



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO



FACULTAD DE ECONOMÍA

**“DETERMINACIÓN DE LAS EMPRESAS QUE GENERAN VALOR DE LA
BMV MEDIANTE LOS INDICADORES FINANCIEROS Y CICLOS
ECONÓMICOS DE MÉXICO A TRAVÉS DE LA TÉCNICA REDES
NEURONALES ARTIFICIALES: 2006-2020”**

TESIS

**QUE PARA OBTENER EL TÍTULO DE:
LICENCIADO EN ACTUARÍA**

**PRESENTA:
RUBÉN JESÚS ALBARRÁN BOBADILLA**

**ASESOR:
DR. EN ADM. OSWALDO GARCÍA SALGADO**

**REVISORAS:
DRA. EN E.A y N LIDIA ELENA CARVAJAL GUTIÉRREZ
DRA. EN ADM. MIRIAM DÍAZ GUTIÉRREZ**

TOLUCA, ESTADO DE MÉXICO

MAYO 2026

Tabla de contenido

Introducción.....	8
Planteamiento del problema.....	8
Justificación.....	9
Objetivos	9
Hipótesis	10
Metodología	10
Capitulado.....	11
1 Capítulo I: Marco Teórico y Referencial sobre Desempeño Financiero y Redes Neuronales Artificiales.....	12
Introducción.....	12
1.1 Marco teórico.....	12
1.1.1 Redes Neuronales Artificiales.....	13
1.1.1 EVA	14
1.1.2 Q de Tobin	14
1.1.2 Análisis DuPont	15
1.1.3 Componentes Principales.....	15
1.1.4 Análisis Discriminante Múltiple	16
1.1.5 CAMEL	16
1.1.6 Rentabilidad.....	17
1.1.7 Cotizaciones	17
1.1.8 Inflación	17
1.1.9 Rendimiento.....	18
1.1.10 Series de Tiempo.....	19
1.2 Marco Referencial	19
1.3 Conclusiones del Capítulo.....	29
2 Capitulo II: Marco contextual	30
Introducción.....	30
2.1 Desempeño Financiero	30
2.1.1 Objetivos y alcances.....	30
2.2 Estados Financieros.....	31
2.2.1 Activo	32

2.2.2	Pasivo	33
2.2.3	Estado de Resultados	33
2.2.4	Flujo de Caja	33
2.3	Razones Financieras	34
2.3.1	Razones de Liquidez	35
2.3.2	Razones de Apalancamiento	35
2.3.3	Razones de Solvencia	36
2.3.4	Razones de Actividad	37
2.3.5	Razones de Rentabilidad	38
2.4	Política monetaria	40
2.5	Banco de México	41
2.6	Mercados financieros	41
2.6.1	Mercado de capitales	42
2.6.2	Mercado de valores	45
2.7	Bolsa de valores	46
2.7.1	Bolsas de Valores en el mundo	46
2.7.2	Bolsa Mexicana de Valores	48
2.7.3	Bolsa Institucional de Valores	54
2.8	Ciclo económico	55
2.8.1	Definición	56
2.8.2	Fases del Ciclo Económico	56
2.8.3	Reloj del Ciclo Económico	57
2.8.4	Indicadores del Ciclo económico	58
2.9	EVA	61
2.9.1	Cálculo del indicador EVA	62
2.10	GEO	62
2.10.1	Cálculo del indicador GEO	63
2.11	Conclusiones del Capítulo	63
3	Capítulo III: Redes Neuronales Artificiales	65
	Introducción	65
3.1	Inspiración biológica	65
3.1.1	Célula	65
3.1.2	Sistema nervioso	66

