez para poder hacer frente a la recesión económica que atravesaba el país.

En el caso del ROE y la rentabilidad neta sobre el activo, el autor también obtuvo una fuerte incidencia directa con la rotación de ventas y el apalancamiento operativo, mientras que con la liquidez hubo una correlación inversa. Dichos resultados demuestran los efectos del aprovechamiento de los costos fijos y la capacidad instalada en el desempeño empresarial (Salazar-Mosquera, 2017).

Por lo tanto, Salazar-Mosquera (2017) recomienda mejorar el apalancamiento operativo a través de estrategias de diversificación o expansión como estrategia para mejorar la rentabilidad sobre el patrimonio. Si fuera el caso de que el mercado no soporte la oferta será necesario disminuir el tamaño de los activos fijos con el fin de mejorar los índices de competitividad y productividad.

Por otro lado, Cegarra (2018) analiza la relación existente entre el ambiente externo y el desempeño financiero del sector privado de la salud en la ciudad de Barinas, Venezuela, tomando las 25 empresas existentes en este sector.

Asimismo, se seleccionaron los 15 factores ambientales más significativos para el sector, relacionados con aspectos políticos, económicos, proveedores y clientes, y se emplearon dos dimensiones (Munificencia y Dinamismo) con el fin de describir las percepciones que se tienen sobre cada uno de los factores seleccionados. Para cuantificar el desempeño financiero se empleó el Retorno sobre la Inversión (ROI), con el fin de determinar el efecto del ambiente externo sobre la utilización de los activos; y el Retorno sobre el Patrimonio (ROE) para precisar la rentabilidad del aporte de los accionistas (Cegarra, 2018).

Posteriormente, Cegarra (2018) planteó cuatro hipótesis, de las cuales, las tres primeras ponen a prueba las relaciones entre los factores ambientales y las proporciones del ambiente externo, dinamismo y munificencia, y la última intenta demostrar la relación entre estas dimensiones y el desempeño financiero.

La primera hipótesis busca determinar aquellos factores ambientales que tienen efectos en la estabilidad o perturbación del ambiente externo. La segunda hipótesis investiga los factores ambientales que se encuentran relacionados con lo predecible o impredecible del ambiente externo. En el caso de la tercera hipótesis, comprueba los factores que contribuyen, de manera favorable o desfavorable, en el ambiente externo. En la cuarta hipótesis se indaga la relación entre las proporciones del ambiente externo y el desempeño financiero (Cegarra, 2018).

Cegarra (2018) realizó un censo, empleando una escala de Likert de 5 categorías, el cual se enfocó en el grado de percepción de variabilidad y

predictibilidad, para poder medir el dinamismo y favorabilidad de cada factor ambiental, y para evaluar la munificencia.

Con el fin de analizar los datos se hizo uso de técnicas estadísticas de escalamiento óptimo, de manera que, para las 3 primeras hipótesis se empleó el Análisis de Componentes Principales Categóricos (CATPCA) con rotación varimax, permitiendo la reducción de la variabilidad a 2 componentes de los 15 factores ambientales seleccionados, permitiendo revelar la contribución de los factores ambientales en cada componente. En el caso de la cuantificación de las 5 categorías de cada factor ambiental, determinó el grado de percepción preponderante en cada uno de ellas. De esta misma manera se procedió con los indicadores de predictibilidad y favorabilidad, obteniendo 2 componentes para cada uno de ellos. Para el caso de la ROI y la ROE, Cegarra (2018) los redujo a un solo componente a través de un Análisis factorial.

Por otra parte, con el fin de demostrar las relaciones significativas entre las dimensiones del ambiente externo y el desempeño financiero, Cegarra (2018) utilizó el Análisis de Correlación Canónica No Lineal (OVERALS). A partir de los componentes obtenidos anteriormente con los Análisis CATPCA y factorial, se armaron 4 conjuntos de datos y se analizaron mediante OVERALS, para determinar aquellos componentes relacionados con la rentabilidad. Todo lo anterior permitió mapear la asociación entre los factores ambientales y el desempeño financiero, así como la magnitud de la percepción de cada factor que tienen efectos en esta relación.

Los hallazgos obtenidos por Cegarra (2018) señalaron la existencia de una fuerte relación entre los factores del ambiente externo y el desempeño financiero, apoyando la teoría en donde el desempeño organizacional es considerado como una variable dependiente y al ambiente externo como independientes. En dicha investigación se llegó a la conclusión de que el ambiente externo se encuentra fuertemente relacionado con el desempeño financiero del sector privado de la salud en la ciudad de Barinas, Venezuela, puesto que se obtuvieron altas correlaciones entre la mayoría de los factores ambientales, las dimensiones del ambiente externo

y la rentabilidad de las empresas de dicho sector, que parecen indicar la existencia de dicha relación.

Por otra parte, se encuentran Díaz et al. (2019) quienes estudiaron el impacto que tiene la adopción de prácticas administrativas en el desempeño financiero de las microempresas mexicanas teniendo como hipótesis que la adopción de ciertas prácticas administrativas juegan un considerable papel para explicar el desempeño financiero de este sector de empresas.

Para dicho estudio se emplearon dos metodologías: una regresión econométrica de sección cruzada, así como las redes neuronales artificiales, con el fin de comparar y confirmar la evidencia. Con relación al modelo de regresión, se establece una relación lineal entre variables dependientes como independientes o explicativas, y se emplea el procedimiento de Mínimos Cuadrados Ordinarios (MCO) con el fin de minimizar el error cuadrático de la función (Díaz et al., 2019).

En el caso de las redes neuronales, su función se asemeja al cerebro debido a que, por una parte, el conocimiento se adquiere a través de un proceso de aprendizaje, y las fuerzas de conexión entre neuronas son empleadas para acumular el conocimiento generado a través de procesos de aprendizaje, tal y como ocurre con una red neuronal biológica. Además, es posible definir parámetros lineales y no lineales, contando con una entrada y una salida (Díaz et al., 2019).

Con los resultados obtenidos, Díaz et al. (2019) demuestran que las prácticas de planeación financiera, dentro de las cuales se encuentra la revisión mensual de las ventas, la realización de presupuestos y ventas anuales, la elaboración de registros contables del desempeño financiero, son aquellas que muestran un impacto en el desempeño financiero de la empresa, el cual está aproximado con los ingresos por ventas. Por el contrario, las prácticas de control de compras e inventarios y registro de compras y mantenimiento, no demuestran un efecto significativo en el desempeño financiero de las empresas. Con relación al acervo de capital, este influye de manera relevante en los ingresos mensuales, demostrando la teoría de que, una mayor relación de capital por trabajador tiene impactos en la productividad y, posteriormente en las ventas.

Los resultados de Díaz et al. (2019) permiten aportar información acerca de aspectos claves en el desempeño financiero de las micro organizaciones mexicanas, destacando las prácticas de planeación financiera y las variables stock de capital, edad y nivel educativo del dueño de la empresa.

Por otra parte, se encuentran Padilla-Ospina et al. (2019) quienes examinan el desempeño financiero de empresas del sector real de Colombia consideradas como las más innovadoras, tomando como muestra 25 empresas de este sector, y empleando un análisis de tendencias de los indicadores financieros: apalancamiento financiero total, rotación de activos operacionales, margen de utilidad neta y rendimiento del patrimonio, de acuerdo con la información contable correspondiente al periodo del 2010 al 2016.

Asimismo, se realizó el cálculo del valor económico agregado (EVA) y su valor de mercado agregado (VMA). El EVA es calculado como la utilidad residual que es resultado de la diferencia entre la utilidad operacional después de impuestos y el cargo por la utilización del capital (Stewart, 2000). En el caso del VMA se refiere al valor presente del EVA, durante el periodo estudiado (Padilla-Ospina et al., 2019).

Padilla-Ospina et al. (2019) lograron comprobar que 14 de las empresas seleccionadas en la muestra, presentaron incrementos en sus inversiones en activos durante el 2012-2016, permitiendo inferir que gran parte se encontraba destinada a actividades de innovación lo que a su vez se traducía en una mayor participación del sector privado en la financiación de la innovación.

Con la evaluación del desempeño financiero de las empresas, Padilla-Ospina et al. (2019) observaron que el 95% de las empresas obtuvieron resultados positivos, de manera que éstas fueron efectivas en la generación de utilidades contables para los socios. No obstante, cuando se examinaron los indicadores de gestión de valor, es decir, el EVA y el VMA, únicamente el 62% fueron aquellas que crearon valor en por lo menos un año del periodo estudiado, entre las cuales, únicamente el 43% fueron las que cumplieron con el objetivo de crear valor del 2012 al 2016.

Entre estas últimas, con VMA positivo, se encuentran cuatro de las cinco empresas más innovadoras de Colombia, corroborando de cierta manera la correlación entre el éxito financiero y una perceptible innovación. Sin embargo, aquellas empresas innovadoras y generadoras de valor fueron menos de la mitad. Esta diferencia existente entre los hallazgos encontrados del desempeño financiero de las empresas innovadoras, a través de indicadores contables e indicadores de gestión de valor, se debe a que el ROE no toma en cuenta los costos de oportunidad de los socios y está calculado a partir de la utilidad neta contable, mientras que, por otra parte, el EVA si toma en consideración estos costos y está basado en la utilidad residual. Por lo tanto, tomando en cuenta lo anterior, Padilla-Ospina et al. (2019) consideran aceptable el desempeño financiero de las empresas innovadoras en términos financieros absolutos, pero no en términos relativos del costo de oportunidad que los inversionistas de estas empresas requieren.

En el caso de Pokharel et al. (2019), ellos tenían por objetivo la identificación del estrés financieros, así como las causas de dicho estrés para las cooperativas agrícolas. Para esta investigación se empleó la media geométrica de la tasa real de rendimiento del capital social, con el fin de poder identificar las cooperativas agrícolas que presentaban dificultades financieras. Esta tasa real de rendimiento de capital social hace posible la asignación del estrés financiero entre el rendimiento de los activos, así como el apalancamiento y las cuestiones de tipos de interés.

En este estudio, Pokharel et al. (2019) encontraron que las cooperativas agrícolas que no presentaban estrés financiero tenían una tasa de rendimiento sobre el capital y sobre los activos más alta, pero las tasas de apalancamiento y de interés resultaron más bajas que las cooperativas agrícolas con estrés financiero. De igual manera, las cooperativas que no se encontraban estresadas contaban con activos y ventas totales superiores a las de las cooperativas estresadas. Por lo tanto, se infiere que las cooperativas de menor tamaño tienen más posibilidades de enfrentarse a tensiones financieras, a comparación de las grandes cooperativas. Con la descomposición de problema financiero se pudo observar que un porcentaje considerable de estrés financiero se encontraba correlacionado con un bajo retorno

sobre los activos o la rentabilidad. Por otro lado, un porcentaje menor de estrés financiero fue causado por decisiones de financiamiento.

Por otro lado, se encuentran Vieira et al. (2019) quienes analizan los factores determinantes del desempeño de las empresas portuguesas, planteando las siguientes hipótesis:

- 1) La liquidez de las empresas presenta efectos significativos en el desempeño corporativo.
- 2) El apalancamiento financiero presenta efectos significativos en el desempeño corporativo.
- 3) El tamaño de la empresa presenta efectos significativos en el desempeño corporativo.
- 4) El PIB se relaciona de manera positiva con el desempeño empresarial.
- 5) La deuda pública presenta efectos significativos en el desempeño corporativo.
- 6) El sentimiento de los inversores presenta efectos significativos en el desempeño corporativo.
- 7) La existencia de propiedad gerencial presenta efectos significativos en el rendimiento.
- 8) El tamaño de la junta presenta efectos significativos en el desempeño corporativo.

En dicha investigación se empleó la metodología de datos panel, ya que presenta diversas ventajas sobre otros modelos, puesto que permite eliminar la heterogeneidad no observable, la cual puede llegar a sesgar los resultados. Comparándolo con un análisis de corte transversal convencional, el modelo de datos panel permite control sobre la heterogeneidad individual, lo cual resulta beneficioso para el estudio ya que el ROA está basado en las decisiones de gestión, así como en las elecciones humanas, las cuales se encuentran estrechamente relacionadas con la especificidad de cada empresa. Asimismo, es posible controlar el problema de endogeneidad al aplicar este método (Vieira et al., 2019).

De acuerdo con los resultados obtenidos, los determinantes del desempeño cambian de acuerdo con la variable que se emplee para la medición del desempeño financiero puesto que se pueden perseguir diversos intereses. Específicamente, se apreció que cuando se hace uso de una variable de desempeño de mercado, las variables que son específicas de las empresas no resultan determinantes para la explicación del desempeño, de manera que los factores macroeconómicos, en los que se incluye el sentimiento del inversor y la propiedad privada de la información privilegiada, son los que permiten explicar de mejor manera el desempeño de la empresa (Vieira et al., 2019).

Ngamjan y Buranasiri (2020) realizan una explicación de los factores que impulsan el desempeño de las cooperativas agrícolas en Tailandia, a través del análisis de DuPont, el cual implica una descomposición del ROE, siendo este método un marco para analizar el desempeño financiero. Si bien en este tipo de análisis se usa ampliamente el desempeño corporativo, muy poco se ha investigado del análisis DuPont aplicado al desempeño financiero agrícola. Asimismo, se estimaron regresiones OLS y por cuantiles. La regresión OLS tiene como base un conjunto de rigurosos supuestos relacionadas con las características de los datos. Con relación a la regresión por cuantiles, esta es más robusta con los valores atípicos.

De acuerdo con los resultados obtenidos se demostró una relación positiva entre la rentabilidad, la eficiencia de los activos y el apalancamiento financiero, con el ROE. Dentro de los factores más significativos que impulsan el ROE se encuentra el margen de beneficio o la eficacia del gestor para generar beneficios netos de las ventas, así como el apalancamiento financiero. Con respecto a las estimaciones por cuantiles, estas proporcionaron un panorama más amplio de aquellos factores que tiene efectos significativos en el desempeño en diferentes cuantiles (Ngamjan y Buranasiri, 2020).

Rivera et al. (2020) analizan el desempeño financiero del sector de bebidas no alcohólicas en Colombia (SBNAC) durante el periodo 2014-2018, empleando un análisis estático y de tendencias de indicadores contables, y de creación de valor.

Asimismo, se realiza una comparación de los resultados con la información de las grandes empresas del sector de bebidas no alcohólicas (SGBNAC).

En el caso de los indicadores contables, éstos son uno de los instrumentos de análisis más reconocidos para la medición y evaluación del desempeño financiero, entre los cuales se encuentran aquellos que permiten medir el crecimiento, eficiencia, eficacia y efectividad. Los indicadores de crecimiento son aquellos que miden el progreso del sector, con relación a sus ventas, activos y utilidad neta, mientras que los de eficiencia son medidos por los indicadores de rotación de activos, destacando los activos totales, fijos, operacionales, de inventarios, y de cartera. Los indicadores de efectividad cuantifican las utilidades recibidas por la inversión que realizan los inversores de las empresas y sus propietarios, a través del rendimiento del activo (ROA), y el rendimiento del patrimonio (ROE), respectivamente (Rivera et al., 2020).

Por otro lado, la creación del valor puede abordarse desde dos perspectivas: interna, la cual es cuantificable para todas las empresas, y la externa, que se aplica únicamente para las empresas que cotizan en bolsa. Desde la perspectiva interna, se puede determinar a través del valor presente neto, ya sea mediante el conocimiento de la información histórica y proyectada, o por información contable ajustada con el fin de obtener una utilidad residual, como es el caso del Valor Agregado Económico (EVA). Por lo tanto, para la investigación se empleó el EVA y el Valor de Mercado Agregado (VMA), el cual se obtiene del valor presente del EVA (Rivera et al., 2020).

Los hallazgos de Rivera et al. (2020) permiten apreciar el crecimiento irregular del sector, específicamente de sus ventas, activos y utilidad neta, el cual coincide con la información de SGBNAC a excepción de la utilidad neta que disminuye. De igual manera, se observa que los indicadores contables de efectividad fueron positivos, con tendencia al alza pero con altibajos, dependiendo del comportamiento que tuvieron los indicadores de eficacia en el control de costos y gastos, particularmente del ROE que se intensificó por un apalancamiento

financiero positivo. Por otra parte, la eficiencia en la utilización de los recursos se mantuvo casi constante.

De igual manera, este sector estuvo creando valor económico agregado (EVA) cada año durante el periodo de estudio, ya que la rentabilidad del activo neto operacional fue mayor al costo del capital. Por lo tanto, de manera general se concluye que el sector de estudio tuvo un desempeño financiero favorable en cuanto a los indicadores contables y de gestión de valor (Rivera et al., 2020).

Neves et al. (2021) evalúan el desempeño financiero de las empresas que se encuentran reguladas, las cuales operan en el mercado eléctrico portugués durante el periodo de 2011 a 2014, periodo en el cual el gobierno portugués brindó ayuda financiera. En este estudio se empleó una metodología de datos panel, ya que permiten tener un control de la heterogeneidad individual lo que resulta importante puesto que, el ROE depende de las decisiones de gestión, lo que podría estar relacionado con la especificidad de cada empresa. De igual manera, permite acomodar la endogeneidad que pudiera resultar entre la variable dependiente y algunas de las variables explicativas del modelo.

De acuerdo con los hallazgos se aprecia que tanto para el 2010 como para el 2014, la mayoría de las empresas no eficientes debería impulsar la inversión en activos fijos con el fin de volverse eficientes. Asimismo, en estos dos periodos, la mayoría de las empresas eléctricas ineficientes deberían aumentar su retorno sobre el capital para poder ser eficientes. También, durante el 2014, las empresas no eficientes están calificadas para la generación de flujos de caja eficientemente, esto debido a que casi no son necesarios ajustes en el flujo de caja de los valores de los activos totales que alcanzaron dichas empresas. Por último, resulta evidente en el 2010, más que en el 2014, la necesidad de tener un impulso en el apalancamiento para aumentar el desempeño financiero, lo que indica la necesidad de disminuir el grado de endeudamiento de las empresas durante este periodo (Neves et al., 2021).

En el caso de Popa et al. (2021), ellos tenían por objetivo el diseño de un índice financiero compuesto que permitiera la determinación del rendimiento financiero de las empresas que cotizan en la Bolsa de Valores de Bucarest, para los

años que comprenden del 2011 al 2018. Se seleccionaron ocho indicadores financieros para la determinación del desempeño financiero de las empresas que se incluyeron en la muestra, los cuales se agruparon en indicadores de valor agregado e indicadores contables tradicionales. Dentro de los primeros indicadores se encuentra el Valor Económico Agregado (EVA), el Valor Agregado de Mercado (MVA), el Flujo de efectivo de retorno de inversión (CFROI) y el Valor agregado en efectivo (CVA). En el caso de los otros indicadores se incluyen el beneficio por acción, la rentabilidad del activo (ROA), la rentabilidad del patrimonio (ROE) y la solvencia (SOL).

Teniendo como base los indicadores ya mencionados, se construyó un indicador compuesto de medición del desempeño compuesto, empleando el análisis de componentes principales, el cual permite el cálculo de nuevas variables que son conseguidas como resultados de combinaciones lineales de las variables originales. Las nuevas variables son denominadas componentes principales, en las cuales, el primer componente rescata la mayor variación de las variables originales, mientras que el segundo componente no tiene correlación con el primero e incorpora la mayoría de las otras posibles variaciones, y así de manera sucesiva. Dicho índice fue construido para añadir la información financiera acerca del desempeño de la empresa, facilitando la predicción de su evolución mediante redes neuronales (Popa et al., 2021).

Posteriormente se empleó un modelo de predicción basado en redes neuronales, el cual consta de tres elementos conformados por las capas de entrada, las capas ocultas y las capas de salida. En cada capa se tiene un conjunto de neuronas que hacen posible la conexión con las neuronas que se encuentran en la siguiente capa (Popa et al., 2021). Dicho modelo ofreció una buena predicción, así como resultados satisfactorios, los cuales pueden ser usados para la evaluación y predicción del desempeño de las empresas de estudio.

En general, Popa et al. (2021) concluyen que son necesarias observaciones de más de un año con el fin de que se pueda predecir el valor del índice de desempeño financiero, de manera que, la predicción del índice como un indicador

compuesto se encuentra relacionada con la evolución de los indicadores financieros de años anteriores y no solo con sus valores individuales de un año. Por lo tanto, se observó que el modelo de redes neuronales realizó una mejor predicción del índice compuesto cuando se toman en cuenta más datos reales para dicho índice en lugar de solo tomar un año.

Sharma et al. (2021) se enfocan en la investigación de los factores que resultan determinantes del desempeño financiero de las compañías de seguros que se encuentran operando en el Reino Unido para el periodo del 2006-2009, empleando un modelo de regresión probit ordenado (OPM), el cual es un método apropiado para los casos en los cuales hay más de dos resultados de una variable dependiente ordinal.

Sharma et al. (2021) hallaron que los determinantes más significativos que influyen en las compañías seleccionadas son la rentabilidad, la liquidez, el tamaño y la forma organizativa. Sin embargo, el apalancamiento, el reaseguro, el crecimiento, así como el tipo de negocio no guardan relación estadísticamente significativa con los grados de calificación.

Por otro lado, Xu et al. (2021) investigaron el papel que tiene la estructura de capital en el desempeño financiero de las empresas agrícolas chinas que cotizaban en la Bolsa para los periodos entre 2013 y 2019. En dicha investigación plantearon tres hipótesis: 1) el índice de deuda total presenta un impacto negativo en el desempeño financiero de las empresas agrícolas cotizadas; 2) el índice de endeudamiento a corto plazo presenta un impacto negativo en el desempeño financiero de las empresas agrícolas cotizadas; 3) el índice de endeudamiento a largo plazo presenta un impacto negativo en el desempeño financiero de las empresas agrícolas cotizadas.

Para el análisis de datos se empleó una regresión de datos panel, utilizando como variables dependientes el ROA y el ROE, usados para la medición del desempeño financiero de las empresas. Por una parte, el ROA mide la eficiencia del uso de los activos para la generación de ganancias y, por otro lado, el ROE muestra la capacidad que tiene una empresa para generar ganancias partiendo del

capital contable. Como variables independientes se empleó el ratio de la deuda total, de la deuda a corto plazo así como de la deuda a largo plazo. De igual manera, se manejaron variables de control como el tamaño de la empresa, la tasa de crecimiento de las ventas, la tangibilidad, la liquidez, y la tasa de crecimiento del producto interno bruto. Finalmente, se incluye una variable ficticia que ayuda a controlar los cambios en el ambiente económico: el año (Xu et al., 2021).

Los hallazgos demostraron que el índice de deuda total y el de deuda a corto plazo presentan efectos negativos en el desempeño financiero de las empresas agrícolas chinas seleccionadas. Por otro lado, el índice de deuda a largo plazo no presenta efectos significativos ni en el ROA ni en el ROE. De igual manera, el efecto de la estructura de capital en el desempeño financiero de las empresas de propiedad privada es mayor que el de las empresas estatales. En el caso de la deuda total, el grado de impacto negativo en el desempeño financiero es mayor para las empresas que se encuentran en las regiones centrales y occidentales, comparadas con las empresas localizadas en la región oriental (Xu et al., 2021).

2.1.2 Indicadores financieros como medida del desempeño financiero

El desempeño financiero de una organización se puede evaluar con la ayuda de razones financieras, en conjunto con hechos y cifras financieras, las cuales permitirán juzgar la capacidad de ganancia que tiene la empresa, así como la eficiencia con la que dicho ente emplea sus recursos en determinado año (Haque y Azfal, 2017).

Los análisis financieros permiten detectar la situación, así como el desempeño económico y financiero de una organización, además de que se pueden revelar las dificultades para poner en marcha las respectivas correcciones. Dicho análisis está basado en el cálculo de los indicadores financieros enfocados en la eficiencia, la solvencia, la liquidez, el endeudamiento y la rentabilidad que tienen los entes. Los indicadores financieros son conocidos como una manera de evaluar las finanzas, mediante la relación y combinación de elementos que permitan representar los datos presentados en los estados financieros (Marcillo-Cedeño et al., 2021).

De acuerdo con Marcillo-Cedeño et al. (2021), los indicadores de liquidez y solvencia tienen por objetivo la medición del grado y forma en que los acreedores están interesados por los financiamientos de las empresas. Es necesario establecer el riesgo que corren los acreedores y dueños, así como las ventajas y desventajas que tiene el endeudamiento. Cuando se habla de liquidez, se hace referencia a que una empresa está cumpliendo con sus deberes, mientras que la solvencia muestra la disponibilidad para poder saldar las deudas.

Entre los indicadores de liquidez se encuentra el capital de trabajo neto, la razón circulante y la prueba ácida. En el caso de los indicadores de solvencia se encuentra el endeudamiento del activo, el endeudamiento patrimonial, endeudamiento del activo fijo, apalancamiento y apalancamiento financiero (Marcillo-Cedeño et al., 2021).

Por otra parte, están los indicadores de eficiencia, también llamados indicadores de la actividad, los cuales, según Marcillo-Cedeño et al. (2021) están enfocados en precisar la velocidad para realizar las ventas o el efectivo. Los indicadores de eficiencia son los siguientes: rotación de activos totales, activos fijos, ventas totales, costos de venta, rotación de cuentas por cobrar, ventas a crédito, cuentas por cobrar y periodo promedio de cobro.

Por otro lado, se encuentran los indicadores de capacidad de endeudamiento los cuales son una de las cuatro medidas fundamentales para el rating de crédito. Por lo tanto, el nivel de endeudamiento que tienen las entidades es un indicador de la cantidad de dinero que contribuyen otras personas para la generación de beneficios. La razón del pasivo circulante a largo plazo, cobertura de interés, pasivos y activos totales, son los indicadores de endeudamiento (Marcillo-Cedeño et al., 2021).

Según Marcillo-Cedeño et al. (2021), la rentabilidad puede ser medida a través de diversos indicadores, que se encuentran determinados por una serie de indicadores de costos y gastos. Estos indicadores pueden permitir la realización de un seguimiento adecuado acerca de la situación de las finanzas de una organización, especialmente en como las ventas pueden convertirse en utilidades.

Dentro de los indicadores de rentabilidad se aprecian los siguientes: deuda o pasivo total, coeficiente de endeudamiento a corto plazo, coeficiente de endeudamiento a largo plazo, cash Flow o flujo de efectivo, y fondo de maniobra.

2.2 Redes Neuronales Artificiales aplicadas a las finanzas

Las redes neuronales artificiales (RNA) se han convertido en una rama de estudio multidisciplinaria en las ciencias en general. Desde 1936, Alan Turing inicia la posibilidad de trabajar con este tipo de redes cuando se encuentran relaciones entre el cerebro y la computación. Actualmente es posible encontrar diversos trabajos que emplean las redes neuronales artificiales, además de que, las empresas ya se encuentran desarrollando aplicaciones de estos modelos para hardware y software (Acevedo et al., 2017).

Villada-Duque et al. (2016) definen las redes neuronales artificiales como sistemas de aprendizaje basados en el funcionamiento del cerebro humano, que permiten establecer relaciones no lineales entre las variables de entrada y salida, haciéndolos de gran utilidad en el pronóstico de datos económicos y financieros, empleando series temporales. Se ha permitido su aplicación en la clasificación y reconocimiento de patrones en sistemas complejos debido a que puede procesar información en paralelo en tiempo real.

Otra concepción es la presentada por Meneses-Bautista y Alvarado (2017) en la cual la red neuronal artificial es vista como un modelo de cómputo que es autoadaptativo y bioinspirado, el cual trata de imitar la gran cantidad de interconexiones que presentan las células nerviosas, alcanzando niveles de procesamiento muy elevados, brindando la capacidad de enfrentarse a problemas muy complejos, con gran eficacia y precisión.

De igual manera, Matich (2001) menciona que las redes neuronales están conformadas por unidades de procesamiento que realizan un intercambio de datos o información, los cuales son utilizados para reconocer patrones, ya sea de imágenes, manuscritos y series de tiempo. Asimismo, son capaces de aprender y con ello mejorar su funcionamiento.

Los modelos de redes neuronales pueden ser clasificados como modelos de tipo biológico o dirigido a la aplicación. En la primera clasificación las redes tratan de imitar los sistemas neuronales biológicos, como algunas funciones auditivas o básicas de la visión. Los modelos dirigidos a la aplicación no guardan necesariamente similitud con los sistemas biológicos y su arquitectura se encuentra fuertemente relacionada con las necesidades de las aplicaciones para la cual se ha diseñado (Matich, 2001).

Entre las primeras aplicaciones de las RNA en las finanzas se encuentra el estudio realizado por White (1988) el cual emplea técnicas de aprendizaje y modelado de redes neuronales con el fin de buscar y decodificar las regularidades no lineales de los movimientos de precios de los activos. En este caso se centró en las rentabilidades diarias de las acciones ordinarias de IBM.

Si bien es cierto que el modelo empleado por White (1988) no resultó como se esperaba, se encontró otro tipo de evidencia como que: la búsqueda de información de los mercados eficientes con redes simples no será tan fácil; las redes simples pueden llegar a sobre ajustar de forma engañosa una serie de precios de activos considerando hasta 1000 observaciones; las redes neuronales simples son capaces de tener un comportamiento dinámico extremadamente rico.

En dicha investigación se fomenta el desarrollo de métodos computacionales eficientes con el fin de obtener redes maduras. De igual manera, sobresale el papel que debe desempeñar la inferencia estadística en el análisis del rendimiento de los modelos de redes neuronales, además de que, se sugieren nuevos problemas estadísticos (White, 1988).

Aunque el estudio de White (1988) fue limitado, resulta una forma de presentar los problemas relevantes en un entorno prácticamente sencillo presentando enfoques significativos. Con este estudio se vuelve prioridad la búsqueda de evidencia en contra de la hipótesis de los mercados eficientes, lo cual puede realizarse creando una red que permita insumos adicionales, así como conexiones recurrentes. Sin embargo, se tiene que considerar que cuantas más conexiones existan, habrá un mayor riesgo de sobreajuste. Otra de las limitaciones

encontradas es que los métodos de optimización que se emplearon fueron locales, siendo preferible un método global.

Por último, se señala que, aunque el método de mínimos cuadrados es apropiado para la prueba de hipótesis de los mercados eficientes, no significa que sea el método necesario que se deba usar si se persigue el interés de una construcción de una red enfocada a los aspectos comerciales del mercado. Por lo tanto, dichas redes deben ser evaluadas y capacitadas empleando las ganancias y pérdidas de las operaciones que se generaron (White, 1988).

Otro de los trabajos enfocados en las finanzas es el realizado por Kimoto et al. (1990) quienes analizan un sistema para predecir los tiempos de compra y venta de las acciones de la Bolsa de Valores de Tokio, basándose en las redes neuronales modulares ya que, los resultados obtenidos por el uso de modelos matemáticos no habían sido satisfactorios debido a que el momento para comprar y vender acciones no es lineal, por lo que lograron obtener excelentes resultados durante el ejercicio de simulación.

En dicha investigación, Kimoto et al. (1990) desarrollaron diversos algoritmos de aprendizaje así como métodos para el sistema de predicción del índice de precios de la Bolsa de Valores de Tokio (TOPIX), siendo este un promedio ponderado de los precios de mercado de todas las acciones que cotizan en la bolsa. Se encuentra ponderado por el número de acciones que cada empresa ha emitido y es utilizado de forma parecida al promedio Dow-Jones.

Kimoto et al. (1990) demostraron que el sistema de predicción tuvo excelentes resultados en el ejercicio de simulación. De igual manera, se lograron extraer reglas de fluctuación del precio de las acciones mediante un análisis de conglomerados, el cual a menudo es empleado para el análisis de la representación interna de una red neuronal jerárquica.

En el caso de Villada-Duque et al. (2016), estos predicen el comportamiento del precio del oro a través de un modelo basado en redes neuronales artificiales. Para la realización del trabajo, se obtuvo la serie de datos del oro mediante los

precios diarios fijados en Londres, que son ajustados dos veces al día: AM y PM. De igual manera, se descargaron los precios del petróleo de referencia para Estados Unidos, la serie de datos del índice del dólar americano (DXY) y la serie del índice Standard and Poor's 500 (S&P500). Para las variables de entrada del primer modelo se utilizaron los precios de cierre diarios PM en dólares americanos, y como la salida el precio a predecir para el día siguiente.

El mecanismo a través del cual se adaptan y modifican todos los parámetros de la red se conoce como la regla o algoritmo de aprendizaje. En el caso del perceptrón multicapa se trata de uno supervisado, ya que los parámetros se modifican para que la salida de la red sea lo más cercana posible a la deseada, tratando de minimizar la función error. El algoritmo utilizado fue del tipo Levenberg Marquardt del toolbox de redes neuronales de Matlab puesto que ha demostrado tener una convergencia más rápida (Villada-Duque et al., 2016).

La red empleada fue del tipo de propagación hacia adelante, dada su capacidad como aproximador universal. El proceso de aprendizaje o entrenamiento consistió en incrementar paso a paso dicha cantidad de neuronas hasta obtener la arquitectura más adecuada que se ajustara a la solución del problema, utilizando como criterio de selección el MAPE (Error absoluto promedio porcentual), y el RMSE (Raíz cuadrada del error promedio cuadrático), ya que son los más utilizados en los textos y artículos científicos dedicados a pronósticos (Villada-Duque et al., 2016).

Primeramente, se presenta un conjunto correspondiente al 62% de los datos seleccionados aleatoriamente y se modifican iterativamente los pesos hasta obtener un error mínimo deseado en los resultados. Otro conjunto aleatorio, con el 20% de los datos es utilizado para validación permitiendo la interrupción del entrenamiento cuando el error de validación empiece a incrementarse y así evitar el sobre entrenamiento. Por último, se prueba la estructura de red obtenida con el 18% de los datos restantes no incluidos en el proceso de entrenamiento (Villada-Duque et al., 2016).

Villada-Duque et al., (2016) eligieron un horizonte de pronóstico de 22 días hábiles, para lo cual se obtuvo una RNA que requería solamente la serie de datos

de los cinco meses anteriores. La serie de datos empleada para este proceso corresponde a los precios de cierre comprendidos entre el 30 de junio de 2014 y el 30 de diciembre de 2014. El mejor resultado que se obtuvo fue la configuración correspondiente a cinco neuronas en la capa oculta y un retardo de tiempo en la capa de entrada, en la cual se tienen bajos errores en el entrenamiento y en la predicción (fuera de la muestra).

Por otro parte, se involucró una segunda variable de entrada: el índice del dólar estadounidense DXY. Para el entrenamiento se utilizó otra estructura de red neuronal que incluía el índice Standard and Poor's 500 (S&P500) como tercera variable de entrada. Asimismo, se probó una cuarta estructura de red que incluía tres variables de entrada: los precios del oro, el índice DXY y la serie de precios del petróleo (Villada-Duque et al., 2016).

Aunado a lo anterior, se verificó la aplicabilidad del modelo propuesto en periodos de alto estrés financiero, escogiendo así la crisis hipotecaria de los Estados Unidos que empezó el 15 de septiembre de 2008. De esta forma, se utilizó la mejor estructura encontrada con las tres entradas de series de precios del oro y de los índices DXY y S&P500, usando la misma cantidad de datos de entrenamiento a partir de la fecha de inicio de esta crisis. Los resultados de la red arrojaron unos errores en el entrenamiento y en el pronóstico que siguen estando dentro del rango de errores mostrados para una variable de entrada, los cuales pueden considerarse como aceptables dada la alta volatilidad en el periodo escogido (Villada-Duque et al., 2016).

El modelo obtenido se convierte en una herramienta de utilidad para gobiernos, bancos centrales y operadores de corto plazo debido a que, entrega señales de precios que permiten planear compras y ventas del metal precioso con mejor precisión en comparación con otros modelos. Además, se obtuvieron mejores resultados al incluir otras variables explicativas que tienen en cuenta la aversión al riesgo. Se verificó el efecto positivo de incluir índices accionarios y también se observó que para el pronóstico satisfactorio del precio del oro basta con un rezago en la serie de tiempo (Villada-Duque et al., 2016).

Por otro lado, se encuentran Doru y Clipici (2017) quienes evalúan el riesgo financiero específicamente del sector del mercado de seguros, puesto que, en caso de que una compañía esté en bancarrota, se le paga una elevada cantidad de dinero por los fondos de garantía de seguros estatales, además de que, no es deseable estar interviniendo en el mercado, para no perturbarlo. Asimismo, está la preocupación de proteger a la sociedad y al sector asegurador de aquellas compañías con seguros insolventes ya que, al declararse en quiebra, el público reduce su confianza en ellos, por lo que es necesario predecir de la mejor manera las fallas que podrían tener las compañías de seguros.

En dicho estudio se tiene por objetivo proponer un mejorado algoritmo para estimar el riesgo de quiebra de las compañías de seguros búlgaras, con el fin de verificar su salud financiera, además de que, es un paso importante hacia una mayor transparencia de los balances de estas, en cumplimiento de las prácticas de supervisión de los mercados financieros en la Unión Europea y en la economía mundial (Doru y Clipici, 2017).

Para la estimación del riesgo de quiebra, Doru y Clipici (2017) aplicaron las redes neuronales artificiales, las cuales son una herramienta poderosa de modelado no lineal que permite manejar de mejor manera las relaciones entre los factores de riesgo y los atributos económico-financieros de la empresa, ya que estas pueden llegar a ser muy complejas o no lineales. Aunque esta herramienta se desarrolló originalmente para el reconocimiento y clasificación de patrones, también puede ser utilizada para predicciones. Por ende, en este trabajo se utilizó la arquitectura neuronal de tipo perceptrón multicapa la cual se encuentra basada en la regla de aprendizaje de retropropagación con fechas de entrada que son representadas por los valores de los indicadores de los estados financieros de las compañías de seguros.

De acuerdo con los resultados obtenidos se observa que, de las 31 compañías de seguros búlgaras, se han obtenido cuatro con niveles de bajo riesgo de quiebra, y todas las demás presentan un riesgo muy bajo. Dichos resultados

experimentales obtenidos proporcionan valiosa información a las empresas aseguradoras con el fin de evitar el riesgo de quiebra (Doru y Clipici, 2017).

En el caso de Meneses-Bautista y Alvarado (2017) utilizaron las redes neuronales entrenadas con el algoritmo de retropropagación con el fin de realizar un análisis y un pronóstico del comportamiento del tipo de cambio dólar estadounidense/peso mexicano (USD/MXN). Asimismo, buscaban evaluar la capacidad de predicción de las redes neuronales de retropropagación, realizando pruebas con diversas arquitecturas y conjunto de datos.

Para decidir qué variables integrarían los datos, Meneses-Bautista y Alvarado (2017) probaron diferentes combinaciones de series de tiempo como variables independientes. Al analizar el entrenamiento de las redes neuronales, puede calcularse un índice de error y asociarlo a cada conjunto de variables independientes, siendo el mejor conjunto para realizar el pronóstico aquel que produce el menor grado de error durante la validación. Como resultado, se eligió el dólar estadounidense, el euro, la libra esterlina y el yen japonés; todas con una periodicidad diaria, correspondiente al periodo entre el 2 de enero de 2015 y el 24 de marzo de 2017.

Posteriormente, se probaron cinco diferentes conjuntos de objetos de entrenamiento. El primero de ellos está formado por vectores con cuatro componentes, mientras que los demás incluyen vectores cuyos componentes son una combinación de tres de las cuatro divisas. La hipótesis inicial sobre los conjuntos de entrenamiento fue que, dada una red neuronal con una arquitectura determinada, los datos de las cuatro series permiten obtener un mejor pronóstico ya que, al descartar alguna de las series, se afecta el modelo calculado por la red (Meneses-Bautista y Alvarado, 2017).

De igual manera, se formaron tres subconjuntos de entrenamiento: con datos en un periodo semestral, anual y a dos años. Para la validación (pronóstico) se eligieron, series de tiempo con 30 muestras, a partir del día inmediato posterior al último objeto en cada serie de entrenamiento. Para emplear los datos de las series, se realizó un escalamiento, asignándole a cada muestra un valor real en el intervalo

[0;1]; únicamente el yen japonés primero fue sometido a un escalamiento por un factor de 100 (Meneses-Bautista y Alvarado, 2017).

Con el fin de encontrar una arquitectura que modelara apropiadamente la función de pronóstico obtenida por la red neuronal después del entrenamiento, Meneses-Bautista y Alvarado (2017) probaron en total doce arquitecturas para cada caso de pronóstico, con una o dos capas ocultas, y cada capa contó con dos, cuatro u ocho neuronas. Se empleó la función sigmoideal logística como función de activación en todas las neuronas de la red. Para cada patrón de entrenamiento, se calculó el error cuadrático medio (MSE), como estimador del error global de la red, para efectuar el ajuste de pesos por retropropagación. Se registró el grado de error obtenido por cada arquitectura, tanto en la regresión de entrenamiento, como en la de pronóstico.

Para las etapas de entrenamiento y de regresión, se presenta la Raíz del Error Cuadrático Medio (RMSE) promedio obtenido, por todas las arquitecturas y periodos de entrenamiento. Sin embargo, el error mínimo deseado para el entrenamiento no fue alcanzado por ninguna arquitectura. En la etapa de pronóstico fue posible identificar dos casos distintos: el pronóstico de 30 muestras, con un mayor grado de error, y el pronóstico de 1 muestra, con el menor grado de error (Meneses-Bautista y Alvarado, 2017).

Los experimentos realizados prueban la habilidad de las redes neuronales de retropropagación para modelar y reproducir adecuadamente la serie de tiempo que describe la variación del tipo de cambio USD/MXN. Asimismo, las redes neuronales calcularon predicciones de mejor calidad al día siguiente que en el caso de 30 muestras a futuro, lo que puede deberse al modelo empleado, enfocado a realizar la predicción al día siguiente. Por lo tanto, será necesario continuar con las investigaciones para determinar si una extensión en el modelo mejoraría la capacidad de predicción en plazos mayores, así como analizar el efecto del uso de un conjunto ampliado de variables independientes, que no se restrinja a tipos de cambio (Meneses-Bautista y Alvarado, 2017).

Por otra parte, se encuentran Singh et al. (2021) quienes exploran las diversas aplicaciones de las RNA en varias ramas de la contabilidad y finanzas, tales como la predicción del mercado de valores, la quiebra, entre otros. Dichos autores manifiestan que este método ha ganado popularidad en varias áreas de los negocios, gracias a su capacidad de aprendizaje y modelación de relaciones no lineales, además de que permiten la construcción de un sólido modelo que resulta confiable para la predicción de futuros eventos. De igual manera, las RNA son utilizadas en varios campos de las finanzas para el análisis de solvencia de clientes, de solicitud de préstamos, entre otros. No obstante, no existen muchos artículos de revisión que estén enfocados en la aplicación de los modelos de RNA en la contabilidad y las finanzas. De igual manera, mencionan que existe una gran demanda de artículos de revisión en los cuales combinan métodos tradicionales con métodos actuales.