3.1.3	Neurona.....	66
3.1.4	Redes neuronales biológicas.....	67
3.2	Redes Neuronales Artificiales	68
3.2.1	Definición	68
3.2.2	Alcance de las Redes Neuronales.....	69
3.2.3	Aplicaciones de las RNA.....	69
3.3	Entrenamiento de RNA	70
3.3.1	Descenso de gradiente	71
3.4	Arquitectura de Redes Neuronales	74
3.5	Funciones de activación.....	75
3.5.1	Función escalón.....	76
3.5.2	Función lineal y mixta	77
3.5.3	Función tangente e hiperbólica.....	78
3.5.4	Función Sigmoidal	78
3.6	Modelos de RNA	79
3.6.1	Modelo simple de neurona biológica	79
3.6.2	Perceptrón	79
3.6.3	Perceptrón Multicapa.....	80
3.6.4	Redes de retropropagación (Backpropagation)	80
3.7	Línea del tiempo de redes neuronales	81
3.8	Conclusiones del Capítulo.....	83
4	Capítulo IV: Metodología	84
	Introducción.....	84
4.1	Empresas que se analizaron de la Bolsa Mexicana de valores	84
4.1.1	Muestreo Irrestricto Aleatorio Estratificado	85
4.1.2	Descripción de la Muestra	88
4.2	Preparación de la Información.....	95
4.3	Modelo de Redes neuronales de Retropropagación	101
4.3.1	Reporte de Clasificación	105
4.3.2	Matriz de Confusión.....	105
4.4	Análisis de resultados	107
4.4.1	Caso EVA	111
4.4.2	Caso GEO	128

4.4.3	Resumen de Redes Neuronales de Retropropagación	145
5	Conclusiones	149
	Bibliografía y Artículos de Referencia	153
	Anexos	158

Introducción

Planteamiento del problema

En el contexto de economías emergentes como la mexicana, la eficiencia del mercado de capitales y el desempeño financiero de las empresas listadas constituyen variables fundamentales para el crecimiento económico y el desarrollo industrial. En este sentido, la creación de valor económico por parte de las empresas que cotizan en la Bolsa Mexicana de Valores (BMV) se convierte en un indicador crucial para evaluar su sostenibilidad y competitividad. Dos de los métodos más reconocidos en la literatura financiera para evaluar dicha creación de valor son el Valor Económico Agregado (EVA, por sus siglas en inglés) y el Valor Económico Generado (GEO financiero). Ambos permiten identificar si las operaciones empresariales realmente contribuyen al crecimiento del valor para los accionistas, más allá de las utilidades contables tradicionales.

Sin embargo, en México persiste una limitada integración entre estos indicadores de valor y la medición del desempeño financiero bursátil, particularmente en su impacto sobre el Índice de Precios y Cotizaciones (IPC) de la BMV, el cual representa el termómetro más visible de la evolución del mercado accionario nacional. Existen brechas en el conocimiento respecto a si las empresas con mayor generación de valor económico son sistemáticamente premiadas por el mercado, reflejando dicha eficiencia en una mayor ponderación en el índice o en una capitalización bursátil creciente. Esta desconexión genera preguntas relevantes: ¿Está el mercado reconociendo adecuadamente la creación de valor? ¿Qué relación guardan el EVA y el GEO financiero con los retornos accionarios, la volatilidad y la estructura del IPC?

Además, la generación de valor empresarial tiene repercusiones agregadas sobre la economía mexicana, dado que un mercado bursátil dinámico, eficiente y alineado con indicadores reales de valor puede incentivar mayor inversión nacional y extranjera, financiamiento productivo y desarrollo industrial. Por el contrario, si los indicadores de valor no se reflejan en el comportamiento bursátil, se corre el riesgo de generar incentivos distorsionados, dificultando el acceso a capital por parte de empresas realmente eficientes.

Este escenario plantea un problema crítico: la falta de evidencia empírica y modelos explicativos que vinculen la generación de valor económico, medida a través de EVA y

GEO financiero, con los indicadores de desempeño financiero en la BMV, su peso en el IPC y su efecto sistémico en la economía y en sectores estratégicos de la industria mexicana.

Justificación

La toma de decisiones siempre ha sido un tema de interés en la sociedad, si bien los datos y la información es relevante, también lo es su interpretación para llegar a soluciones y reducir la incertidumbre que rodea los problemas modernos. Con el avance de las ciencias exactas, económicas y la agrupación de sociedades, surgen métodos que le permiten a las personas tanto físicas como a las empresas tomar mejores decisiones para su salud financiera y beneficio económico, dichos métodos con cimientos probabilísticos han ido modernizándose con el paso del tiempo y el alcance humano. La aplicación y comparación entre metodologías para resolver un problema es necesario para optimizar los beneficios.