En los últimos años se ha podido observar como la aplicación de las RNA se ha vuelto popular debido a su distintiva capacidad de detectar la relación entre conjuntos de datos diferentes. No obstante, la precisión de este método está determinada por diversos factores como la selección de las variables de entrada, la arquitectura para cierto problema y el patrón de entrenamiento, por mencionar algunos. Asimismo, varios estudios han concluido que las RNA proporcionan una mejor predicción comparada con los modelos tradicionales, aunque en ocasiones estas últimas superan a las RNA cuando se refiere a pronosticar (Singh et al., 2021).

En el área de las finanzas, las RNA han demostrado tener un buen potencial aplicadas en su mayoría a la predicción de quiebras, siendo un factor determinante en la evaluación del desempeño de una empresa; a la predicción del mercado de valores, ya que ayudan a predecir de manera más precisa y exacta el precio de las acciones. De igual manera, este método ha sido utilizado para pronosticar series de tiempo, predecir divisas, entre otros, aunque esta área de aplicación es relativamente nueva comparada con la predicción de quiebras y del mercado de valores (Singh et al., 2021).

En el caso de Beytollahi y Zeinali (2020), ellos buscan predecir el precio de los contratos de incumplimiento de crédito SWAP con el modelo de Black-Scholes-Merton y con los modelos de redes neuronales compuestos, también llamadas redes neuronales híbridas (RNH), en donde se incluye el Sistema de inferencia adaptativo neuro difuso (ANFIS), el autoregresivo de red neuronal con entradas exógenas (NNARX), AdaBoost y regresión de máquinas vectoriales de soporte (SVM). De igual manera, se compara el poder de predicción de estos algoritmos, los cuales destacan como los más prestigiosos e inteligentes en el área de finanzas. Su investigación se aplica a las empresas norteamericanas y europeas con calificación A, conocidas como las entidades de referencia para los swaps de incumplimiento crediticio, durante el periodo 2008 al 2015.

Si bien es cierto que los modelos financieros convencionales permiten predecir el precio de los derivados, como las opciones y los swaps, los cuales se basan en los datos existentes, las predicciones resultan limitadas. No obstante, los algoritmos de RNH, tienen un mayor potencial para realizar pronósticos de las tendencias, permitiendo predicciones precisas gracias a diversos factores como la aplicación de un proceso automático de aprendizaje, así como la capacidad de manejar una gran cantidad de cálculos. Por ende, este tipo de modelos estadísticos inteligentes, permiten incorporar mayor certeza de medición y predicción a los modelos financieros tradicionales, tales como el modelo de Merton, además de que ayuda a la reducción de la tasa de error de dichos modelos (Beytollahi y Zeinali, 2020).

De acuerdo con los resultados de Beytollahi y Zeinali (2020), los modelos de RNA y los modelos financieros convencionales como el modelo de Merton, proporcionan una alta precisión para predecir los precios de los derivados. De igual manera se observa que los algoritmos NNARX y ANFIS son aquellos que predicen de manera más certera, destacando el modelo el modelo ANFIS para predecir a un año, y el modelo NNARX para dos años.

Resumen

En este capítulo se revisaron artículos científicos, teniendo como común denominador el desempeño financiero, sus indicadores financieros y la aplicación de las RNA a las finanzas. Los estudios de desempeño financiero se desarrollaron en diversos sectores o industrias, como la de bienes de consumo, manufactura, sector privado de salud, microempresas, sector real, sector agrícola, de bebidas no alcohólicas, mercado eléctrico, o de seguros. En dichos estudios se ha observado la aplicación de distintos métodos analíticos, como los relacionados con las tendencias o modelos econométricos, además de que se implementan diversas razones financieras para su análisis correspondiente. De igual manera, se realiza una revisión de la literatura relacionada con las RNA y las finanzas, en la cual se ha observado el análisis, y en algunos casos el pronóstico del movimiento o comportamiento de precios de los activos, la compra y venta de acciones, o incluso el riesgo de quiebra en el sector de seguros.

Capítulo 3. Diseño de arquitecturas de RNA

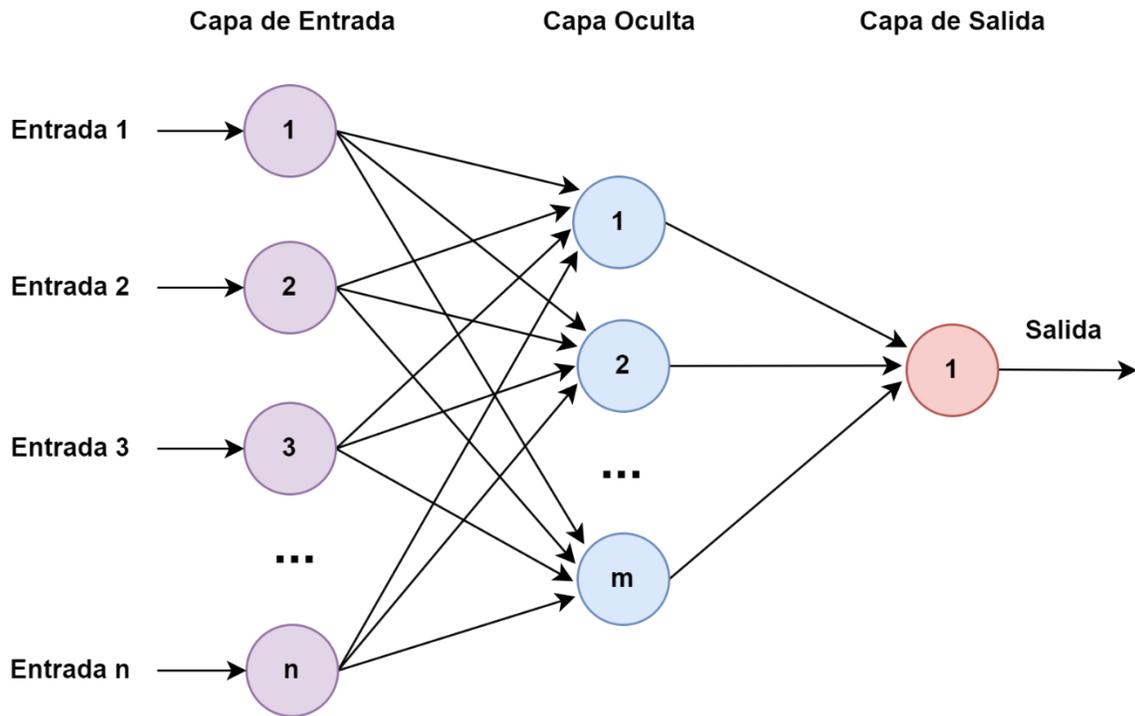
3.1 Técnica de análisis de datos

El supuesto de linealidad suele resultar poco realista en tiempos de eventos turbulentos o cuando se han dado cambios frecuentes, por lo que no es apropiado el uso de modelos estocásticos lineales. Por este motivo, las redes neuronales artificiales (RNA) son adecuadas para llevar a cabo un análisis en condiciones de suposiciones no cumplidas: no normalidad y no linealidad (Šestanovic y Arneric, 2021).

Se ha demostrado que los procedimientos de RNA resultan ser más precisos que las técnicas estadísticas convencionales cuando se utilizan grandes conjuntos de datos no paramétricos o no lineales. En el caso del COVID-19, éste generó un incremento en la incertidumbre de los mercados, influyendo esencialmente en la no linealidad y haciendo necesario un tratamiento atípico, para los que las RNA se han vuelto popularmente eficaces (Li et al., 2023).

EL perceptrón multicapa (MLP) es una de las redes más utilizadas, la cual consta de al menos tres capas de nodos siendo estas la capa de entrada, la capa oculta y la capa de salida. La capa de entrada es aquella que toma los datos que se analizarán como entrada y los ajusta para que la red neuronal pueda leerlos y así trabajar con ellos. Con relación a la capa oculta, la red puede tener varias capas, sin embargo, mientras más capas tenga se realizarán más análisis en los datos y por lo tanto los resultados serán más precisos. Esta capa ayuda a determinar la relación entre las distintas variables para así poder obtener un resultado. En el caso de la capa de salida, ésta proporciona la salida final de la red de acuerdo con los datos proporcionados como entrada y los resultados de la capa oculta (Kruse et al., 2016; Talwar, 2022).

Diagrama 1. Funcionamiento de una RNA



Fuente: Elaboración propia

Cada capa se encuentra representada por unidades computacionales denominadas neuronas. En cada uno de los nodos, exceptuando los de entrada, la neurona utiliza una función de activación la cual es no lineal. El MLP es una técnica de aprendizaje que emplea un enfoque de retropropagación para llevar a cabo el entrenamiento. De igual manera, el MLP se diferencia del perceptrón lineal, ya que presenta diversas capas y tiene una activación no lineal (Kruse et al., 2016).

De acuerdo con Kruse et al. (2016), las RNA resultan ser una herramienta para la toma de decisiones o para modelar datos estadísticos no lineales. Estas se pueden utilizar para modelar relaciones complejas entre las variables de entrada y de salida, o simplemente para descubrir ciertos patrones en los datos.

Para fines de esta investigación, la técnica que se empleará son las RNA puesto que proporcionan resultados más precisos en comparación con otros métodos más tradicionales, como lo son los modelos econométricos, ya sea de datos panel, de series de tiempo o de corte transversal. Algunos de los trabajos que

han implementado las redes neuronales son los de White (1988), Kimoto et al. (1990), Villada-Duque et al. (2016), Doru y Clipici (2017), Meneses-Bautista y Alvarado (2017), Díaz et al. (2019), Beytollahi y Zeinali (2020), Popa et al. (2021), y Singh et al. (2021).

Por lo tanto, se optó por utilizar el software estadístico SPSS, ya que proporciona herramientas de redes neuronales que facilitan el análisis e interpretación de resultados, lo que permitirá determinar los factores que impactan en el comportamiento del desempeño financiero de las empresas de estudio.

Para el estudio del sector de comercio electrónico, se emplearon los datos financieros proporcionados por la plataforma S&P Capital IQ, en donde se consideraron aquellas empresas que no solo se dedicarán a la comercialización de bienes sino también de servicios a través de medios electrónicos. Como un criterio de selección, se tomaron en cuenta aquellas empresas que tuvieran operaciones de por lo menos 5 años, tomando datos trimestrales a partir de 2017 hasta 2022. Como otro aspecto que se consideró es que las empresas tuvieran un grado similar de capitalización con el fin de evitar sesgos en la muestra, por lo que se omitieron aquellas empresas que tengan un alto o menor grado de capitalización.

Para la selección de las razones financieras, primeramente, se tomaron aquellas proporcionadas por la plataforma, considerando las categorías de rentabilidad, análisis de margen, rotación de activos, liquidez a corto plazo, así como solvencia a largo plazo. Posteriormente, se realizó un filtrado de cada una de las razones, descartando aquellas que no tuvieran datos suficientes ya que es necesario tener la mayor cantidad de datos para el diseño de la red.

De igual manera, como medida del desempeño financiero, se decidió utilizar el Rendimiento sobre activos (ROA), ya que, de acuerdo con la literatura, se ha observado que es una de las medidas más comunes para implementar en estos casos, por lo que se descartaron otras medidas de rentabilidad. Algunos autores que han implementado el ROA como medida de desempeño financiero son Salazar-Mosquera (2017), Vieira et al. (2019), y Xu et al. (2021).

3.2 Selección de variables para la arquitectura de las RNA

De acuerdo con los criterios de selección de variables antes establecidos, para el desarrollo de la red se consideraron los datos trimestrales de 14 empresas que cotizan en la bolsa de EE.UU., así como 18 razones financieras, las cuales se utilizarán como las variables independientes, siendo un total de 336 datos por cada razón financiera seleccionada. Estas permitirán medir el impacto en el comportamiento de la variable de desempeño financiero seleccionada, el ROA, la cual será la variable dependiente en el modelo para el periodo de 2017-2022.

Tabla 2. Empresas seleccionadas del sector de comercio electrónico

Clave	Empresa
TJX	The TJX Companies Inc
ULTA	Ulta Beauty Inc
EBAY	eBay Inc
BBY	Best Buy Co Inc
TSCO	Tractor Supply Company
DKS	DICK S Sporting Goods Inc
BIDU	Baidu Inc
MELI	MercadoLibre Inc
JD	JD com Inc
ETSY	Etsy Inc

WBD	Warner Bros Discovery Inc
LYV	Live Nation Entertainment Inc
WMG	Warner Music Group Corp
FWON.K	Formula One Group

Fuente: Elaboración propia con datos de S&P Capital IQ
(<https://www.capitaliq.com/>)

Tabla 3. Razones financieras seleccionadas

Término	Razón Financiera	Descripción	Categoría
Variable dependiente			
ROA	Rendimiento sobre activos	$\frac{EBIT * 0.625}{\frac{Activos\ totales(t) + Activos\ totales(t - 1)}{2}}$	Rentabilidad
Variables independientes			
RF1	Margen bruto	$\frac{Utilidad\ bruta}{Ingresos\ totales}$	Análisis de margen
RF2	Margen de gastos de venta, generales y administrativos	$\frac{Gastos\ generales\ de\ venta\ y\ administración}{Ingresos\ totales}$	
RF3	Margen EBITDA	$\frac{EBITDA}{Ingresos\ totales}$	
RF4	Margen EBITA	$\frac{EBITA}{Ingresos\ totales}$	
RF5	Margen EBIT	$\frac{EBIT}{Ingresos\ totales}$	

RF6	Margen de utilidad de las operaciones continuas	$\frac{\text{Utilidades de operaciones en curso}}{\text{Ingresos totales}}$		
RF7	Margen de utilidad neta	$\frac{\text{Utilidad neta}}{\text{Ingresos totales}}$		
RF8	Utilidad neta disponible para margen Común	$\frac{\text{Utilidad neta sobre ingresos ordinarios sin partidas adicionales}}{\text{Ingresos totales}}$		
RF9	Margen de utilidad neta normalizado	$\frac{\text{Utilidad neta normalizada}}{\text{Ingresos totales}}$		
RF10	Margen de flujo de caja libre apalancado	$\frac{\text{Flujo de caja libre apalancado}}{\text{Ingresos totales}}$		
RF11	Margen de flujo de caja libre no apalancado	$\frac{\text{Flujo de caja libre no apalancado}}{\text{Ingresos totales}}$		
RF12	Rotación total de activos	$\frac{\text{Ingresos totales}}{\frac{\text{Activos totales (t) + Activos totales (t - 1)}}{2}}$		Rotación de activos
RF13	Rotación de activos fijos	$\frac{\text{Ingresos totales}}{\frac{\text{Propiedad, planta y equipo netos(t) + Propiedad, planta y equipo netos (t - 1)}}{2}}$		
RF14	Razón de liquidez	$\frac{\text{Total activo circulante}}{\text{Total pasivo circulante}}$		Liquidez a corto plazo
RF15	Prueba del ácido	$\frac{\text{Total tesorería e inversiones a corto plazo + deudores}}{\text{Total pasivo corriente}}$		
RF16	Deuda total/Capital	$\frac{\text{Deuda total}}{\text{Capital total}}$	Solvencia a largo plazo	
RF17	Deuda a largo plazo/Capital	$\frac{\text{Deuda a largo plazo + Arrendamientos a largo plazo}}{\text{Capital total}}$		

RF18	Pasivos totales/Activos totales	$\frac{\text{Pasivos totales}}{\text{Activos totales}}$	
-------------	---------------------------------------	---	--

Fuente: Elaboración propia con datos de S&P Capital IQ
(<https://www.capitaliq.com/>)

Para el diseño de la red se empleó el modelo perceptrón multicapa (Multilayer Perceptron), utilizando la función de activación Sigmoide para las capas ocultas y de salida. El tipo de entrenamiento seleccionado fue el de lote, con el algoritmo de optimización de gradiente conjugado escalado.

Tabla 4. Características de la RNA

Modelo de la red	Multilayer Perceptron (MLP)
Función de activación de capa oculta	Sigmoide
Función de activación de capa de salida	Sigmoide
Tipo de entrenamiento	Lote
Algoritmo de optimización	Gradiente conjugado escalado

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

Para cada periodo de estudio se diseñaron 30 arquitecturas, realizando 10 con una y 20 con dos capas ocultas, variando el número de unidades en cada capa, y teniendo 18 variables de entrada (razones financieras) y una variable de salida (ROA), con el fin de realizar una comparación entre los resultados y así determinar la red que proporcionara el mejor ajuste de los datos (ver Anexo 1).

Resumen

En este capítulo se presenta la descripción del funcionamiento de una RNA, así como sus respectivas características. Además, se presentan los criterios de selección de las empresas dedicadas al comercio electrónico, para el periodo 2017-2022, tomando como base la información proporcionada por la plataforma S&P Capital IQ. De igual manera, se realiza un filtrado de las razones financieras que se utilizarían como variables de entrada y de salida, para las arquitecturas de RNA. Asimismo, se proporcionan las características técnicas de la RNA que se implementaría para el diseño de las arquitecturas.

Capítulo 4. Análisis de resultados

En esta investigación se decidió realizar tres tipos de análisis, uno general y dos más específicos, correspondientes a determinados periodos dentro del tiempo estudiado. El primer periodo abarca del 2017-2022, mientras que los otros dos van del 2017-2019 y del 2020-2022, respectivamente. Esto permitirá tener un panorama más amplio del comportamiento general de las empresas de comercio electrónico, así como su comportamiento antes y durante la pandemia, de manera que se podrá apreciar si hubo algún cambio en las razones financieras que impactan al desempeño financiero empresarial.

4.1 Periodo 2017-2022

De acuerdo con los resultados preliminares obtenidos de las diversas arquitecturas realizadas, para el periodo 2017-2022 se observa que, al igual que las empresas convencionales, las razones financieras impactan significativamente en el desempeño financiero de las empresas de comercio electrónico.

En la tabla 5 se presentan las 5 arquitecturas que demostraron tener un mayor ajuste a los datos entre todas las pruebas realizadas. En dichas arquitecturas se observa un patrón similar en ciertas variables que impactan en el desempeño financiero de las empresas de comercio electrónico, como es el caso de las razones 5 y 12.

Tabla 5. Arquitecturas con los mejores ajustes de datos. Periodo 2017-2022

Variables	18-4-1	18-8-1	18-9-1	18-4-4-1	18-4-5-1
RF1	5.27%	4.32%	1.96%	4.95%	8.93%
RF2	4.75%	4.91%	2.95%	5.40%	10.05%
RF3	4.10%	6.12%	3.93%	9.28%	8.67%

RF4	8.22%	7.49%	8.83%	8.81%	10.27%
RF5	17.22%	17.75%	21.39%	15.62%	17.46%
RF6	5.57%	5.55%	4.74%	5.17%	3.13%
RF7	6.03%	7.67%	8.88%	3.49%	1.46%
RF8	2.03%	3.95%	3.74%	6.91%	2.66%
RF9	8.56%	5.64%	5.39%	4.18%	2.66%
RF10	3.69%	3.90%	4.16%	6.83%	1.77%
RF11	4.24%	4.57%	2.84%	6.33%	3.58%
RF12	12.50%	10.01%	11.76%	10.16%	11.13%
RF13	2.79%	1.89%	1.68%	1.14%	1.70%
RF14	3.92%	3.60%	5.70%	2.65%	2.25%
RF15	3.40%	3.85%	3.25%	2.91%	1.68%
RF16	1.42%	1.37%	3.44%	1.00%	5.87%
RF17	3.47%	3.27%	3.49%	1.95%	3.19%
RF18	2.82%	4.15%	1.88%	3.22%	3.53%
Porcentaje de ajuste (R^2)	94.97%	93.65%	94.71%	95.17%	93.45%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

La arquitectura que demostró un mejor ajuste de los datos fue 18-4-4-1, usando el modelo de Perceptrón Multicapa. El ajuste del modelo se determinó a través del cálculo del R^2 , donde el valor máximo obtenido de las diversas arquitecturas realizadas fue del 95.17%, lo que nos indica que, en el mejor de los casos, las razones financieras seleccionadas impactan en un 95.17% el comportamiento del desempeño financiero (ROA). En la tabla 6 se presenta la información de la RNA seleccionada, con las características técnicas empleadas para su diseño.

Tabla 6. Información de la RNA. Periodo 2017-2022

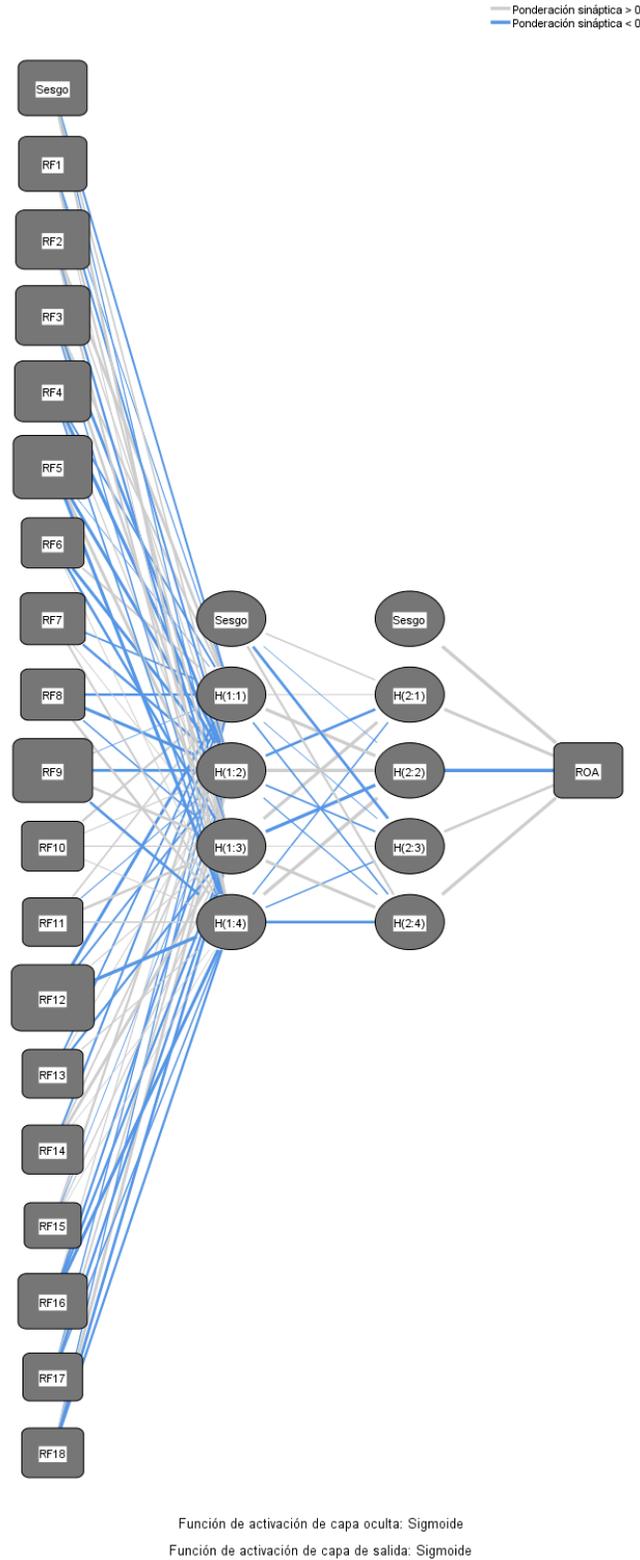
Resumen	
Núm. de RNA	29
Nombre de la red	Multilayer Perceptron (MLP) 18-4-4-1
Número de datos	336
Desempeño de la red	95.17%
Tipo de entrenamiento	Lote
Algoritmo de optimización	Gradiente conjugado escalado
Capa de entrada	
Número de unidades	18
Capas ocultas	
Número de capas ocultas	2

Número de unidades en la capa oculta 1	4
Número de unidades en la capa oculta 2	4
Función de activación	Sigmoide
Capa de salida	
Número de unidades	1
Función de activación	Sigmoide

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

El diagrama 2 muestra la conceptualización esquemática de la RNA MLP 18-4-4-1, con las 18 razones financieras de entrada, aplicando 2 capas ocultas, con 4 unidades en cada capa, y teniendo como variable de salida la medida de desempeño financiero seleccionada, el ROA.

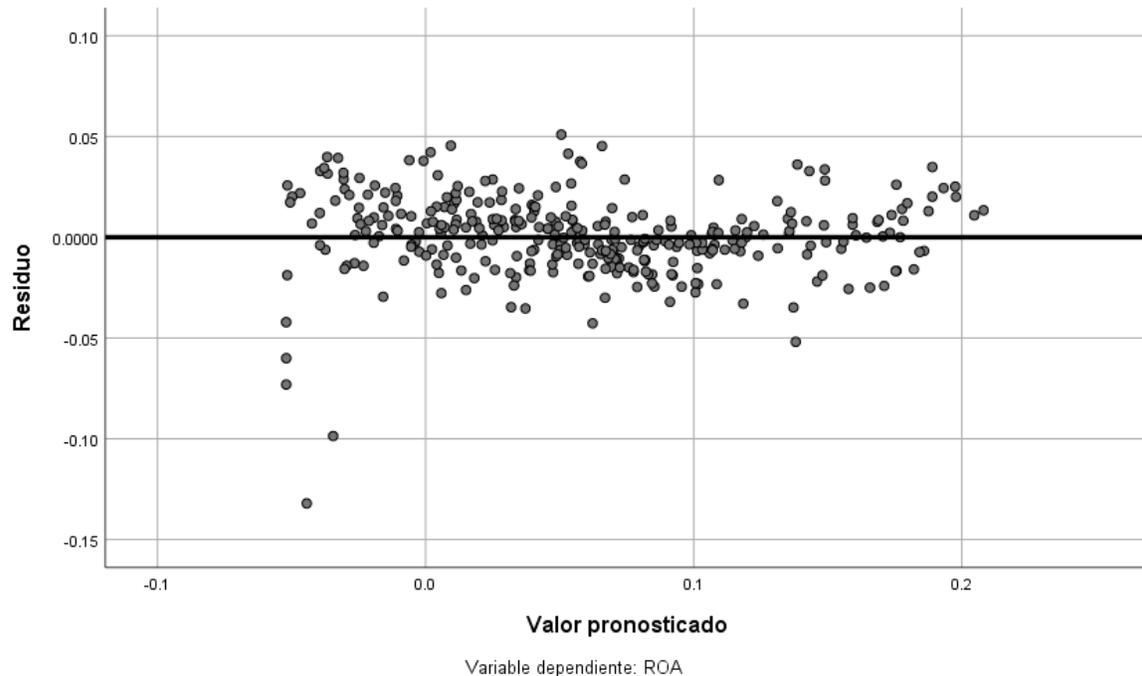
Diagrama 2. RNA MLP 18-4-4-1. Periodo 2017-2022



Fuente: Resultado de la arquitectura diseñada en SPSS

De igual manera, en la gráfica 1 se puede observar que los residuos presentan, en su mayoría, un comportamiento homogéneo, por lo que no se presenta un patrón anormal que sea significativo en la distribución de los mismos. Por lo tanto, al no haber una distribución atípica en los residuos, los valores pronosticados presentan un buen ajuste de los datos.

Gráfica 1. Residuos de RNA MLP 18-4-4-1. Periodo 2017-2022



Fuente: Resultado de la arquitectura diseñada en SPSS

Los resultados han proporcionado aquellas variables que impactan en el desempeño financiero de las empresas del sector de comercio electrónico. En este caso se observa que, las variables con mayor impacto en el ROA son las siguientes:

- RF5 Margen EBIT, con un impacto del 15.62%
- RF12 Rotación total de activos, con un impacto del 10.16%
- RF3 Margen EBITDA, con un impacto del 9.28%

Tabla 7. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2022

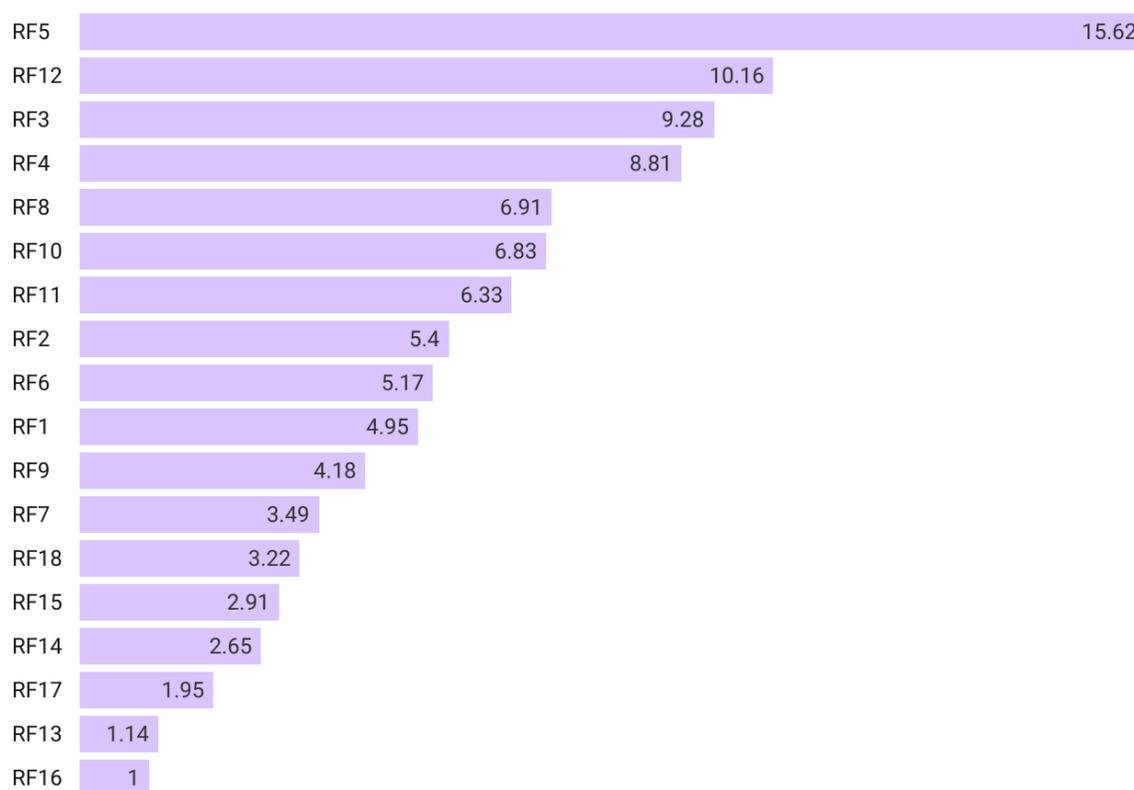
Variables	Orden de importancia	Porcentaje de impacto
RF5	1	15.62%
RF12	2	10.16%
RF3	3	9.28%
RF4	4	8.81%
RF8	5	6.91%
RF10	6	6.83%
RF11	7	6.33%
RF2	8	5.40%
RF6	9	5.17%
RF1	10	4.95%
RF9	11	4.18%
RF7	12	3.49%
RF18	13	3.22%
RF15	14	2.91%

RF14	15	2.65%
RF17	16	1.95%
RF13	17	1.14%
RF16	18	1.00%

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

Como se observa en la gráfica 2, la RF5 Margen EBIT es la variable que presenta el mayor impacto en el desempeño financiero, lo cual nos indica que, dejando a un lado la parte tributaria, los beneficios que el grupo de empresas analizado ha generado, derivado de su actividad económica, han sido significativos. En segundo lugar, se encuentra la RF12 Rotación total de activos, por lo que la gestión de los activos de la empresa influye en los resultados obtenidos del desempeño empresarial. Por último, se encuentra la RF3 Margen EBITDA, lo que indica que la rentabilidad generada en las operaciones comerciales impacta el comportamiento financiero de la empresa.

Gráfica 2. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2022



Fuente: Elaboración propia con Datawrapper (<https://www.datawrapper.de/>) a partir de la arquitectura diseñada en SPSS

4.2 Periodo 2017-2019

Para el periodo 2017-2019, entendido como el periodo antes de que se declarara la pandemia por el COVID-19, se observa que, las razones financieras seleccionadas tienen un impacto en el desempeño financiero de las empresas de comercio electrónico.

En la tabla 8 se observan las 5 arquitecturas que presentaron un mayor ajuste a los datos entre todas las pruebas realizadas. En dichas arquitecturas se aprecia un patrón similar en ciertas variables que impactan en el desempeño financiero de las empresas seleccionadas, como es el caso de las razones 4, 5 y 12.

Tabla 8. Arquitecturas con los mejores ajustes de datos. Periodo 2017-2019

Variables	18-7-1	18-8-1	18-7-5-1	18-9-3-1	18-10-4-1
RF1	1.19%	4.71%	2.49%	1.19%	2.95%
RF2	1.73%	1.54%	0.81%	1.47%	2.30%
RF3	2.75%	6.64%	4.83%	7.04%	4.54%
RF4	13.97%	14.08%	11.29%	7.14%	13.03%
RF5	10.22%	12.64%	12.94%	12.44%	16.14%
RF6	10.58%	1.94%	2.08%	4.21%	2.57%
RF7	4.55%	6.46%	7.90%	2.79%	5.10%
RF8	7.14%	3.96%	2.55%	2.63%	3.49%
RF9	3.32%	4.71%	9.74%	12.97%	5.81%
RF10	1.92%	4.93%	2.54%	5.66%	5.47%
RF11	1.04%	3.86%	5.95%	5.71%	5.93%
RF12	12.49%	14.88%	16.19%	13.41%	14.10%
RF13	4.36%	2.42%	3.05%	2.25%	1.44%
RF14	3.36%	2.51%	0.60%	5.15%	1.25%
RF15	2.15%	3.95%	2.55%	3.93%	1.16%

RF16	5.50%	3.97%	5.88%	5.52%	6.56%
RF17	9.53%	5.08%	6.52%	2.90%	6.69%
RF18	4.22%	1.72%	2.10%	3.60%	1.45%
Porcentaje de ajuste (R^2)	96.87%	96.96%	97.90%	97.51%	97.02%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

La arquitectura que demostró un mejor ajuste de los datos fue 18-7-5-1, usando el modelo de Perceptrón Multicapa. El ajuste del modelo se determinó a través del cálculo del R^2 , donde el valor máximo obtenido de las diversas arquitecturas realizadas fue del 97.90%, lo que nos indica que, en el mejor de los casos, las razones financieras seleccionadas impactan en un 97.90% el comportamiento del desempeño financiero (ROA). En la tabla 9 se presenta la información de la RNA seleccionada, con las características técnicas empleadas para su diseño.

Tabla 9. Información de la RNA. Periodo 2017-2019

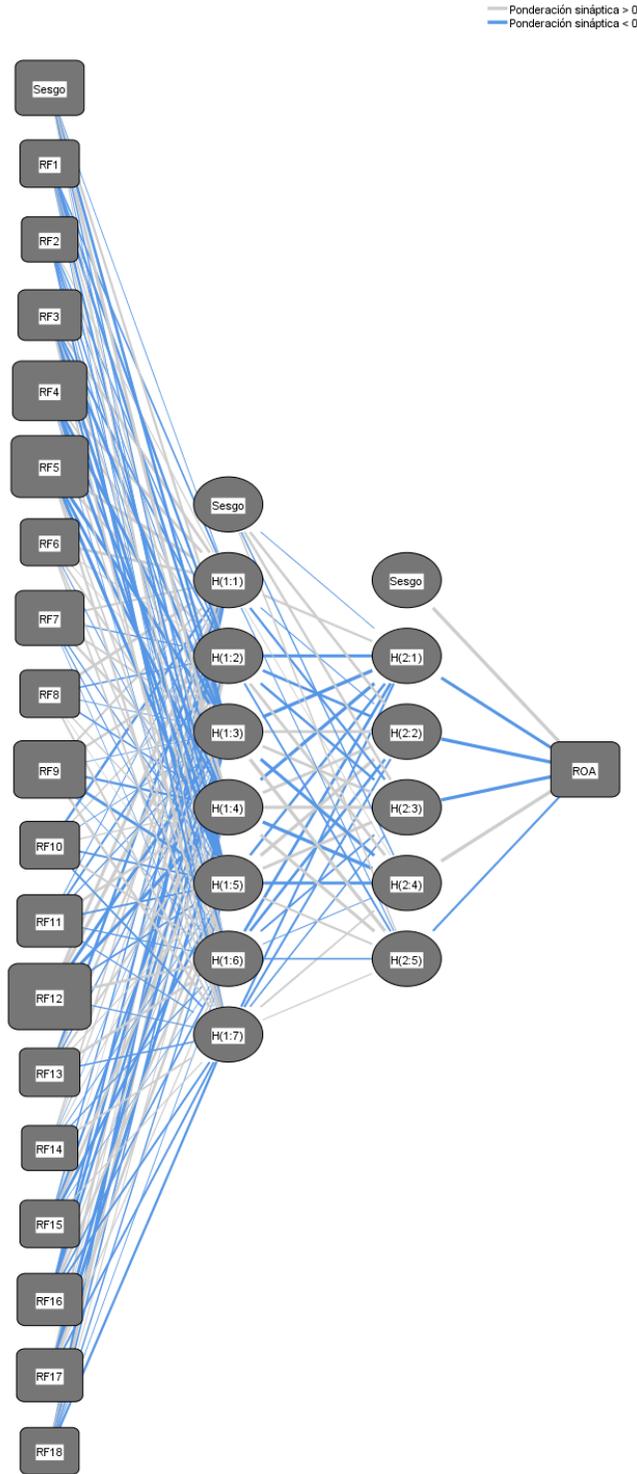
Resumen	
Núm. de RNA	15
Nombre de la red	Multilayer Perceptron (MLP) 18-7-5-1
Número de datos	168
Desempeño de la red	97.90%
Tipo de entrenamiento	Lote
Algoritmo de optimización	Gradiente conjugado escalado

Capa de entrada	
Número de unidades	18
Capas ocultas	
Número de capas ocultas	2
Número de unidades en la capa oculta 1	7
Número de unidades en la capa oculta 2	5
Función de activación	Sigmoide
Capa de salida	
Número de unidades	1
Función de activación	Sigmoide

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

El diagrama 3 muestra la conceptualización esquemática de la RNA MLP 18-7-5-1, con las 18 razones financieras de entrada, aplicando 2 capas ocultas, con 7 y 5 unidades respectivamente, y teniendo como variable de salida la medida de desempeño financiero, el ROA.

Diagrama 3. RNA MLP 18-7-5-1. Periodo 2017-2019

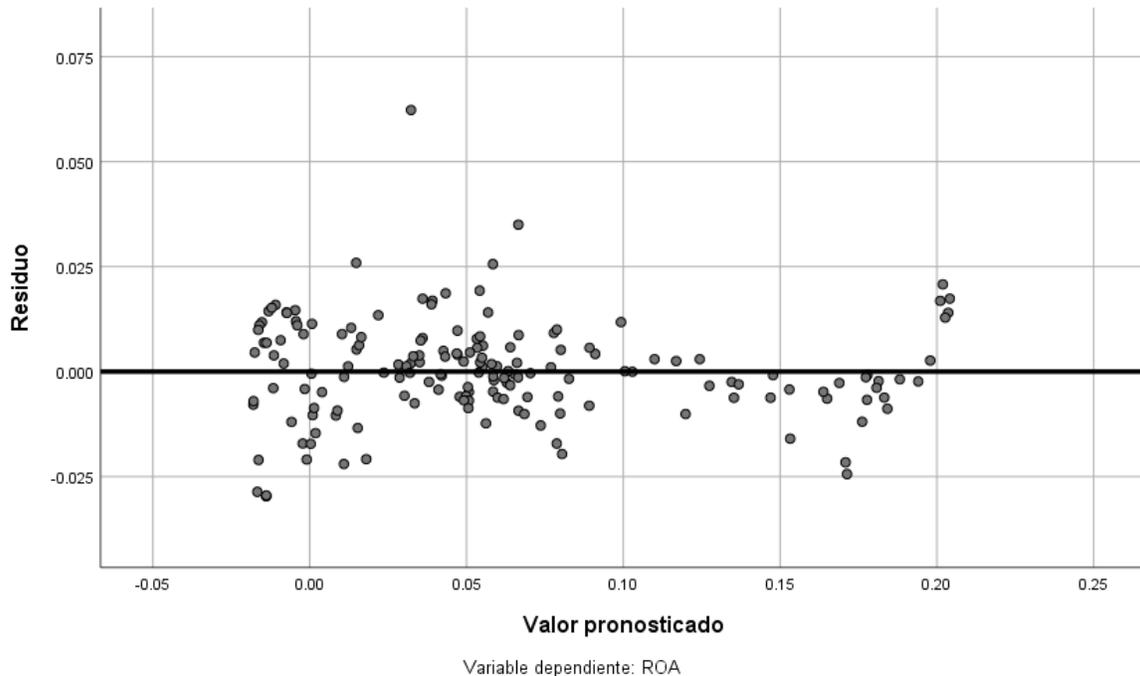


Función de activación de capa oculta: Sigmoide
Función de activación de capa de salida: Sigmoide

Fuente: Resultado de la arquitectura diseñada en SPSS

Asimismo, en la gráfica 3 se logra apreciar que los residuos presentan, en su mayoría, un comportamiento homogéneo, por lo que no se presenta un patrón anormal que sea significativo en la distribución de estos. Por lo consiguiente, al no haber una distribución que resulte atípica en los residuos, se asume que los valores pronosticados tienen un buen ajuste de los datos.