Para ello es necesario realizar análisis multivariados o modelos más contemporáneos que permitan determinar estas razones financieras y fases del ciclo económico, de tal manera que se propongan técnicas de inteligencia artificial en específico de Redes Neuronales Artificiales de retropropagación, que permitan ser más eficaces que otras técnicas tradicionales multivariadas, dado a que esta técnica busca patrones de comportamiento y no características de estadísticas paramétricas.

Con este nuevo enfoque de redes neuronales aplicado al área financiera y la generación de valor, las empresas pueden tomar decisiones de mercado útiles, encontrar puntos por fortalecer y generar una sólida planificación financiera para su futuro.

Objetivos

La presente investigación tiene como objetivo principal el uso de la técnica de redes neuronales artificiales, específicamente las redes de retropropagación para determinar la generación de valor de ciertas acciones que figuran en la BMV.

De forma específica, los objetivos son:

- Determinar las relaciones entre las razones financieras y los indicadores para generación de valor como el EVA.
- Determinar las relaciones entre razones financieras de las emisoras pertenecientes a la BMV y los indicadores de valor como el GEO.
- Determinar la correlación presente entre las razones financieras y el ciclo económico para la generación de valor de emisoras de la BMV.

Hipótesis

Como hipótesis principal se plantea:

H_P: Existe relación de determinadas razones financieras y ciclos económicos con los indicadores de creación de valor GEO y EVA de las emisoras de la BMV;

Contrariamente a esta hipótesis se declara que las razones financieras y los ciclos económicos no proporcionan información relevante para influir en los resultados de los indicadores de generación de valor.

Como hipótesis secundarias se plantean que;

Hs₁: Existen determinadas razones financieras de las emisoras de la BMV que tienen relación con el indicador GEO.

Hs₂: Existen determinadas razones financieras de las emisoras de la BMV que tienen relación con el indicador EVA.

Hs₃: Existen determinadas fases de los ciclos económicos de México que tienen relación con el indicador GEO de las emisoras de la BMV.

Hs₄: Existen determinadas fases de los ciclos económicos de México tienen relación con el indicador EVA de las emisoras de la BMV.

Metodología

Para la realización del trabajo se comenzó con la obtención de una base de datos en hoja electrónica donde se encuentran variables importantes para la investigación: emisora, periodo, razones financieras, indicadores de valor de emisoras, entre otras para cada etapa del reloj de ciclo económico, que, a su vez, brindan información financiera sobre las

emisoras de la BMV; para el periodo de estudio comprendido entre 2006 a 2020. Esta base de datos fue obtenida de la plataforma Economatica de la UNAM y que fue proporcionada de los trabajos realizados por Espinoza (2024) y Garduño (2022) y de la investigación del cuerpo académico Economía Financiera Internacional del proyecto de investigación 5012 2020CIB. Para después filtrar y seleccionar las que se utilizaron en la investigación, quedando solo ciertas emisoras, y sus correspondientes razones financieras, etapas del reloj del ciclo económico en el que se encontraban y resultados de los indicadores de generación de valor igual correspondientes a las emisoras seleccionadas. El siguiente paso fue la generación de modelos de redes neuronales de auto propagación que respondieron las hipótesis planteadas y cumplieron con los objetivos de la investigación. Finalmente, se llegó a la etapa en la que se resolvieron las preguntas de investigación y se desarrollaron los resultados obtenidos de los modelos, se discutieron las conclusiones y se propusieron futuras aplicaciones de la investigación.

Capitulado

En cuanto a la organización de la investigación, se divide en cinco apartados diferentes: el primer capítulo recolecta los conceptos más importantes y las investigaciones de diversos autores que sirven como base para entender esta investigación. El segundo capítulo describe el contexto de la investigación de forma detallada, enfocándose en conceptos necesarios de entender como las variables utilizadas en la base de datos de forma detallada y su importancia en esta investigación. El tercer capítulo, profundiza en la técnica a utilizar: las redes neuronales, con énfasis en la retropropagación. El cuarto capítulo aplica la técnica de Redes Neuronales en una base de datos para generar el modelo que establezca las relaciones entre razones financieras, ciclo económico e indicadores de generación de valor, estableciendo la metodología utilizada en la investigación y presentando los modelos y resultados obtenidos. Finalmente, en el último capítulo las conclusiones de la investigación, comprobación de hipótesis, limitaciones y recomendaciones para futuras investigaciones.