Gráfica 3. Residuos de RNA MLP 18-7-5-1. Periodo 2017-2019



Fuente: Resultado de la arquitectura diseñada en SPSS

Los resultados han proporcionado aquellas variables que impactan en el desempeño financiero de las empresas del sector de comercio electrónico. En este caso se observa que, las variables con mayor impacto en el ROA son las siguientes:

- RF12 Rotación total de activos, con un impacto del 16.19%
- RF5 Margen EBIT, con un impacto del 12.94%
- RF4 Margen EBITA, con un impacto del 11.29%

Tabla 10. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2019

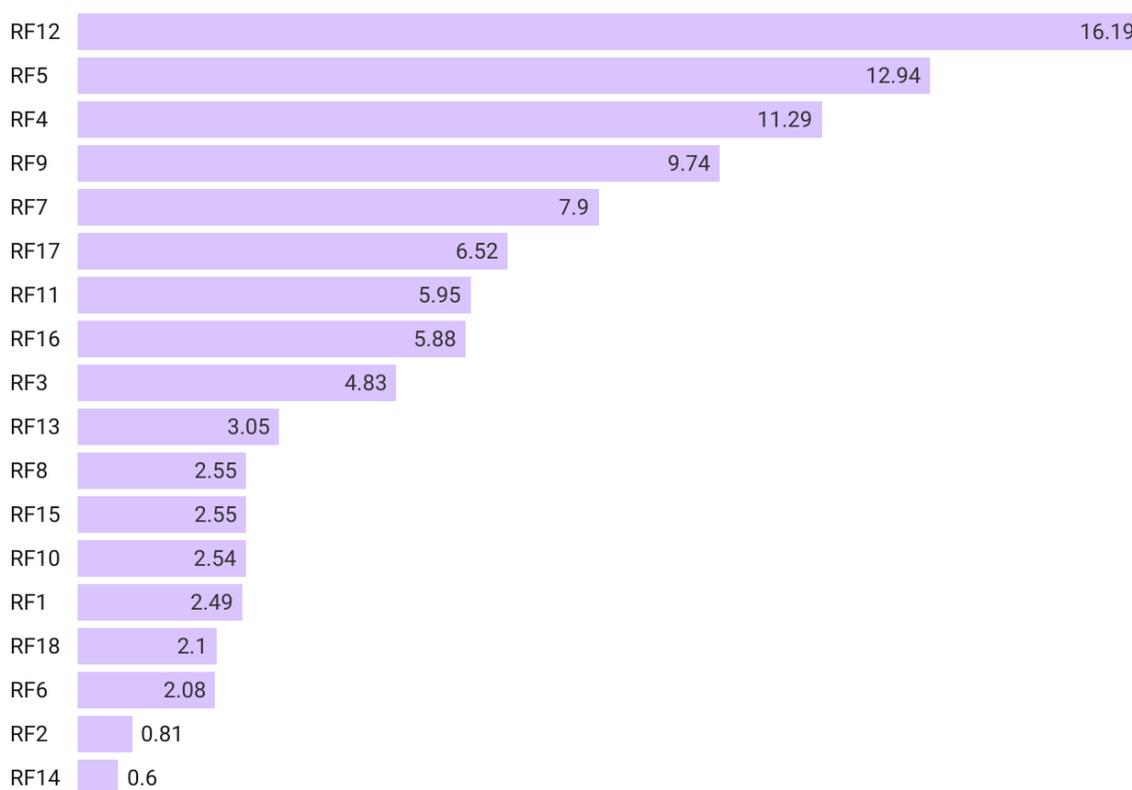
Variables	Orden de importancia	Porcentaje de impacto
RF12	1	16.19%
RF5	2	12.94%
RF4	3	11.29%
RF9	4	9.74%
RF7	5	7.90%
RF17	6	6.52%
RF11	7	5.95%
RF16	8	5.88%
RF3	9	4.83%
RF13	10	3.05%
RF8	11	2.55%
RF15	12	2.55%
RF10	13	2.54%
RF1	14	2.49%

RF18	15	2.10%
RF6	16	2.08%
RF2	17	0.81%
RF14	18	0.60%

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

En la gráfica 4 se observa que RF12 Rotación total de activos ocupa el primer lugar en cuanto el impacto en el desempeño financiero del grupo de empresas de comercio electrónico, de manera que, la administración de los activos resulta importante. Posteriormente se encuentra la RF5 Margen EBIT, lo que indica una influencia de las ganancias que se han obtenido, antes de los respectivos pagos tributarios y de intereses. En tercer lugar, se encuentra la RF4 Margen EBITA, lo cual nos indica un impacto proveniente de las ganancias generadas, sin considerar los impuestos, los intereses y las amortizaciones.

Gráfica 4. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2017-2019



Fuente: Elaboración propia con Datawrapper (<https://www.datawrapper.de/>) a partir de la arquitectura diseñada en SPSS

4.3 Periodo 2020-2022

Durante el periodo 2020-2022, siendo el periodo en el cual se desarrolló y evolucionó la pandemia por el COVID-19, se puede observar que, las razones financieras impactan de manera significativa en el desempeño financiero de las empresas que se dedican al comercio electrónico.

En la tabla 11 se presentan las 5 arquitecturas que demostraron tener un mayor ajuste a los datos entre todas las pruebas realizadas. En casi todas las arquitecturas se destaca cierto patrón con relación a la razón financiera 4 y 5, las cuales presentan un impacto significativo en el desempeño financiero de las empresas seleccionadas.

Tabla 11. Arquitecturas con los mejores ajustes de datos. Periodo 2020-2022

Variables	18-4-1	18-7-1	18-7-2-1	18-7-3-1	18-9-5-1
RF1	4.21%	5.53%	4.98%	6.37%	7.13%
RF2	7.91%	9.17%	9.85%	5.91%	8.47%
RF3	13.07%	5.41%	10.00%	9.70%	3.16%
RF4	10.08%	5.13%	10.08%	15.14%	12.19%
RF5	12.33%	14.43%	11.47%	14.28%	11.79%
RF6	3.14%	3.11%	4.13%	5.39%	4.92%
RF7	2.40%	6.75%	3.19%	3.93%	4.09%
RF8	5.98%	2.13%	3.05%	2.34%	2.31%
RF9	8.48%	9.84%	6.07%	11.04%	7.76%
RF10	2.30%	1.89%	3.61%	1.71%	3.75%
RF11	1.54%	2.31%	2.97%	1.60%	2.17%
RF12	9.79%	9.02%	11.25%	8.63%	10.28%
RF13	2.61%	2.85%	3.05%	3.03%	2.39%
RF14	5.25%	4.94%	4.20%	2.46%	6.75%
RF15	3.56%	8.38%	4.59%	2.16%	5.06%

RF16	3.45%	3.11%	1.94%	1.11%	2.19%
RF17	1.33%	2.09%	2.12%	2.64%	3.52%
RF18	2.59%	3.93%	3.46%	2.56%	2.07%
Porcentaje de ajuste (R^2)	96.25%	93.94%	94.94%	98.00%	93.96%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

La arquitectura que demostró un mejor ajuste de los datos fue 18-7-3-1, usando el modelo de Perceptrón Multicapa. El ajuste del modelo se determinó a través del cálculo del R^2 , donde el valor máximo obtenido de las diversas arquitecturas realizadas fue del 98%, lo que nos indica que, en el mejor de los casos, las razones financieras seleccionadas impactan en un 98% el comportamiento del desempeño financiero (ROA). En la tabla 12 se muestra la información de la RNA seleccionada, con las características técnicas utilizadas para su diseño.

Tabla 12. Información de la RNA. Periodo 2020-2022

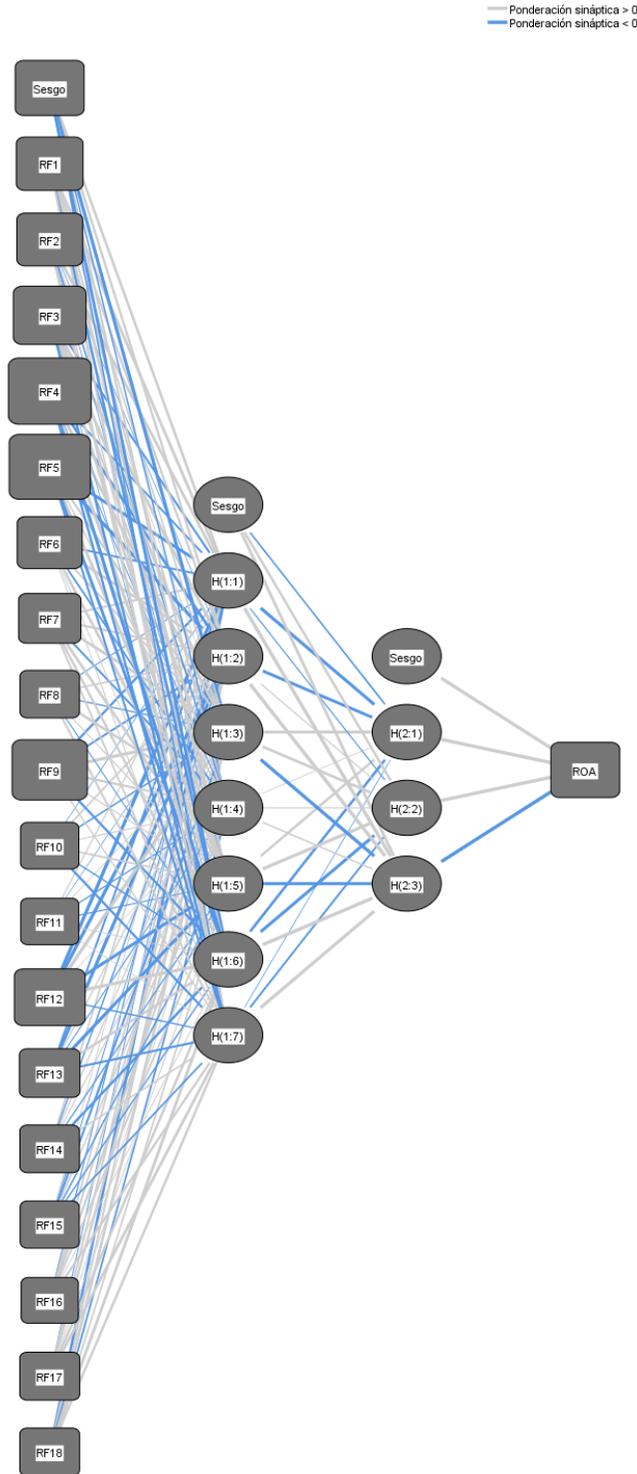
Resumen	
Núm. de RNA	18
Nombre de la red	Multilayer Perceptron (MLP) 18-7-3-1
Número de datos	168
Desempeño de la red	98%
Tipo de entrenamiento	Lote
Algoritmo de optimización	Gradiente conjugado escalado
Capa de entrada	

Número de unidades	18
Capas ocultas	
Número de capas ocultas	2
Número de unidades en la capa oculta 1	7
Número de unidades en la capa oculta 2	3
Función de activación	Sigmoide
Capa de salida	
Número de unidades	1
Función de activación	Sigmoide

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

El diagrama 4 muestra la conceptualización esquemática de la RNA MLP 18-7-3-1, con las 18 razones financieras de entrada, aplicando 2 capas ocultas, con 7 y 3 unidades respectivamente, teniendo como variable de salida el desempeño financiero de las empresas, medido a través del ROA.

Diagrama 4. RNA MLP 18-7-3-1. Periodo 2020-2022

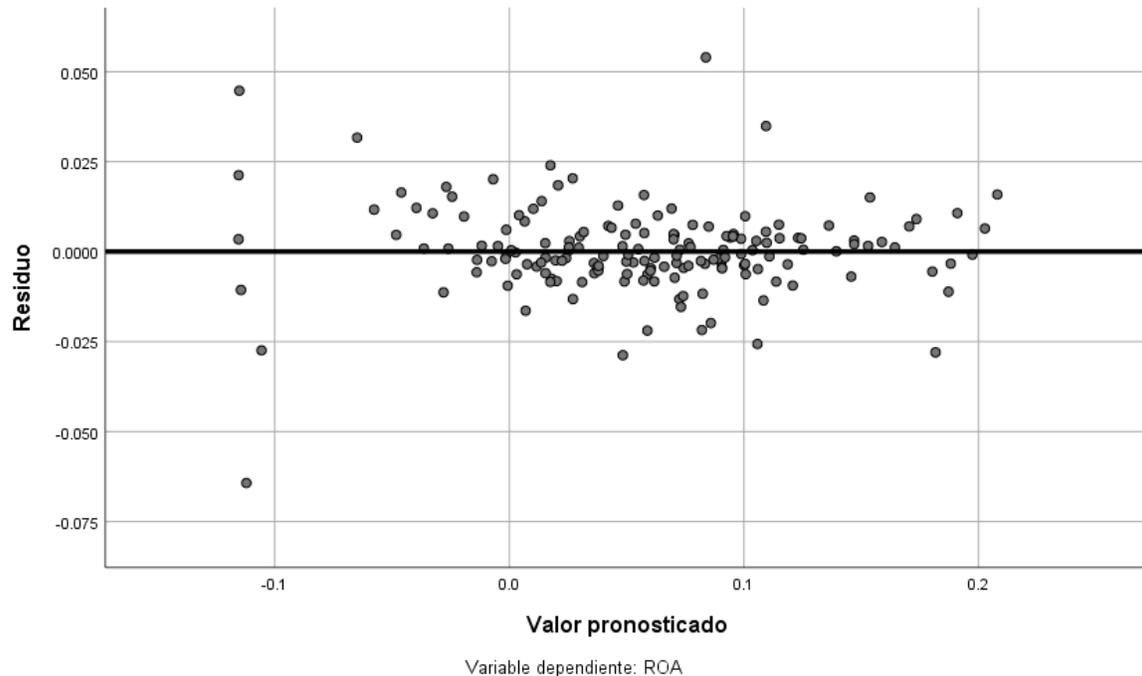


Función de activación de capa oculta: Sigmoide
Función de activación de capa de salida: Sigmoide

Fuente: Resultado de la arquitectura diseñada en SPSS

Asimismo, en la gráfica 5 se observa que, en la mayoría de los casos, los residuos presentan un comportamiento homogéneo, de manera que, no se presenta un patrón anormal que resulte significativo en la distribución de los mismos. Es por ello que, al no haber una distribución atípica en los residuos, los valores pronosticados presentan un buen ajuste de los datos.

Gráfica 5. Residuos de RNA MLP 18-7-3-1. Periodo 2020-2022



Fuente: Resultado de la arquitectura diseñada en SPSS

Los resultados han proporcionado aquellas variables que impactan en el desempeño financiero de las empresas del sector de comercio electrónico. En este caso se observa que, las variables con mayor impacto en el ROA son las siguientes:

- RF4 Margen EBITA, con un impacto del 15.14%
- RF5 Margen EBIT, con un impacto del 14.28%
- RF9 Margen de utilidad neta normalizado, con un impacto del 11.04%

Tabla 13. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2020-2022

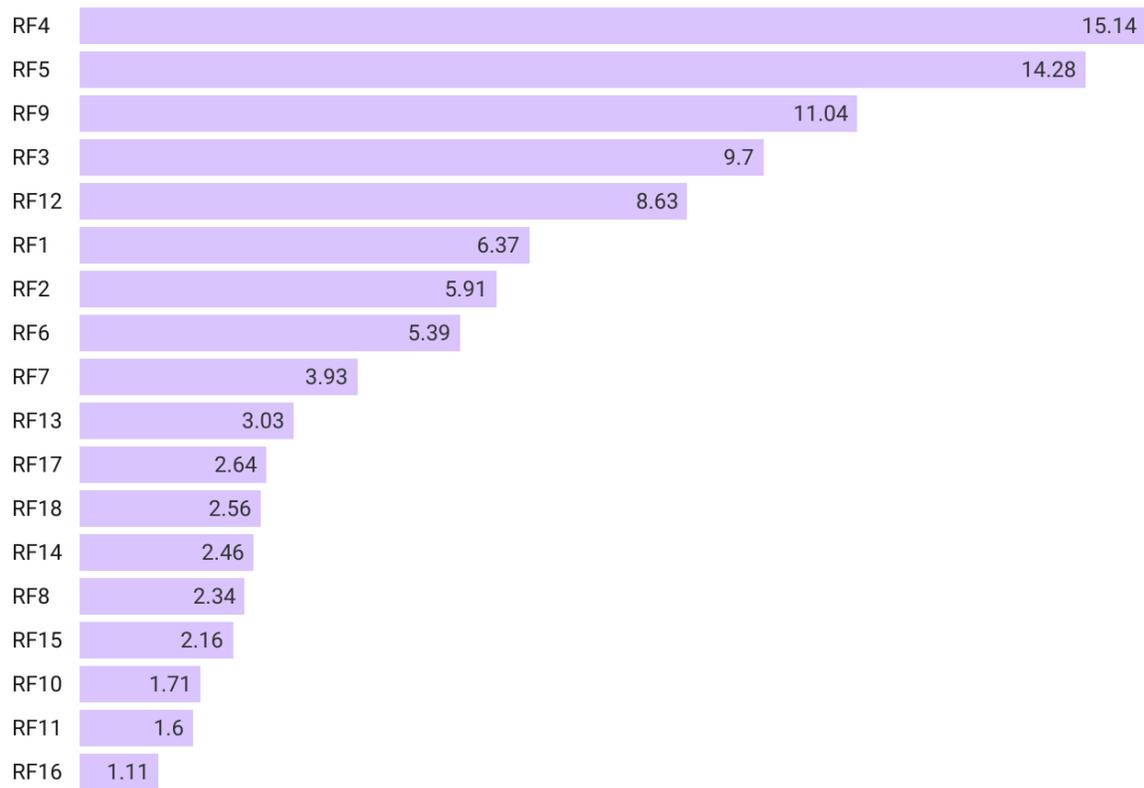
Variables	Orden de importancia	Porcentaje de impacto
RF4	1	15.14%
RF5	2	14.28%
RF9	3	11.04%
RF3	4	9.70%
RF12	5	8.63%
RF1	6	6.37%
RF2	7	5.91%
RF6	8	5.39%
RF7	9	3.93%
RF13	10	3.03%
RF17	11	2.64%
RF18	12	2.56%
RF14	13	2.46%
RF8	14	2.34%

RF15	15	2.16%
RF10	16	1.71%
RF11	17	1.60%
RF16	18	1.11%

Fuente: Elaboración propia a partir de la arquitectura diseñada en SPSS

Como se aprecia en la gráfica 6, la RF4 Margen EBITA es la variable que más impacta en el desempeño financiero, de manera que, sin tomar en cuenta los intereses, los impuestos y las amortizaciones, los beneficios que el grupo de empresas analizado ha generado, han sido significativos. Seguidamente se encuentra la RF5 Margen EBIT, lo que significa que hay una influencia de las ganancias que se han obtenido, antes de intereses e impuestos, en el desempeño empresarial. Finalmente, la RF9 Margen de utilidad neta normalizado nos indica que, los beneficios generados luego de los costos de producción, presenta un impacto en el comportamiento financiero de la empresa.

Gráfica 6. Importancia de las razones financieras que impactan el comportamiento del desempeño financiero. Periodo 2020-2022



Fuente: Elaboración propia con Datawrapper (<https://www.datawrapper.de/>) a partir de la arquitectura diseñada en SPSS

De manera general, en la tabla 14 se aprecian los cambios que han tenido las razones financieras que han impactado al desempeño financiero de las empresas de comercio electrónico durante los periodos estudiados, en donde se puede apreciar ligeras variaciones en el grado de impacto de estas.

Tabla 14. Resumen arquitecturas con los mejores ajustes de datos

Periodo	2017-2022	2017-2019	2020-2022
Arquitectura	18-4-4-1	18-7-5-1	18-7-3-1
RF1	4.95%	2.49%	6.37%
RF2	5.40%	0.81%	5.91%
RF3	9.28%	4.83%	9.70%
RF4	8.81%	11.29%	15.14%
RF5	15.62%	12.94%	14.28%
RF6	5.17%	2.08%	5.39%
RF7	3.49%	7.90%	3.93%
RF8	6.91%	2.55%	2.34%
RF9	4.18%	9.74%	11.04%
RF10	6.83%	2.54%	1.71%
RF11	6.33%	5.95%	1.60%
RF12	10.16%	16.19%	8.63%
RF13	1.14%	3.05%	3.03%

RF14	2.65%	0.60%	2.46%
RF15	2.91%	2.55%	2.16%
RF16	1.00%	5.88%	1.11%
RF17	1.95%	6.52%	2.64%
RF18	3.22%	2.10%	2.56%
Porcentaje de ajuste (R^2)	95.17%	97.90%	98.00%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

Resumen

En este capítulo se presentan los resultados obtenidos para los periodos 2017-2022, 2017-2019 y 2020-2022, los cuales permiten tener un panorama general y dos más específicos del comportamiento de las empresas dedicadas al comercio electrónico. Se abordaron las 5 arquitecturas de RNA que demostraron tener el mayor ajuste de datos entre todas pruebas realizadas, poniendo especial énfasis en aquella que tuvo el ajuste más alto, medido a través del R^2 . Igualmente, se incluyen las características de la arquitectura seleccionada, así como aquellas razones financieras que presentaron un mayor impacto en el desempeño financiero en cada periodo señalado.

Capítulo 5. Conclusiones y recomendaciones

La literatura ha demostrado que, en diversos sectores, como de alimentos, bebidas, sector agrícola o financiero, el desempeño financiero, medido a través de algunas variables como el ROA o el ROE, es explicado en gran parte por una serie de razones financieras tales como liquidez o solvencia, por mencionar las más comunes. Por ende, se esperaría que el comportamiento de las empresas orientadas al comercio electrónico sea igual o similar a aquellas empresas que no necesariamente manejan la dinámica de los medios electrónicos, ya que como toda empresa, lo importante es maximizar los beneficios. De igual manera, se esperaría que el uso de las redes neuronales ayude a obtener resultados más eficientes con respecto a otros métodos no lineales, puesto que en muchos casos los datos no necesariamente responden al supuesto de normalidad.

Algunas investigaciones que han utilizado el ROA como una aproximación de desempeño financiero empresarial son: Salazar-Mosquera (2017), enfocado en el sector manufacturero; Vieira et al. (2019), quienes estudiaron las empresas portuguesas; y Xu et al. (2021), quienes se enfocaron en las empresas agrícolas de china.

Salazar-Mosquera (2017) seleccionó una muestra de 140 sociedades manufactureras en Ecuador, empleando el análisis de correlación para su estudio. Utilizó las razones financieras de liquidez-corriente, prueba ácida, endeudamiento sobre el activo, endeudamiento sobre el patrimonio, endeudamiento sobre el activo fijo neto, apalancamiento operativo, apalancamiento financiero, rotación de cartera, rotación del activo fijo, rotación de ventas, rentabilidad neta sobre el activo, margen bruto en ventas y rentabilidad sobre el patrimonio.

Por otra parte, Vieira et al. (2019) analizaron los factores determinantes del desempeño de las empresas en Portugal, utilizando un modelo de regresión de datos panel. Para ello, emplearon los indicadores de liquidez, apalancamiento financiero, el tamaño de la empresa, el PIB, el sentimiento de los inversores, la existencia de propiedad gerencial, así como el tamaño de la junta.

En el caso de Xu et al. (2021), estos se centraron en examinar el papel que tiene la estructura de capital en el desempeño financiero de las empresas agrícolas en China, específicamente aquellas que cotizaban en la bolsa entre el 2013 y el 2019, haciendo uso de un modelo de datos panel. En dicho análisis, emplearon el ratio de la deuda total, de la deuda a corto plazo así como de la deuda a largo plazo. Asimismo, incorporaron variables de control como el tamaño de la empresa, la tasa de crecimiento de las ventas, la tangibilidad, la liquidez, y la tasa de crecimiento del producto interno bruto, y una variable ficticia, el año.

En el caso de esta investigación se analizaron las empresas dedicadas al comercio electrónico, entendiéndolo como aquellas dedicadas a la comercialización no sólo de bienes sino también de servicios, a través de medios electrónicos. De igual forma se consideró el periodo del 2017 al 2022, tomando datos trimestrales y se incluyeron razones financieras pertenecientes a las categorías de análisis de margen, rotación de activos, liquidez a corto plazo, así como de solvencia a largo plazo.

Adicionalmente, se estableció la siguiente hipótesis: el comportamiento financiero de las empresas vistas en el periodo podrá diferir según las razones financieras del grupo de análisis de margen, rotación de activos, liquidez a corto plazo, y solvencia a largo plazo.

Para el desarrollo de este trabajo se decidió utilizar la técnica de redes neuronales artificiales ya que, de acuerdo a diversos autores como White (1988), Kimoto et al. (1990), Villada-Duque et al. (2016), Doru y Clipici (2017), Meneses-Bautista y Alvarado (2017), Díaz et al. (2019), Beytollahi y Zeinali (2020), Popa et al. (2021), y Singh et al. (2021), esta técnica ha demostrado tener capacidad de obtener resultados más precisos en comparación con otros métodos utilizados, que generalmente son apropiados para el análisis financiero, pero que no necesariamente significa que sean lo que se requieren para el estudio.

De acuerdo con lo anterior, se ha encontrado evidencia de que ciertas razones financieras impactan el desempeño financiero de las empresas de comercio electrónico, ya que la dinámica manejada en este sector no es tan

diferente a las empresas convencionales, debido a que lo único que cambia o varía son los medios en los cuales se comercializan los bienes o servicios. Asimismo, los resultados arrojaron altos índices de ajuste con respecto a los datos originales; esto significa que la técnica empleada permite analizar eficientemente el impacto de ciertos factores en el comportamiento de la variable en estudio, considerando un periodo atípico debido al COVID-19.

Para realizar el análisis de comportamiento del desempeño financiero de las empresas de comercio electrónico (ROA) se realizaron diversas arquitecturas de redes neuronales que permitieran el estudio de los periodos: 2017-2022, 2017-2019, y 2020-2022. A grandes rasgos, la arquitectura desarrollada en el primer periodo permitió tener un panorama general de las variables que impactaron el desempeño empresarial. Sin embargo, al analizar los periodos que abarcan antes (2017-2019) y durante la pandemia (2020-2022) del COVID-19, se pudo tener una perspectiva más amplia del comportamiento financiero de las empresas.

De manera general, se comprueba la hipótesis planteada, ya que si hubo una variación en el comportamiento del desempeño financiero en cada periodo. Si bien es cierto que algunas de las razones financieras que más impactaron en el desempeño de las empresas se mantuvieron, se observan ligeros cambios en el grado de influencia de estas. No obstante, las razones más relevantes únicamente pertenecen a los grupos de análisis de margen y rotación de activos.

Durante el periodo de 2017-2022 se observa que la variable que tiene un impacto mayor en el desempeño financiero es la RF5 Margen EBIT con un impacto del 15.62%, seguida por la RF 12 Rotación total de activos con el 10.16% y la RF3 Margen EBITDA con el 9.28%. Esto nos indica que, los beneficios generados, dejando un lado los impuestos, la gestión de los activos, así como la rentabilidad generada en las operaciones comerciales, han tenido efectos relevantes en el desempeño financiero del grupo de empresas.

Por otro lado, durante el periodo del 2017-2019, se observa cambios en las razones que impactan al desempeño, donde la RF12 Rotación total de activos es la que tiene efectos más significativos, con un impacto del 16.19%; seguidamente se

encuentra la RF5 Margen EBIT, con el 12.94% y la RF4 Margen EBITA, con un impacto del 11.29%. Por lo tanto, durante este periodo se vuelve más relevante la administración de los activos, las ganancias obtenidas antes de los pagos tributarios e intereses, así como las ganancias antes de impuestos, intereses y amortizaciones.

Durante el periodo 2020-2022, la RF4 Margen EBITA representa la variable con mayor impacto en el desempeño con el 15.14%; en segundo lugar se encuentra la RF5 Margen EBIT, con un impacto del 14.28% y finalmente la RF9 Margen de utilidad neta normalizado, con el 11.04%. De acuerdo con esto se aprecia que, los beneficios generados, sin considerar los intereses, impuestos y amortizaciones, y luego de los costos de producción, han tenido efectos significativos en el desempeño financiero del grupo de empresas.

A grandes rasgos se puede observar que, en el caso de la RF5 Margen EBIT, ésta se mantuvo presente en todos los periodos y únicamente hubo cambios en el porcentaje de impacto en el ROA. La RF12 Rotación total de activos únicamente tuvo presencia en los primeros dos periodos (2017-2022 y 2017-2019), con algunos cambios que no fueron tan significativos. De igual manera, la RF4 Margen EBITA presentó un impacto en los periodos de 2017-2019 y 2020-2022, variando el grado de influencia en los mismos. Con respecto a las variables RF3 Margen EBITDA y RF9 Margen de utilidad neta normalizado, éstas solo impactaron el desempeño financiero en los periodos de 2017-2022 y 2020-2022, respectivamente.

Estos resultados difieren de los encontrados por Salazar-Mosquera (2017), Vieira et al. (2019) y Xu et al. (2021). Salazar-Mosquera (2017) observó que el factor determinante fue la rotación de ventas, teniendo una fuerte correlación para los años 2014 y 2015. De igual manera, se observa una correlación inversa de la liquidez con la rentabilidad durante el 2014, aunque en el 2015 se aprecia un efecto directo, derivado de una disminución de los indicadores de endeudamiento ocasionada por una recesión económica.

Por otro lado, Vieira et al. (2019) pudieron determinar que las variables que son específicas de la empresas no son determinantes del desempeño, sino más bien las variables macroeconómicas son aquellas que tienen efectos significativos,

incluyendo el sentimiento del inversor y la propiedad privada de la información privilegiada.

En el caso de Xu et al. (2021), sus resultados demostraron que los índices de deuda total y a corto plazo son los que tienen efectos negativos sobre el desempeño financiero, mientras que el índice de deuda a largo plazo no afecta significativamente. Asimismo, la estructura de capital en el desempeño de las empresas de propiedad privada es mayor que en las estatales. En cuanto a la deuda total se observa que el impacto negativo es mayor en aquellas empresas ubicadas en las regiones centrales y occidentales en comparación de las que se encuentran en la región oriental.

Por lo tanto, se puede observar que, aunque en los estudios mencionados se empleó el ROA como medida del desempeño financiero, las razones financieras utilizadas variaban conforme a lo que se buscaba probar, incluso aunque se utilizara el mismo método, como lo fue en el caso de Vieira et al. (2019) y Xu et al. (2021), quienes utilizaron modelos de regresión de datos panel. Asimismo, se observa que no siempre el desempeño se ve afectado por algún indicador financiero, sino más bien influyen otros factores macroeconómicos, como lo son las recesiones económicas, la ubicación en la que se encuentran las empresas, o incluso aquellos relacionados con la conducta de los inversores.

De igual forma, otros aspectos que se pueden considerar que pueden influenciar los resultados obtenidos son el tamaño de la muestra, la técnica o el método empleado, el tamaño de las empresas, o incluso la actividad comercial a la que se dediquen ya que algunas pueden depender en específico de ciertas áreas o funciones para poder operar, las cuales pueden resultar poco importantes o nada relevantes en el desempeño financiero de otras empresas.

En el caso del sector de comercio electrónico, se observa que algunas empresas no solo comercializan a través de medio electrónicos, sino que también mantienen tiendas físicas para tener un mayor alcance. Una característica de este sector es que es estacional, es decir que, una gran parte de los ingresos y ganancias que se generan dependen del periodo en el que se encuentren, siendo el cuarto

trimestre uno de los más importantes debido a la alta demanda de compras relacionadas con la temporada navideña.

Aquellas empresas orientadas a la venta de bienes les resulta importante cuidar los niveles de inventario ya que de esa manera podrán satisfacer la demanda de los consumidores. Otro aspecto fundamental para la correcta operación de las empresas de comercio electrónico, son los canales de distribución y de suministro, ya que una interrupción o escasez en estos podría tener efectos adversos en los resultados financieros. De igual forma, hay una alta dependencia de los sistemas tecnológicos, debido a que es un factor clave en los procesos comerciales, por lo que algún daño o falla en estos podría interrumpir la funcionalidad de la empresa.

La pandemia del COVID-19 provocó cambios repentinos en la operación de las empresas, exponiéndolas a una serie de riesgos relacionados con las ventas, la demanda de clientes, la rentabilidad, así como aquellos relacionados con la deuda. Esto se debe a que hubo una reducción significativa en las visitas de los clientes a las tiendas físicas, además de que su gasto se vio alterado. Sin embargo, la demanda de algunos productos no necesarios se vio disminuida mientras que la compra de otros bienes o servicios aumentó de forma considerable, por lo que no todas las empresas tuvieron la capacidad de satisfacer dicha demanda, provocando la escasez y por ende el incremento en los precios por parte de los proveedores. Todo esto afectó de forma negativa los ingresos y la rentabilidad de las empresas, sobre todo a aquellas que dependían mayormente de las ventas realizadas en las tiendas físicas y no en línea.

Como resultado de la pandemia, el comportamiento de los consumidores cambió, lo que se vio reflejado en un incremento en las compras en línea, haciendo notoria la necesidad de mejorar los canales de distribución y asegurar las cadenas de suministro, por lo que las empresas adoptaron estrategias para garantizar la funcionalidad de las mismas.

Otra de las medidas que tomaron las empresas fue el incremento en los precios o tarifas de los bienes y servicios, en comparación con los que se tenían antes de la pandemia. Asimismo, se optó por invertir en la tecnología puesto que su

uso ya se vio como una necesidad permanente y no como algo opcional, lo que permitiría asegurar la satisfacción del cliente.

Los hallazgos de esta investigación hacen evidente la importancia de cuidar la generación de beneficios como resultado de la actividad económica de las empresas. De igual manera, hay que tener en cuenta la manera en cómo se gestionan los activos de la empresa, con el fin de tener una mayor productividad y que se garantice el buen funcionamiento de la compañía. Otro aspecto por considerar es el control eficiente de los costos de producción, administración y distribución ya que esto puede llegar a impactar en la rentabilidad de la empresa.

Futuras líneas de investigación

Otras posibles investigaciones relacionadas con el estudio del desempeño financiero pueden ir orientadas a utilizar una muestra más grande de estudio, seleccionar algún otro grupo de empresas pertenecientes al mismo sector que puedan tener un mayor o menor grado de capitalización, o ampliar el periodo de estudio. De igual manera, se pueden incorporar otras razones financieras o variables macroeconómicas para el respectivo estudio, incorporar variables cualitativas, como aspectos relacionados con la conducta del inversor, o incluso implementar otras técnicas o métodos estadísticos para realizar el análisis correspondiente. Por lo tanto, se espera que estos resultados se vean reflejados sobre la variable seleccionada para medir el desempeño financiero empresarial.

Limitaciones

Durante el desarrollo de esta investigación se presentaron algunas limitaciones relacionadas con la recolección de datos y determinación de la muestra. Debido a que la técnica que se utilizaría era RNA, se procuró utilizar la mayor cantidad de datos que fueran posibles para el periodo de estudio determinado. Inicialmente se seleccionó un grupo grande de empresas, sin embargo, no todas contaban con las mismas razones financieras o había una falta de datos. Por lo tanto, se optó por seleccionar otro grupo de empresas que se dedicaran al comercio electrónico, cuidando que tengan la mayor cantidad de razones entre ellas para así

seleccionar las empresas de estudio. Asimismo, se verificó que dichas empresas tuvieran un grado de capitalización similar, con el fin de evitar sesgos entre las empresas, ya que algunas cuentan con un grado demasiado alto o bajo, lo que implicaría sesgos al momento de realizar las arquitecturas de RNA.

Adendum

Actualmente en el sector analizado se presenta, según la prensa económica y la opinión de los expertos, lo siguiente:

Mercado Libre demuestra un notable fortalecimiento aún después de la pandemia, demostrando la triplicación de sus utilidades netas en el primer trimestre de 2023, los cuales se vieron impulsados por el crecimiento en todo su ecosistema de negocios y un incremento de sus ingresos (Reforma, 2023b). La posición de Mercado Libre ha mejorado considerablemente ya que ha regresado a donde estaba a principios de 2022, y su valor se ha duplicado, comparado con el periodo antes de la pandemia (Reforma, 2023a).

Como en muchas partes del mundo, la pandemia provocó un aceleramiento del crecimiento del comercio electrónico. Sin embargo, posterior a la pandemia, algunas empresas de comercio electrónico, como es el caso de Amazon, Shopify, Coupang y Grab han ido en declive, provocando el despido de miles de trabajadores, así como otras afectaciones financieras. No obstante, Mercado Libre ha podido aprovechar dichas circunstancias, volviéndola una fortaleza para mejorar su posición dentro el sector (Reforma, 2023a).

Derivado de lo anterior, se tomó la decisión de realizar inversiones tanto en México como Brasil, para ampliar la red logística, aumentando su capacidad de transporte, así como la penetración de sus servicios financieros. Lo anterior permitirá llegar a una mayor cantidad de usuarios, dando servicio a más ciudades, y aumentar la colocación de crédito como parte de sus servicios de Mercado Pago (El Economista, 2023; Reforma, 2023c).

Referencias bibliográficas

- Acevedo, E., Serna, A., y Serna, E. (2017). Principios y características de las redes neuronales artificiales. En E. Serna (Ed.), *Desarrollo e Innovación en Ingeniería* (Segunda ed., págs. 173-182). Instituto Antioqueño de Investigación.
- Altman, E. (1968). Financial ratios, discriminant analysis and prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.
- Beytollahi, A., y Zeinali, H. (2020). Comparing Prediction Power of Artificial Neural Networks Compound Models in Predicting Credit Default Swap Prices through Black–Scholes–Merton Model. *Iranian Journal of Management Studies (IJMS)*, 13(1), 63-93.
- Bouza-Herrera, C. (2018). *Modelos de regresión y sus aplicaciones*. La Habana: GRASHUMEDIA.
- Castañeda, W., Vega, F., y Polo, B. (2022). Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial. *Universidad, Ciencia y Tecnología*, 27(118), 51-56.
- Cegarra, A. (2018). Ambiente Externo y Desempeño Financiero en el Sector Privado de la Salud. *Revista Scientific*, 3(7). Obtenido de http://www.indteca.com/ojs/index.php/Revista_Scientific/article/view/174
- Díaz, H., Sosa, M., y Cabello, M. (2019). Financial performance and administrative practices in Mexican microenterprises: An analysis with artificial neural networks. *Contaduría y Administración*, 64(3), 1-16.
- Doru, C., y Clipici, E. (2017). AN IMPROVED ALGORITHM BASED ON THE NEURAL ARCHITECTURES FOR ESTIMATING THE RISK OF BANKRUPTCY OF THE BULGARIAN INSURANCE COMPANIES. *Proceedings of the International Multidisciplinary Scientific GeoConference SGEM*, 17, 85-94.

- El Economista. (2023). MercadoLibre invertirá 3,600 millones de dólares en Brasil este año. *El Economista*. Obtenido de <https://www.eleconomista.com.mx/empresas/MercadoLibre-invertira-3600-millones-de-dolares-en-Brasil-este-ano-20230316-0024.html>
- García, J. (2018). La regulación del comercio: retos ante el cambio tecnológico. *Revista del Instituto de Ciencias Jurídicas de Puebla*, 12(41), 43-70. Obtenido de <http://www.scielo.org.mx/pdf/rius/v12n41/1870-2147-rius-12-41-43.pdf>
- Gitman, L., y Zutter, C. (2012). *Principios de administración financiera*. México: Pearson Educación.
- Gujarati, D., y Porter, D. (2010). *Econometría* (Quinta ed.). México: McGraw-Hill.
- Haque, S., y Afzal, M. (2017). An Appraisal of Financial Performance of the Fast Moving Consumer Goods (FMCG) Industry in India. *PACIFIC BUSINESS REVIEW INTERNATIONAL*, 10(6), 61-66.
- Kimoto, T., Asakawa, K., Yoda, M., y Takeoka, M. (1990). Stock market prediction system with modular neural networks. *IJCNN International Joint Conference on Neural Networks*, 1-6.
- Kruse, R., Borgelt, C., Braune, C., Mostaghim, S., y Steinbrecher, M. (2016). *Computational Intelligence. A Methodical Introduction* (Segunda ed.). Londres: Springer.
- Li, X., Sengupta, T., Si Mohammed, K., y Jamaani, F. (2023). Forecasting the lithium mineral resources prices in China: Evidence with Facebook Prophet (Fb-P) and Artificial Neural Networks (ANN) methods. *Resources Policy*, 82, 1-9.
- López-Aguado, M., y Gutiérrez-Provecho, L. (2019). Cómo realizar e interpretar un análisis factorial exploratorio utilizando SPSS. *Revista d'Innovació i Recerca en Educació*, 12(2), 1-14.
- Marcillo-Cedeño, C., Aguilar-Guijarro, C., y Gutiérrez-Jaramillo, N. (2021). Análisis financiero: una herramienta clave para la toma de decisiones de gerencia. *Digital Publisher CEIT*, 6(3), 87-106.

- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Argentina: Universidad Tecnológica Nacional.
- Mejia, R. (2019). *Predicción del Desempeño Financiero de las Empresas del Sector de Productos de Consumo Frecuente que Cotiza en la Bolsa Mexicana de Valores*. Tesis doctoral, Universidad Nacional Autónoma de México.
- Meneses-Bautista, F. D., y Alvarado, M. (2017). Pronóstico del tipo de cambio USD/MXN con redes neuronales de retropropagación. *Research in Computing Science*, 139, 97-110.
- Ngamjan, P., y Buranasiri, J. (2020). An Investigation of the Factors Influencing the Financial Performance of Agricultural Cooperatives in Thailand. *SOCIAL SCIENCES & HUMANITIES*.
- Neves, M., Henriques, C., y Vilas, J. (2021). Financial performance assessment of electricity companies: evidence from Portugal. *Operational Research*, 21.
- Padilla-Ospina, A., Rivera-Godoy, J., y Ospina-Holguín, J. (2019). Desempeño financiero de las empresas más innovadoras del sector real de Colombia. *Entramado*, 15(1), 78-97.
- Pokharel, K., Regmi, M., Featherstone, A., y Archer, D. (2019). Examining the financial performance of agricultural cooperatives in the USA. *Agricultural Finance Review*, 79(2), 271-282.
- Popa, C., Popa, D.N., Bogdan, V., y Simut, R. (2021). COMPOSITE FINANCIAL PERFORMANCE INDEX PREDICTION - A NEURAL NETWORKS APPROACH. *JOURNAL OF BUSINESS ECONOMICS AND MANAGEMENT*, 22(2), 277-296
- Rivera, J., Torres, A., y García, J. (2020). ANÁLISIS DEL DESEMPEÑO FINANCIERO DE LA INDUSTRIA DE BEBIDAS NO ALCOHÓLICAS EN COLOMBIA. *Economía Coyuntural, Revista de Temas de Coyuntura y Perspectivas*, 5(4), 123-159.

- Reforma. (2023a). ¿Por qué MercadoLibre sigue creciendo? *Reforma*. Obtenido de https://www.reforma.com/aplicacioneslibre/preacceso/articulo/default.aspx?__rval=1&urlredirect=https://www.reforma.com/por-que-mercadolibre-sigue-creciendo/ar2599914?referer=-7d616165662f3a3a6262623b727a7a7279703b767a783a--
- Reforma. (2023b). Ganancias de Mercado Libre se disparan en primer trimestre. *Reforma*. Obtenido de https://www.reforma.com/aplicacioneslibre/preacceso/articulo/default.aspx?__rval=1&urlredirect=/ganancias-de-mercado-libre-se-disparan-en-primer-trimestre/ar2598645
- Reforma. (2023c). Mercado Libre invertirá 1,600 mdd en México en 2023. *Reforma*. Obtenido de https://www.reforma.com/aplicacioneslibre/preacceso/articulo/default.aspx?__rval=1&urlredirect=/mercado-libre-invertira-1-600-mdd-en-mexico-en-2023/ar2570822
- Rodríguez, J., y Rodríguez, E. (2016). Estadística para Administración y economía (Segunda ed.). México: Grupo Editorial Patria.
- Salazar-Mosquera, G. (2017). Factores determinantes del desempeño financiero en el sector manufacturero en la República del Ecuador. *Panorama Económico*, 25(2), 243-254.
- Šestanovic, T., y Arneric, J. (2021). Neural network structure identification in inflation forecasting. *Journal of Forecasting* (40), 62-79.
- Sharma, A., Jadi, D., y Ward, D. (2021). Analysing the determinants of financial performance for UK insurance companies using financial strength ratings information. *Economic Change and Restructuring*, 54.
- Singh, N. P., Som, B. K., Komalavalli, C., y Goel, H. (2021). A Meta-Analysis of the Application of Artificial Neural Networks in Accounting and Finance. *SCMS Journal of Indian Management*, 18(1), 5-21.