Capítulo I: Marco Teórico y Referencial sobre Desempeño Financiero y Redes Neuronales Artificiales

Introducción

Este capítulo se divide en dos partes, en primera instancia se muestran conceptos y teorías que adentran al entendimiento de diversas técnicas para el análisis financiero de rentabilidades, acciones y preámbulo de la generación de valor, junto con un extracto de la investigación con el fin de entender las teorías y aplicaciones más comunes para el desarrollo de la generación de valor. Posteriormente, se recapitulan los diversos trabajos de investigación, procedentes de distintos contextos, países y autores que emplean técnicas de redes neuronales en sus investigaciones financieras o bursátiles, mostrando los beneficios del uso de estas para las áreas financieras, bursátiles y empresariales, dichas investigaciones sirven como pilares para este trabajo de investigación.

En consecuencia, se muestra la comparación de la aplicación de redes neuronales artificiales y otras técnicas más generales para el análisis financiero, los beneficios y déficits que se presentan por cada una, con la finalidad de generar decisiones orientadas a una mayor generación de valor en el ámbito financiero y organizacional de una empresa.

1.1 Marco teórico

Entre los objetivos más importantes de una empresa está el de ser generadora de valor con el fin de mantener una buena salud financiera, atraer nuevos inversionistas, crecer su importancia en el mercado, entre otros. Tanto son los beneficios derivados de la generación de valor, que resulta natural para las empresas conocer los métodos y conceptos que aporten sobre la generación de valor, estos se presentan en el marco teórico.

García y Morales (2014) conglomeran diversas técnicas y metodologías en cuatro enfoques sobre el desempeño financiero y su obtención, descritos a continuación:

Tabla 1-1 Enfoques de trabajos relacionados con el desempeño financiero de las empresas.

Enfoque	Descripción
Enfoques que analizan el desempeño bajo medidas convencionales financieras	Enfoques basados en la información contable, como lo son los indicadores EVA, estructura de capital, actividad basada en los costos, ROI, ROA, MVA, Q de Tobin, flujo de efectivo, margen de utilidad, utilidad por acción (EPS), relación precio/utilidad (P/U), coeficiente de solvencia WACC, análisis DUPOPNT, entre otras medidas financieras.
Enfoques que analizan la técnica utilizada para la determinación del desempeño	Aquellos que utilizan metodologías estadísticas como: componentes principales, regresión múltiple, análisis discriminante múltiple, árboles de decisión CHAID, modelos logísticos, series de tiempo, técnicas estadísticas como ANOVA y REMS, modelos tipo CAMEL, algoritmos genéticos, lógica difusa, redes neuronales artificiales, modelos de crédito, curvas ROC entre otros.
Enfoques del desempeño financiero de acuerdo con características de las empresas	Hace referencia al capital intelectual, recursos humanos, información tecnológica, corporativo social, el tamaño de las corporaciones, la calidad de la información financiera, el balance score card, indicadores del mercado bursátil o no bursátil, entrenamiento del manejo de información financiera, responsabilidad social, desempeño de activos internacionales, valor del funcionamiento, cadena de suministros y la reputación de las empresas.
Enfoques que aplican otros criterios no financieros para la importancia del desempeño	Analizando a las pequeñas empresas, a las medianas y a las grandes, Aquellas pertenecientes a las Bolsas de valores, a las empresas internacionales y a las filiales. También analiza aquellas que tienen un enfoque relacionado con los sectores bancario, manufacturero, industrial o de arrendamiento, entre otros.

Fuente: García y Morales (2014)

1.1.1 Redes Neuronales Artificiales

Diversas investigaciones mencionan el uso de redes neuronales artificiales, técnicas con múltiples aplicaciones que, gracias al poder computacional moderno, han evolucionado exponencialmente.

Las redes neuronales se desarrollaron para simular el sistema nervioso humano para tareas de aprendizaje automático tratando las unidades computacionales como un modelo de aprendizaje de manera similar a las neuronas humanas. La gran visión de las redes neuronales es crear inteligencia artificial mediante la construcción de máquinas cuya arquitectura simule los cálculos del sistema nervioso humano (Aggarwal, 2018).