- Stewart, B. (2000). *En Busca del Valor*. Barcelona: Ediciones Gestión.
- Talwar, N. (2022). Modeling Non-Linear Associations between Independent and Dependent Variables Using Artificial Neural Networks in Python. *OORJA - International Journal of Management & IT*, 20(1), 11-22.
- United Nations Conference on Trade and Development. (2021). *Estimates of global e-commerce 2019 and preliminary assessment of Covid-19 impact on online retail 2020*.
- Vieira, E., Neves, M., y Dias, A. (2019). Determinants of Portuguese firms' financial performance: panel data evidence. *International Journal of Productivity and Performance Management*, 68(7), 1323-1342.
- Villada-Duque, F., Muñoz-Galeano, N., y García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información Tecnológica*, 27(5), 143-150.
- Xu, J., Sun, Z., y Yue, S. (2021). Capital structure and financial performance in China's agricultural sector: a panel data analysis. *Intellectual capital efficiency of agricultural listed companies in China*, 445-463.
- White, H. (1988). Economic prediction using neural networks: the case of IBM daily stock returns. *IEEE 1988 International Conference on Neural Networks*, 451-458.
- World Health Organization. (2023). *Timeline: WHO's COVID-19 response*. Obtenido de World Health Organization: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/interactive-timeline#!>

Anexo 1. Arquitecturas diseñadas en SPSS

Tabla 15. Arquitecturas de RNA. Periodo 2017-2022

Variables	18-1-1	18-2-1	18-3-1	18-4-1	18-5-1	18-6-1	18-7-1	18-8-1	18-9-1	18-10-1
RF1	6.57%	5.73%	3.13%	5.27%	8.16%	8.26%	5.20%	4.32%	1.96%	7.77%
RF2	6.70%	6.38%	6.98%	4.75%	6.67%	7.01%	2.74%	4.91%	2.95%	8.51%
RF3	5.73%	8.41%	10.08%	4.10%	4.54%	2.05%	7.37%	6.12%	3.93%	6.79%
RF4	9.46%	9.28%	12.71%	8.22%	11.73%	12.73%	6.92%	7.49%	8.83%	8.29%
RF5	10.78%	12.24%	18.32%	17.22%	12.88%	12.26%	10.46%	17.75%	21.39%	12.25%
RF6	5.88%	4.07%	2.19%	5.57%	6.40%	2.21%	2.18%	5.55%	4.74%	2.73%
RF7	3.65%	1.49%	4.80%	6.03%	4.76%	4.25%	4.35%	7.67%	8.88%	3.27%
RF8	1.88%	5.18%	6.10%	2.03%	1.92%	2.98%	2.98%	3.95%	3.74%	4.28%
RF9	3.48%	9.27%	3.31%	8.56%	4.82%	3.53%	8.26%	5.64%	5.39%	2.85%
RF10	2.66%	6.75%	1.61%	3.69%	6.49%	3.33%	5.05%	3.90%	4.16%	0.61%
RF11	0.95%	8.27%	0.75%	4.24%	4.24%	3.31%	6.77%	4.57%	2.84%	1.33%
RF12	13.49%	9.49%	11.10%	12.50%	10.99%	10.78%	12.79%	10.01%	11.76%	12.51%
RF13	3.90%	2.97%	1.14%	2.79%	1.81%	1.04%	2.29%	1.89%	1.68%	2.90%
RF14	5.49%	2.54%	4.82%	3.92%	3.57%	4.06%	5.76%	3.60%	5.70%	4.47%
RF15	4.02%	1.12%	2.86%	3.40%	1.61%	4.07%	5.24%	3.85%	3.25%	5.53%
RF16	4.20%	3.67%	2.93%	1.42%	1.67%	5.17%	0.94%	1.37%	3.44%	4.80%
RF17	5.68%	1.03%	3.15%	3.47%	3.78%	5.13%	6.39%	3.27%	3.49%	5.14%

RF18	5.48%	2.10%	4.01%	2.82%	3.96%	7.83%	4.29%	4.15%	1.88%	5.96%
Porcentaje de ajuste (R²)	80.18%	85.96%	92.67%	94.97%	86.43%	89.84%	79.17%	93.65%	94.71%	85.05%

Variables	18-1-1-1	18-1-2-1	18-1-3-1	18-1-4-1	18-1-5-1	18-2-1-1	18-2-2-1	18-2-3-1	18-2-4-1	18-2-5-1
RF1	2.48%	2.21%	6.61%	5.45%	0.16%	7.16%	3.42%	4.57%	8.04%	1.59%
RF2	5.64%	0.88%	5.51%	4.37%	4.96%	0.64%	4.36%	7.35%	8.09%	3.69%
RF3	2.30%	1.29%	6.58%	7.18%	10.59%	12.07%	5.72%	1.37%	1.20%	8.93%
RF4	9.50%	9.93%	7.10%	8.39%	11.83%	11.81%	10.66%	10.41%	12.90%	6.66%
RF5	8.72%	11.15%	12.49%	11.59%	0.50%	2.70%	10.00%	13.45%	9.87%	10.49%
RF6	3.14%	3.92%	6.36%	5.07%	3.21%	1.86%	7.62%	10.81%	8.98%	7.73%
RF7	3.68%	6.62%	3.59%	1.79%	5.77%	1.44%	5.65%	9.23%	3.79%	3.63%
RF8	3.37%	2.34%	5.00%	6.59%	8.30%	4.59%	6.99%	1.53%	5.81%	4.81%
RF9	3.85%	7.80%	3.29%	4.83%	0.24%	12.03%	8.16%	1.63%	8.49%	3.20%
RF10	6.67%	4.95%	0.70%	3.39%	3.03%	0.93%	2.08%	1.06%	4.81%	10.27%
RF11	8.68%	5.23%	4.22%	5.18%	16.59%	2.23%	4.95%	3.91%	3.55%	10.12%
RF12	12.96%	15.48%	13.87%	11.76%	5.00%	12.58%	11.18%	11.81%	9.16%	9.16%
RF13	4.51%	5.20%	5.44%	3.33%	9.36%	3.42%	2.23%	4.39%	2.43%	3.28%
RF14	8.04%	4.32%	0.90%	0.82%	6.82%	5.01%	3.30%	6.65%	2.13%	3.51%
RF15	5.64%	3.48%	2.01%	0.79%	1.29%	3.72%	3.07%	4.25%	1.79%	1.71%
RF16	4.93%	3.30%	1.00%	3.22%	8.76%	5.35%	4.84%	2.68%	3.07%	4.48%

RF17	3.29%	6.16%	8.49%	8.14%	1.58%	5.16%	2.20%	3.44%	2.17%	6.44%
RF18	2.60%	5.77%	6.84%	8.11%		7.29%	3.58%	1.47%	3.71%	0.32%
Porcentaje de ajuste (R^2)	72.20%	73.55%	77.14%	81.20%	72.00%	70.30%	86.54%	86.69%	85.44%	83.17%

Variables	18-3-1-1	18-3-2-1	18-3-3-1	18-3-4-1	18-3-5-1	18-4-1-1	18-4-2-1	18-4-3-1	18-4-4-1	18-4-5-1
RF1	8.27%	4.34%	6.24%	4.88%	1.46%	6.45%	7.66%	3.37%	4.95%	8.93%
RF2	7.60%	8.29%	4.25%	8.47%	1.33%	6.95%	9.08%	6.42%	5.40%	10.05%
RF3	7.95%	8.86%	8.52%	4.05%	1.57%	9.07%	5.72%	8.17%	9.28%	8.67%
RF4	9.97%	12.93%	11.16%	11.55%	12.69%	3.91%	11.09%	12.26%	8.81%	10.27%
RF5	13.25%	14.96%	13.44%	11.30%	15.93%	12.28%	12.29%	13.19%	15.62%	17.46%
RF6	3.07%	2.69%	2.96%	4.11%	10.62%	7.04%	4.46%	3.60%	5.17%	3.13%
RF7	3.24%	2.44%	8.63%	3.92%	2.01%	8.32%	4.06%	2.49%	3.49%	1.46%
RF8	5.25%	3.35%	3.40%	7.49%	5.19%	3.68%	6.97%	5.68%	6.91%	2.66%
RF9	6.57%	6.43%	2.75%	8.32%	7.82%	6.09%	2.30%	4.29%	4.18%	2.66%
RF10	1.87%	3.61%	5.17%	4.86%	2.83%	5.22%	4.64%	2.36%	6.83%	1.77%
RF11	2.37%	3.01%	5.61%	4.89%	4.57%	5.64%	5.76%	2.49%	6.33%	3.58%
RF12	12.63%	11.54%	11.04%	10.05%	14.72%	11.38%	10.34%	11.24%	10.16%	11.13%
RF13	3.02%	2.87%	0.69%	1.65%	3.22%	2.04%	2.31%	2.33%	1.14%	1.70%
RF14	3.05%	6.17%	5.07%	1.87%	6.86%	0.93%	3.48%	5.61%	2.65%	2.25%
RF15	2.20%	3.39%	2.52%	1.20%	4.43%	2.30%	2.20%	5.39%	2.91%	1.68%

RF16	3.21%	1.90%	2.59%	5.21%	0.92%	2.44%	1.89%	4.75%	1.00%	5.87%
RF17	2.39%	1.36%	2.89%	2.58%	2.88%	3.27%	2.07%	2.07%	1.95%	3.19%
RF18	4.07%	1.87%	3.05%	3.58%	0.94%	3.00%	3.69%	4.30%	3.22%	3.53%
Porcentaje de ajuste (R^2)	84.33%	88.80%	89.94%	85.12%	86.73%	89.16%	85.86%	81.93%	95.17%	93.45%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

Tabla 16. Arquitecturas de RNA. Periodo 2017-2019

Variables	18-1-1	18-2-1	18-3-1	18-4-1	18-5-1	18-6-1	18-7-1	18-8-1	18-9-1	18-10-1
RF1	0.13%	6.37%	1.04%	3.43%	2.32%	1.83%	1.19%	4.71%	1.11%	2.09%
RF2	1.84%	1.20%	0.31%	1.57%	3.26%	1.09%	1.73%	1.54%	1.49%	1.05%
RF3	0.29%	1.95%	1.27%	4.04%	2.12%	4.24%	2.75%	6.64%	1.55%	5.70%
RF4	8.73%	8.11%	8.06%	12.23%	10.97%	14.23%	13.97%	14.08%	12.78%	11.71%
RF5	11.63%	13.31%	14.56%	15.15%	16.18%	12.82%	10.22%	12.64%	15.23%	9.15%
RF6	0.69%	6.51%	5.80%	5.54%	8.03%	8.10%	10.58%	1.94%	4.48%	10.17%
RF7	4.96%	2.87%	4.59%	5.60%	6.07%	2.40%	4.55%	6.46%	6.80%	8.17%
RF8	5.67%	0.50%	0.87%	6.53%	3.59%	4.51%	7.14%	3.96%	3.61%	4.38%
RF9	0.06%	7.06%	8.31%	9.53%	7.49%	4.31%	3.32%	4.71%	2.91%	3.79%
RF10	2.07%	5.54%	1.38%	2.06%	3.06%	1.26%	1.92%	4.93%	3.72%	1.84%
RF11	0.42%	4.35%	2.67%	1.25%	1.70%	2.95%	1.04%	3.86%	3.76%	5.11%
RF12	16.65%	14.49%	15.27%	12.90%	18.60%	17.30%	12.49%	14.88%	17.97%	18.09%

RF13	6.41%	0.28%	5.84%	2.73%	2.42%	2.41%	4.36%	2.42%	2.81%	2.80%
RF14	4.13%	4.12%	3.55%	2.43%	0.64%	4.16%	3.36%	2.51%	1.86%	1.59%
RF15	3.86%	5.26%	4.05%	2.28%	2.07%	6.09%	2.15%	3.95%	1.56%	1.26%
RF16	11.09%	7.60%	8.67%	4.76%	0.88%	0.89%	5.50%	3.97%	1.96%	1.58%
RF17	15.17%	8.73%	11.16%	6.03%	6.19%	5.83%	9.53%	5.08%	9.04%	5.29%
RF18	6.20%	1.75%	2.60%	1.95%	4.43%	5.59%	4.22%	1.72%	7.36%	6.23%
Porcentaje de ajuste (R²)	88.08%	91.03%	93.66%	87.68%	95.82%	91.37%	96.87%	96.96%	94.48%	96.33%

Variables	18-7-1-1	18-7-2-1	18-7-3-1	18-7-4-1	18-7-5-1	18-8-1-1	18-8-2-1	18-8-3-1	18-8-4-1	18-8-5-1
RF1	2.77%	2.29%	3.81%	2.53%	2.49%	4.25%	1.60%	2.40%	2.06%	2.05%
RF2	1.37%	1.08%	1.95%	3.51%	0.81%	2.44%	1.86%	1.48%	2.49%	2.14%
RF3	5.37%	2.32%	4.28%	5.97%	4.83%	7.65%	2.62%	4.14%	6.91%	6.71%
RF4	12.81%	13.77%	11.06%	7.90%	11.29%	11.89%	10.15%	10.95%	5.25%	7.19%
RF5	12.54%	13.86%	10.15%	14.37%	12.94%	16.38%	11.15%	12.57%	9.48%	10.19%
RF6	6.06%	2.96%	6.90%	3.22%	2.08%	4.04%	5.22%	6.69%	2.41%	5.15%
RF7	2.50%	4.77%	4.22%	6.32%	7.90%	2.50%	8.41%	3.98%	4.10%	6.25%
RF8	5.19%	7.15%	4.32%	5.20%	2.55%	3.64%	4.07%	5.03%	4.26%	4.57%
RF9	9.72%	8.72%	7.72%	9.10%	9.74%	4.49%	3.75%	10.07%	7.77%	12.41%
RF10	5.79%	1.83%	5.16%	2.34%	2.54%	4.22%	1.28%	4.93%	7.55%	3.90%
RF11	3.75%	5.01%	6.26%	8.18%	5.95%	3.89%	2.07%	2.05%	2.71%	2.57%

RF12	15.06%	17.04%	14.16%	14.26%	16.19%	15.14%	18.23%	15.81%	18.80%	16.77%
RF13	1.16%	5.63%	1.18%	2.32%	3.05%	2.24%	3.74%	2.12%	3.72%	3.88%
RF14	2.33%	2.30%	1.92%	1.21%	0.60%	2.99%	5.28%	1.90%	6.83%	4.86%
RF15	1.86%	3.37%	1.92%	1.97%	2.55%	2.79%	5.07%	2.16%	4.74%	4.41%
RF16	5.53%	2.57%	6.74%	3.21%	5.88%	4.65%	0.88%	2.39%	2.98%	2.66%
RF17	4.80%	3.70%	7.66%	6.75%	6.52%	3.73%	8.44%	7.52%	4.51%	1.98%
RF18	1.41%	1.61%	0.59%	1.65%	2.10%	3.08%	6.18%	3.80%	3.43%	2.32%
Porcentaje de ajuste (R^2)	93.05%	88.98%	96.57%	94.00%	97.90%	94.63%	80.15%	92.96%	86.35%	95.50%

Variables	18-9-1-1	18-9-2-1	18-9-3-1	18-9-4-1	18-9-5-1	18-10-1-1	18-10-2-1	18-10-3-1	18-10-4-1	18-10-5-1
RF1	2.16%	1.34%	1.19%	1.28%	4.30%	2.61%	1.67%	2.56%	2.95%	3.25%
RF2	2.63%	2.97%	1.47%	1.05%	1.78%	1.00%	2.10%	1.07%	2.30%	3.29%
RF3	5.27%	9.55%	7.04%	1.22%	5.28%	3.63%	3.23%	4.79%	4.54%	4.88%
RF4	10.68%	10.72%	7.14%	9.81%	10.22%	12.50%	10.19%	12.27%	13.03%	8.86%
RF5	8.85%	13.75%	12.44%	12.98%	12.88%	11.92%	14.31%	13.25%	16.14%	14.94%
RF6	9.77%	5.24%	4.21%	3.46%	6.71%	4.76%	4.53%	4.69%	2.57%	6.29%
RF7	3.72%	6.03%	2.79%	10.41%	3.77%	4.13%	5.04%	2.31%	5.10%	3.77%
RF8	4.17%	4.58%	2.63%	5.43%	3.13%	6.21%	7.26%	4.65%	3.49%	5.25%
RF9	9.68%	7.72%	12.97%	8.11%	9.09%	7.69%	7.35%	5.17%	5.81%	12.80%
RF10	2.96%	2.03%	5.66%	4.59%	2.10%	3.06%	3.95%	5.68%	5.47%	1.49%

RF11	5.13%	2.53%	5.71%	4.38%	1.88%	2.58%	5.60%	5.72%	5.93%	3.99%
RF12	15.48%	16.92%	13.41%	16.76%	18.50%	18.71%	17.88%	18.22%	14.10%	15.75%
RF13	2.99%	2.87%	2.25%	4.24%	1.85%	3.20%	3.84%	5.33%	1.44%	3.96%
RF14	3.03%	3.19%	5.15%	1.82%	3.07%	3.64%	3.39%	3.56%	1.25%	2.89%
RF15	4.07%	2.77%	3.93%	1.24%	4.78%	3.16%	2.39%	3.25%	1.16%	1.79%
RF16	3.23%	3.33%	5.52%	4.19%	2.68%	3.67%	2.19%	1.62%	6.56%	2.03%
RF17	4.62%	1.91%	2.90%	7.29%	6.11%	6.42%	3.43%	4.31%	6.69%	2.87%
RF18	1.55%	2.54%	3.60%	1.73%	1.86%	1.10%	1.67%	1.56%	1.45%	1.89%
Porcentaje de ajuste (R^2)	88.69%	94.83%	97.51%	92.84%	92.05%	80.45%	82.58%	93.68%	97.02%	96.47%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

Tabla 17. Arquitecturas de RNA. Periodo 2020-2022

Variables	18-1-1	18-2-1	18-3-1	18-4-1	18-5-1	18-6-1	18-7-1	18-8-1	18-9-1	18-10-1
RF1	4.42%	0.81%	11.46%	4.21%	5.19%	2.95%	5.53%	7.54%	4.82%	6.55%
RF2	8.64%	2.82%	6.31%	7.91%	3.60%	8.99%	9.17%	8.93%	1.70%	3.68%
RF3	9.63%	5.74%	2.53%	13.07%	3.66%	4.79%	5.41%	3.13%	2.79%	1.71%
RF4	11.02%	13.20%	12.32%	10.08%	9.98%	10.75%	5.13%	12.04%	12.19%	13.20%
RF5	10.51%	13.21%	10.27%	12.33%	11.33%	14.34%	14.43%	13.19%	14.66%	13.13%
RF6	8.29%	7.83%	8.24%	3.14%	8.23%	4.52%	3.11%	5.33%	2.90%	5.64%
RF7	11.93%	0.21%	0.64%	2.40%	6.01%	3.60%	6.75%	2.40%	2.85%	3.65%

RF8	2.70%	6.21%	9.34%	5.98%	2.92%	1.43%	2.13%	1.82%	7.28%	2.45%
RF9	1.00%	1.56%	3.05%	8.48%	8.67%	9.72%	9.84%	4.86%	8.89%	10.49%
RF10	4.83%	3.81%	0.67%	2.30%	7.99%	4.85%	1.89%	4.87%	3.44%	2.77%
RF11	5.23%	5.43%	0.90%	1.54%	5.57%	3.19%	2.31%	2.49%	5.27%	2.66%
RF12	6.51%	8.75%	11.16%	9.79%	8.17%	7.40%	9.02%	8.29%	10.34%	9.27%
RF13	2.27%	1.60%	4.17%	2.61%	2.38%	0.87%	2.85%	2.38%	3.45%	1.96%
RF14	4.20%	6.59%	5.63%	5.25%	4.86%	5.39%	4.94%	6.26%	4.67%	3.19%
RF15	4.53%	6.35%	4.32%	3.56%	3.72%	5.85%	8.38%	8.85%	3.74%	4.23%
RF16	0.73%	8.21%	2.17%	3.45%	3.22%	6.97%	3.11%	1.78%	3.63%	6.95%
RF17	1.60%	1.61%	3.37%	1.33%	1.37%	2.02%	2.09%	1.92%	2.69%	1.67%
RF18	1.95%	6.07%	3.45%	2.59%	3.12%	2.36%	3.93%	3.93%	4.69%	6.79%
Porcentaje de ajuste (R²)	82.65%	87.91%	87.90%	96.25%	88.50%	80.74%	93.94%	88.82%	93.92%	84.60%

Variables	18-4-1-1	18-4-2-1	18-4-3-1	18-4-4-1	18-4-5-1	18-7-1-1	18-7-2-1	18-7-3-1	18-7-4-1	18-7-5-1
RF1	5.12%	1.59%	9.09%	4.98%	9.02%	4.69%	4.98%	6.37%	8.61%	2.21%
RF2	5.72%	6.67%	9.38%	8.01%	6.64%	5.98%	9.85%	5.91%	7.39%	5.34%
RF3	2.42%	12.64%	6.20%	2.86%	5.95%	7.38%	10.00%	9.70%	6.02%	13.69%
RF4	12.79%	11.45%	8.93%	10.76%	5.87%	10.20%	10.08%	15.14%	10.25%	10.90%
RF5	14.80%	11.76%	13.54%	12.44%	11.31%	11.17%	11.47%	14.28%	2.90%	12.75%
RF6	5.19%	1.27%	2.42%	3.41%	7.48%	4.20%	4.13%	5.39%	11.41%	3.84%

RF7	4.04%	5.40%	5.40%	5.92%	2.52%	4.78%	3.19%	3.93%	7.98%	7.12%
RF8	1.44%	6.57%	4.22%	1.57%	2.17%	2.28%	3.05%	2.34%	5.92%	3.02%
RF9	12.22%	10.88%	3.82%	11.56%	8.36%	9.89%	6.07%	11.04%	9.30%	6.31%
RF10	1.24%	3.27%	2.59%	3.04%	1.79%	2.14%	3.61%	1.71%	1.67%	2.77%
RF11	2.62%	1.03%	2.97%	5.24%	2.22%	2.42%	2.97%	1.60%	0.93%	2.86%
RF12	11.19%	11.00%	11.85%	6.84%	9.90%	11.43%	11.25%	8.63%	9.73%	10.46%
RF13	2.87%	2.88%	5.16%	3.07%	1.34%	1.43%	3.05%	3.03%	1.24%	2.28%
RF14	5.93%	3.89%	3.80%	4.86%	6.34%	5.68%	4.20%	2.46%	5.27%	4.13%
RF15	5.72%	1.29%	0.36%	6.06%	7.82%	5.45%	4.59%	2.16%	6.91%	2.88%
RF16	1.25%	2.69%	2.92%	5.30%	3.78%	5.71%	1.94%	1.11%	0.90%	3.94%
RF17	4.49%	2.59%	3.66%	1.07%	3.01%	2.10%	2.12%	2.64%	2.90%	2.13%
RF18	0.94%	3.14%	3.70%	3.00%	4.45%	3.08%	3.46%	2.56%	0.68%	3.40%
Porcentaje de ajuste (R^2)	72.06%	84.54%	85.72%	86.01%	85.71%	83.36%	94.94%	98.00%	64.87%	87.31%

Variables	18-8-1-1	18-8-2-1	18-8-3-1	18-8-4-1	18-8-5-1	18-9-1-1	18-9-2-1	18-9-3-1	18-9-4-1	18-9-5-1
RF1	6.62%	4.56%	8.14%	3.47%	5.25%	6.20%	7.48%	2.63%	3.12%	7.13%
RF2	7.84%	3.05%	9.28%	4.50%	6.91%	7.81%	9.52%	5.72%	6.48%	8.47%
RF3	8.49%	10.45%	6.50%	9.56%	11.54%	8.47%	7.19%	6.97%	9.24%	3.16%
RF4	10.58%	5.96%	10.25%	11.96%	10.35%	9.09%	10.82%	10.19%	10.96%	12.19%
RF5	10.20%	8.69%	9.58%	17.08%	7.48%	9.01%	12.03%	10.58%	11.65%	11.79%

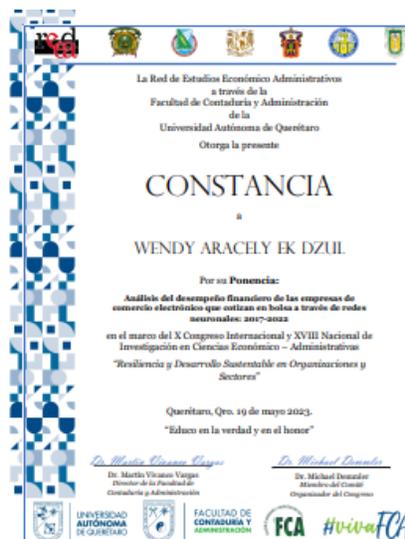
RF6	2.62%	8.67%	4.54%	5.43%	3.61%	5.09%	1.56%	5.66%	3.94%	4.92%
RF7	5.42%	2.28%	2.89%	4.42%	4.32%	4.62%	2.08%	4.38%	5.82%	4.09%
RF8	2.64%	5.37%	3.48%	4.04%	4.87%	4.65%	1.61%	3.11%	6.19%	2.31%
RF9	7.14%	10.84%	9.52%	4.15%	7.67%	8.79%	7.46%	9.86%	4.93%	7.76%
RF10	8.70%	8.14%	2.58%	1.99%	2.51%	4.48%	2.53%	8.30%	3.23%	3.75%
RF11	5.21%	7.00%	1.45%	2.55%	2.02%	0.94%	5.96%	5.24%	1.71%	2.17%
RF12	9.27%	6.51%	10.30%	10.19%	12.08%	7.87%	9.84%	9.57%	10.90%	10.28%
RF13	2.91%	2.64%	2.03%	1.93%	3.43%	4.22%	2.06%	1.85%	3.93%	2.39%
RF14	4.79%	4.18%	4.01%	5.51%	6.69%	6.53%	7.26%	6.54%	6.24%	6.75%
RF15	4.24%	5.25%	5.80%	4.14%	4.29%	5.74%	5.69%	4.41%	3.43%	5.06%
RF16	1.30%	1.86%	2.19%	1.89%	2.09%	2.51%	2.49%	2.28%	3.26%	2.19%
RF17	1.45%	3.38%	3.42%	2.85%	2.59%	1.55%	1.80%	1.63%	2.07%	3.52%
RF18	0.58%	1.19%	4.06%	4.34%	2.30%	2.43%	2.61%	1.08%	2.91%	2.07%
Porcentaje de ajuste (R^2)	85.33%	88.45%	87.81%	93.71%	85.78%	81.18%	83.44%	91.03%	84.56%	93.96%

Fuente: Elaboración propia a partir de las arquitecturas diseñadas en SPSS

Ek, W. (2023). *Aplicación de la Inteligencia Artificial (RNA) en las finanzas* [Taller].
Ciclo de conferencias y talleres: Toma de decisiones en los Mercados
Financieros.



Ek, W. (2023). *Análisis del desempeño financiero de las empresas de comercio electrónico que cotizan en bolsa a través de redes neuronales: 2017-2022* [Ponencia]. X Congreso Internacional y XVIII Nacional de Investigación en Ciencias Económico-Administrativas "Resiliencia y Desarrollo Sustentable en Organizaciones y Sectores".



Ek, W. (2023). *Evaluación del desempeño financiero de las empresas de comercio electrónico* [Ponencia]. Programa de Movilidad de Estudiantes de Posgrado (Maestría y Doctorado) y profesores visitantes latinoamericanos PROMO-LAC 2023.



Participación en cursos y talleres

Software Shop (2021). *Análisis Económico de Proyectos basados en Riesgo con apoyo de PEAT* [Curso].



BBVA (2022). *Prepárate para una emergencia* [Taller].



Escuela Nacional de Formación Pública y Empresarial (2022). *Macroeconomía* [Taller].



Universidad Nacional Autónoma de México (2022). *“Recursos de EBSCO como herramientas para la investigación y trabajos académicos”* [Curso].



Universidad Nacional Autónoma de México (2022). *Taller Colaborativo de toma informada de decisiones (SOLE)* [Taller].



Universidad Nacional Autónoma de México (2022). *Uso de recursos electrónicos para la biblioteca digital de la UNAM* [Curso].



Santander Universidades (2022). *Introducción a las Habilidades Digitales* [Curso].



Asociación Latinoamericana de Facultades y Escuelas de Contaduría y Administración y Universidad de Santo Tomás (2023). *Data Analytics* [Curso].



Universidad Autónoma Metropolitana (2023). *Fundamentos de innovaciones en finanzas y en las inversiones* [Curso].



Anexo 3. Reporte de similitudes y coincidencias

Análisis del desempeño financiero de las empresas de comercio electrónico que cotizan en la bolsa de valores de EE.UU. a través de RNA: 2017-2022

INFORME DE ORIGINALIDAD

25%

ÍNDICE DE SIMILITUD

FUENTES PRIMARIAS

1	www.researchgate.net Internet	590 palabras — 3%
2	www.rcs.cic.ipn.mx Internet	486 palabras — 2%
3	www.indteca.com Internet	338 palabras — 2%
4	revistas.unilibre.edu.co Internet	215 palabras — 1%
5	revistas.unicartagena.edu.co Internet	206 palabras — 1%
6	www.scielo.org.mx Internet	205 palabras — 1%
7	hdl.handle.net Internet	194 palabras — 1%
8	doczz.es Internet	188 palabras — 1%
9	www.theibfr.com Internet	157 palabras — 1%

10	dialnet.unirioja.es Internet	132 palabras — 1%
11	www.scielo.org.bo Internet	127 palabras — 1%
12	idoc.pub Internet	125 palabras — 1%
13	theibfr.com Internet	101 palabras — < 1%
14	www.coursehero.com Internet	99 palabras — < 1%
15	1library.co Internet	93 palabras — < 1%
16	repositorio.cepal.org Internet	93 palabras — < 1%
17	dspace.unl.edu.ec Internet	64 palabras — < 1%
18	dspace.ups.edu.ec Internet	54 palabras — < 1%
19	eprints.uanl.mx Internet	48 palabras — < 1%
20	moam.info Internet	45 palabras — < 1%
21	www.scielo.org.co Internet	45 palabras — < 1%

22	colpaxmex.com Internet	43 palabras — < 1%
23	repository.unab.edu.co Internet	43 palabras — < 1%
24	repositorio.upt.edu.pe Internet	41 palabras — < 1%
25	docplayer.es Internet	40 palabras — < 1%
26	dspace.ceu.es Internet	40 palabras — < 1%
27	repositorio.utn.edu.ec Internet	39 palabras — < 1%
28	core.ac.uk Internet	34 palabras — < 1%
29	www.grafiati.com Internet	34 palabras — < 1%
30	www.slideshare.net Internet	33 palabras — < 1%
31	prezi.com Internet	32 palabras — < 1%
32	repositorio.usm.cl Internet	30 palabras — < 1%
33	seekingalpha.com Internet	30 palabras — < 1%

web.unfpa.org

34	Internet	30 palabras — < 1%
35	repositorio.uta.edu.ec Internet	29 palabras — < 1%
36	www.icesi.edu.co Internet	26 palabras — < 1%
37	es-us.finanzas.yahoo.com Internet	25 palabras — < 1%
38	tesis.ipn.mx Internet	25 palabras — < 1%
39	dspace.utpl.edu.ec Internet	23 palabras — < 1%
40	repositorioacademico.upc.edu.pe Internet	23 palabras — < 1%
41	risisbi.uqroo.mx Internet	23 palabras — < 1%
42	publicaciones.unirioja.es Internet	22 palabras — < 1%
43	openaccesojcs.com Internet	21 palabras — < 1%
44	ojs.brazilianjournals.com.br Internet	19 palabras — < 1%
45	repositorio.comillas.edu Internet	19 palabras — < 1%
46	repositorio.ug.edu.ec	

	Internet	19 palabras — < 1%
47	repositorio-digital.cide.edu Internet	18 palabras — < 1%
48	www.icesi.co Internet	18 palabras — < 1%
49	www.upb.edu Internet	18 palabras — < 1%
50	qdoc.tips Internet	17 palabras — < 1%
51	www.ecorfan.org Internet	17 palabras — < 1%
52	cdi.mecon.gov.ar Internet	16 palabras — < 1%
53	www.blueknow.com Internet	16 palabras — < 1%
54	repository.eafit.edu.co Internet	14 palabras — < 1%
55	Alves, Marta Sofia Maravilhas. "O Impacto Financeiro no Primeiro ano de Pandemia de Pandemia Covid-19 nas Farmácia Comunitárias em Portugal", Instituto Politecnico do Porto (Portugal), 2023 ProQuest	13 palabras — < 1%
56	Ana González-Urteaga, Luis Muga, Rafael Santamaría. "Coasimetría idiosincrática y riesgo de insolvencia en el mercado de valores español",	13 palabras — < 1%

-
- 57 Plaza Rey, Walter. "Factores que intervienen en el comportamiento de los consumidores en su intención de comprar productos vendidos por negocios locales o internacionales a través de la red social de Facebook", University of Puerto Rico, Rio Piedras (Puerto Rico), 2023
ProQuest 13 palabras — < 1%
-
- 58 Alicia Bonamino, Fátima Alves, Creso Franco, Sibeles Cazelli. "Os efeitos das diferentes formas de capital no desempenho escolar: um estudo à luz de Bourdieu e de Coleman", Revista Brasileira de Educação, 2010
Crossref 12 palabras — < 1%
-
- 59 Mogollon Olivos, Patricia | Pariona Retamozo, Albert | Raa Hervias, Rafael | Varas Hilario, Roberto. "Buenas Practicas Financieras En El Proceso De Fusiones Por Absorcion En Empresas Peruanas Que Cotizan En La Bolsa De Valores De Lima.", Pontificia Universidad Catolica del Peru - CENTRUM Catolica (Peru), 2020
ProQuest 12 palabras — < 1%
-
- 60 investiga.banrep.gov.co
Internet 12 palabras — < 1%
-
- 61 revistas.uis.edu.co
Internet 12 palabras — < 1%
-
- 62 www.tdx.cat
Internet 12 palabras — < 1%
-
- 63 www.webpondo.org
Internet 12 palabras — < 1%

64	Alencastre Nin, Ciro Antuan Cortez Nunez del Prado, Ramiro Renzo De Los Rios Sanchez, Nataly Alexandra Zegarra Arias et al. "Indice de Progreso Social de la Provincia de Chumbivilcas.", Pontificia Universidad Catolica del Peru - CENTRUM Catolica (Peru), 2020 ProQuest	11 palabras — < 1%
65	bdigital.unal.edu.co Internet	11 palabras — < 1%
66	espejos.unesco.org.uy Internet	11 palabras — < 1%
67	isiarticles.com Internet	11 palabras — < 1%
68	portalsocial.guanajuato.gob.mx Internet	11 palabras — < 1%
69	publicaciones.uat.edu.mx Internet	11 palabras — < 1%
70	repositorio.unasam.edu.pe Internet	11 palabras — < 1%
71	repositoriodigital.ucsc.cl Internet	11 palabras — < 1%
72	voces.huffingtonpost.com Internet	11 palabras — < 1%
73	www.scribd.com Internet	11 palabras — < 1%
74	Cruz Gaitan, Stefanie. "Gobierno corporativo y responsabilidad social en empresas de la bolsa"	10 palabras — < 1%

de valores de Lima", Pontificia Universidad Catolica del Peru -
CENTRUM Catolica (Peru), 2021

ProQuest

75	Svetlana Viktorovna Panasenko, Vyacheslav Petrovich Cheglov, Ibrahim Agaevich Ramazanov, Elena Anatolevna Krasil'nikova et al. "Mechanisms of e-commerce enterprises development in the context of digitalization", Nexo Revista Científica, 2021 <small>Crossref</small>	10 palabras — < 1%
76	cybertesis.uni.edu.pe <small>Internet</small>	10 palabras — < 1%
77	documentop.com <small>Internet</small>	10 palabras — < 1%
78	exonegocios.com <small>Internet</small>	10 palabras — < 1%
79	opencommons.uconn.edu <small>Internet</small>	10 palabras — < 1%
80	repository.unipiloto.edu.co <small>Internet</small>	10 palabras — < 1%
81	revistas.itm.edu.co <small>Internet</small>	10 palabras — < 1%
82	rua.ua.es <small>Internet</small>	10 palabras — < 1%
83	upc.aws.openrepository.com <small>Internet</small>	10 palabras — < 1%
84	www.colibri.udelar.edu.uy <small>Internet</small>	10 palabras — < 1%

85	www.scielo.cl Internet	10 palabras — < 1%
86	www.spell.org.br Internet	10 palabras — < 1%
87	www2.ing.puc.cl Internet	10 palabras — < 1%
88	Rodrigo Estupiñan. "Análisis financiero y de gestión", Ecoe Ediciones S. A. S., 2020 Crossref	9 palabras — < 1%
89	Yong-Hong KUO, Janny M.Y. LEUNG, Yimo YAN. "Public Transport for Smart Cities: Recent Innovations and Future Challenges", European Journal of Operational Research, 2022 Crossref	9 palabras — < 1%
90	bibliotecavirtual.dgb.umich.mx:8083 Internet	9 palabras — < 1%
91	catalogo.uniandes.edu.co Internet	9 palabras — < 1%
92	cupdf.com Internet	9 palabras — < 1%
93	doaj.org Internet	9 palabras — < 1%
94	dspace.esPOCH.edu.ec Internet	9 palabras — < 1%
95	informativos.net Internet	9 palabras — < 1%

96	pdfs.semanticscholar.org Internet	9 palabras — < 1%
97	pesquisa.bvsalud.org Internet	9 palabras — < 1%
98	pesquisa.teste.bvsalud.org Internet	9 palabras — < 1%
99	repositorio.deusto.es Internet	9 palabras — < 1%
100	repositorio.pucp.edu.pe Internet	9 palabras — < 1%
101	repository.usta.edu.co Internet	9 palabras — < 1%
102	reunir.unir.net Internet	9 palabras — < 1%
103	tesiuami.uam.mx Internet	9 palabras — < 1%
104	worldwidescience.org Internet	9 palabras — < 1%
105	ws.glisc.info Internet	9 palabras — < 1%
106	www.diariodexalapa.com.mx Internet	9 palabras — < 1%
107	www.eluniversal.com Internet	9 palabras — < 1%

www.legisver.gob.mx

108	Internet	9 palabras — < 1%
109	www.ptolomeo.unam.mx:8080 Internet	9 palabras — < 1%
110	www.scotiainverlat.com Internet	9 palabras — < 1%
111	www.timetoast.com Internet	9 palabras — < 1%
112	www.web.facpya.uanl.mx Internet	9 palabras — < 1%
113	Dominguez, angel Martin Ramos. "«Análisis de las Preferencias del Turista Mediante Análisis Conjunto: El Caso de Tenerife", Universidad de La Laguna (Canary Islands, Spain), 2022 ProQuest	8 palabras — < 1%
114	Mercedes Luque-Vílchez, Pablo Rodríguez-Gutiérrez, María Dolores Guerrero-Baena. "El género del CEO como determinante de la supervivencia de la empresa: el caso de las pymes agroalimentarias españolas", Revista Galega de Economía, 2019 Crossref	8 palabras — < 1%
115	baixardoc.com Internet	8 palabras — < 1%
116	bde.es Internet	8 palabras — < 1%
117	buleria.unileon.es Internet	8 palabras — < 1%

118	covid-19.openaire.eu Internet	8 palabras — < 1%
119	documents.mx Internet	8 palabras — < 1%
120	dspace-uaio.metacatalogo.com Internet	8 palabras — < 1%
121	fr.slideshare.net Internet	8 palabras — < 1%
122	observatorioecommerce.mintic.gov.co Internet	8 palabras — < 1%
123	ojs.correspondenciasy analisis.com Internet	8 palabras — < 1%
124	perso.wanadoo.es Internet	8 palabras — < 1%
125	publications.iadb.org Internet	8 palabras — < 1%
126	rcientificas.uninorte.edu.co Internet	8 palabras — < 1%
127	repositorio.chapingo.edu.mx Internet	8 palabras — < 1%
128	repositorio.uncp.edu.pe Internet	8 palabras — < 1%
129	repository.uaeh.edu.mx Internet	8 palabras — < 1%

revistas.unipamplona.edu.co

130	Internet	8 palabras — < 1%
131	rnw-classical.nl Internet	8 palabras — < 1%
132	transportesynegocios.wordpress.com Internet	8 palabras — < 1%
133	www.bancomundial.org Internet	8 palabras — < 1%
134	www.cepchile.cl Internet	8 palabras — < 1%
135	www.ciberconta.unizar.es Internet	8 palabras — < 1%
136	www.clubitm.com Internet	8 palabras — < 1%
137	www.cpcecf.org.ar Internet	8 palabras — < 1%
138	www.europarl.europa.eu Internet	8 palabras — < 1%
139	www.la-bolsa.com Internet	8 palabras — < 1%
140	www.questionpro.com Internet	8 palabras — < 1%
141	www.tiramillas.net Internet	8 palabras — < 1%
142	www2.uca.edu.ar	

Internet

8 palabras — < 1%

143 Elena Díez Sánchez. "Aprovechamiento de subproductos de zumos de frutos rojos para el diseño de alimentos", Universitat Politecnica de Valencia, 2021 7 palabras — < 1%
Crossref Posted Content

144 Francisco José López-Arceiz, Ana José Bellostas-Pérezgrueso, José Mariano Moneva-Abadía, María Pilar Rivera-Torres. "The role of Corporate Governance and transparency in the generation of financial performance in socially responsible companies", Spanish Journal of Finance and Accounting / Revista Española de Financiación y Contabilidad, 2017 7 palabras — < 1%
Crossref

145 Gustavo Ortiz Millán. "COVID-19 y bioética: los aspectos bioéticos más relevantes de una pandemia", Universidad Nacional Autonoma de Mexico, 2021 7 palabras — < 1%
Crossref

146 idus.us.es 6 palabras — < 1%
Internet

EXCLUIR CITAS

ACTIVADO

EXCLUIR FUENTES

DESACTIVADO

EXCLUIR BIBLIOGRAFÍA

ACTIVADO

EXCLUIR COINCIDENCIAS

DESACTIVADO