1.1.1 EVA

Mavila & Polar (2006) mencionan que el EVA se traduce como un indicador específico de ingreso residual, utilizado por muchas empresas para medir su desempeño. Este puede ser usado para evaluar alternativas de inversión o evaluar la actuación de los directivos empresariales, este método se fundamenta en que los recursos empleados por una empresa o unidad estratégica de negocio deben producir una rentabilidad superior a su costo, pues de no ser así, desde el punto de vista estratégico, es mejor trasladar los bienes utilizados a otra actividad.

El EVA también se conoce como EP (Economic Profit) o utilidad económica; autores como García y Morales (2014) evalúan en términos del EVA si las fusiones han generado valor en empresas de telecomunicaciones cotizantes en la Bolsa Mexicana de Valores, identificando el modelo que mayores ventajas brinda en la generación de valor.

1.1.2 Q de Tobin

Tapia (2017) establece que la Q de Tobin es un indicador básico de rentabilidad y beneficios a largo plazo de un sector, indica si un activo está sobrevalorado o infravalorado, posibilitando predicciones sobre inversiones de capital. Para obtener su valor se divide el valor total de la acción del mercado entre el valor contable de la acción, si la razón indica ser mayor a uno se considera que el activo está sobrevalorado, caso contrario se considera al activo infravalorado. A pesar de que es una herramienta útil de evaluación, no debe usarse de forma aislada.

En Kerst (2018), se establece que la capacidad de una empresa para generar valor está impulsada por el crecimiento de su flujo de fondos a lo largo del tiempo y la rentabilidad que obtiene de su capital invertido en relación con su costo de capital, y a su

vez la rentabilidad que obtiene la misma sobre su capital invertido está determinada por el valor de la productividad marginal del capital. Finalmente, la Q de Tobin muestra diferencias significativas entre sectores especialmente entre sectores de industrias intensivas en capital y servicios.

1.1.2 *Análisis DuPont*

“El modelo DuPont se emplea para examinar los estados financieros de las empresas y valorar su eficacia en la utilización de recursos, mediante dos indicadores de rentabilidad: el retorno sobre los activos (ROA) y el retorno sobre el patrimonio (ROE), utilizando el concepto de apalancamiento. Una de las principales ventajas del modelo DuPont es su capacidad para desglosar los componentes que contribuyen al crecimiento económico de una empresa desde tres perspectivas: la eficiencia en el uso de los activos, la eficacia operativa y el apalancamiento financiero” García, 2014.

En Rosa & Caio (2011) se estudió la descomposición del indicador de rentabilidad financiera (ROE por sus siglas en inglés) de las empresas listadas en la bolsa de valores de Sao Paulo para el periodo 1995-2008, para lo cual llevaron a cabo dos modelos Dupont, esto con el objetivo de determinar cuál de éstos explica mejor el comportamiento de las acciones de las empresas que cotizan en bolsa, en sus conclusiones mencionan que los modelos Dupont son una buena herramienta que exponen de manera efectiva la generación de valor de las acciones en tanto que el modificado explica los rendimientos de las acciones de manera precisa dado que separa los resultados operacionales de los resultados financieros de la organización.

1.1.3 *Componentes Principales*

Se desarrolla en 1901 pero tuvo un auge mayor con la llegada de las computadoras, permitiendo cálculos multivariantes a escala. En IBM (2025) establecen que análisis de componentes principales reduce el número de dimensiones de grandes conjuntos de datos a componentes principales que conservan la mayor parte de la información original. Esto se logra transformando variables potencialmente correlacionadas en un conjunto más pequeño de variables, llamadas componentes principales.

Austria (2007) define al ACP como un método multivariante de simplificación o reducción de la dimensión de un número de variables originales cuantitativas para obtener un número menor de variables, combinación lineal de las originales que se conocerán como componentes principales, así mismo realiza una investigación donde los factores hicieron posible un análisis de desempeño financiero mucho más sencillo e integral de todas las variables empleadas en su muestra, pues cuando están altamente correlacionadas, el componente subyacente es factible de ser interpretado a través de unos cuantos componentes principales, para su obtención se cuenta con una muestra de tamaño n con p variables las cuales se supone están correlacionadas.

1.1.4 Análisis Discriminante Múltiple

En Hernández (2014) se estudia el ADM aplicado en el estudio de las posibilidades de quiebra de una compañía para clasificar una observación dentro de una de diversas agrupaciones a priori que depende de las características individuales de la observación, se establecen clasificaciones de grupo donde el número de grupos pueden ser dos o más, dado que el número de grupos excede los dos se establecen los grupos y se recolectan los datos para los objetos en los grupos, razón por la cual muchos analistas se refieren a la técnica de análisis discriminante como “múltiple”.

“Entre las ventajas de esta técnica estadística se encuentra que considera el perfil completo de los estados financieros y la interacción entre estas. Adicionalmente se tiene como facilidad la reducción del número de variables determinadas a priori dependiendo de las correlaciones resultantes del modelo. En el ADM las variables independientes del modelo corresponden a los valores financieros reales, por lo que al analizar la lista de ratios financieros el modelo podría descartar las variables que no presenten mayor importancia dada la correlación o colinealidad entre sí, motivo por el que la ecuación resultante suele ser simplificada y sus variables de un mayor potencial explicativo.” Martin (2018).

1.1.5 CAMEL

Es una metodología utilizada para evaluar la solidez financiera de instituciones bancarias analizando cinco componentes: Capital, Activos, Manejo, Rentabilidad y

Liquidez. Las autoras Calahorrano, et al 23 comentan en su investigación que el método CAMEL se basa en el cálculo de ratios financieros a partir de extractos de cuentas bancarias y su principal ventaja es que es un método rápido y menos costoso. En su investigación, buscan una comparación entre diversos bancos del Ecuador sometiéndolos al método CAMEL para evaluar sus respectivos riesgos en un periodo de cinco años, en cada componente de la metodología para determinar los mejores y peores bancos, los bancos evaluados son calificados en una escala de 1 (mejor calificación) a 5 (peor calificación); concluyendo que el modelo es eficaz para evaluar la salud financiera de las instituciones y permitir identificar riesgos estructurales y operativos.

1.1.6 Rentabilidad

“La rentabilidad de una empresa es una medida clave para evaluar su eficiencia y la administración de su dinero. Una empresa se considera rentable cuando sus ingresos superan sus costos y gastos, lo que le permite obtener ganancias consistentes a lo largo del tiempo” BBVA, s.f

Así mismo, Díaz Mondragón (2014) comenta que “No siempre la rentabilidad es el objetivo general de la empresa, debido a la posible existencia de pagos futuros por la naturaleza de la empresa” Así, la rentabilidad se vuelve un tema constante en las empresas cotizantes en las bolsas de valores alrededor del mundo

1.1.7 Cotizaciones

También llamados tipos de cambio “se expresan no solo como una cantidad numérica, sino también a través de una serie de símbolos que permiten su identificación en los distintos sistemas electrónicos que sirven como plataforma para su negociación diaria [...] la cotización directa es la expresión de cuanta moneda nacional se da o recibe por una moneda extranjera” (Díaz Mondragón, 2014).

Algunos autores determinan las rentabilidades de mercados de capital apoyándose en las técnicas de RNA para la predicción de cotizaciones, como Ruiz Y Jiménez (2020)

1.1.8 Inflación

La inflación se trata del incremento generalizado de los precios en la economía de una nación, a medida que estos precios aumentan, el valor del dinero disminuye; Mishkin (2014) comenta que un aumento continuo en la oferta monetaria podría ser un factor importante para provocar la inflación, por ello este problema se considera de alta importancia para los países. Díaz Mondragón (2014) menciona que los efectos negativos de la inflación pueden ser englobarlos en dos: obligar a las autoridades monetarias a reducir la oferta y subir las tasas de interés y deteriorar las expectativas de crecimiento económico, generando un desaliento en las inversiones financieras.

Aristizábal, M. (2006) exploró la relación no lineal entre el dinero y la inflación en Colombia a través de una red neuronal, su artículo incorporó algunas innovaciones en la modelación del dinero e inflación que permiten generar pronósticos más confiables; en sus resultados encontró un buen desempeño de la RNA y su factibilidad para memorizar el comportamiento no lineal de las variables.

1.1.9 Rendimiento

Lara Haro (2019) menciona que el rendimiento de un activo o un portafolio es el cambio de valor que registra en un tiempo determinado con respecto a su valor inicial. De igual forma, Mishkin (2014) hace referencia de que el rendimiento sobre un activo mide cuanto se gana por poseer dicho activo.

Díaz Mata (2013) comenta que las tres formas en las que se obtiene rendimiento sobre las inversiones bursátiles son el interés, los dividendos y las ganancias de capital. El interés es el pago que se pacta por el capital ajeno; los dividendos son las utilidades que obtienen las empresas y que reparten entre sus accionistas y finalmente se obtienen las ganancias de capital cuando se venden títulos a un precio superior al que se paga en el momento de comprarlos, siendo esta la opción más común de obtener ganancias en la bolsa de valores.

“En el caso de los bonos, la forma más común de calcular sus tasas de interés es conocida como rendimiento al vencimiento que se trata de la tasa de interés que iguala el

valor presente de los pagos de flujo de efectivo recibidos de un instrumento de deuda con su valor actual”. (Mishkin, 2014).

En el artículo de los autores Johnson & Padilla (2005) se mencionó la importancia actual de las RNA como instrumento para modelar y predecir rendimientos accionarios, puesto que los modelos incorporan variables no lineales en sus estudios, en su trabajo buscan las regularidades no lineales en diversos índices accionarios con el uso de RNA. Se demostró un mejor ajuste en los modelos generados por RNA que los generados con técnicas convencionales como las series de tiempo.

1.1.10 Series de Tiempo

Ordenar información con base en su temporalidad es algo muy común y útil, aplicable en una gran diversidad de áreas y enfoques, a este arreglo secuenciado se le conoce como series de tiempo, pues como lo mencionan Kirchgässner et al (2007): Una serie temporal se define como un conjunto de observaciones cuantitativas organizadas en orden cronológico. Además, Cryer & Chan (2008) establecen como propósito de las series de tiempo que;

El propósito del análisis de series temporales es generalmente doble: comprender o modelar el mecanismo estocástico que da lugar a una serie observada y predecir o pronosticar los valores futuros de una serie basándose en su historial y, posiblemente, en otras series o factores relacionados.

1.2 Marco Referencial

En el apartado referencial se congregan diversas investigaciones de diferentes alcances académicos, con distintos autores y de procedencias diversas, con la característica de sustentar aplicaciones similares en diversos contextos de la metodología referenciada sobre el análisis de desempeño financiero.

El artículo escrito por Ruiz y Jiménez (2000) se enfocó en el análisis de rentabilidades del mercado de capitales español, apoyándose en la técnica de RNA para la predicción de cotizaciones. La investigación usó el índice español IBEX-35 de los años 1995-1998 y sus diferentes variables como índices de cierre, cotizaciones respecto a divisas, índice de

fuerza relativa, entre otras. Esta investigación se apoyó en los trabajos para encontrar las peculiaridades más habitualmente repetidas en los modelos neuronales financieros de White (1988), Tsiburis y Zeidenberg y Bosarge, Jr. (1991), autores como Kryzanowski, Galler y Wright (1993), Baestaens y Van den Bergh, Steiner y Wittkemper, así como Yoon y Swales (1991), Kimoto, Asakawa, Yoda y Takeoka (1990) Sharda y Patil (1992), y Jhee y Shaw; y trabajos sobre los mercados financieros primarios y derivados en Jain y Nag, y Trippi y DeSieno (1992).

Los autores pretendieron en su estudio determinar la rentabilidad del mercado de capitales mediante la técnica de RNA, para poder predecir siguientes periodos verificando con los datos observados. Su trabajo tuvo un carácter ejemplificativo, plantearon de forma práctica como se realiza el diseño, en todas las etapas de una predicción financiera mediante redes neuronales y los resultados obtenidos. Se trató de un estudio longitudinal ya que fue en periodo de 1995 a 1998 de forma diaria; fue multivariado dado que aplicaron diferentes ratios financieros como variables independientes, siendo estos: la cotización de cierre del Bono Nacional a 10 años del mercado de Deuda Pública Español, la cotización de cierre al contado del tipo de cambio euro/dólar, la cotización de cierre del día anterior al cierre del IBEX del índice norteamericano Dow-Jones, entre otros. Como salida e hipótesis del sistema se consideró de primera instancia la cotización de cierre del IBEX-35, para luego modificarse por la estimación de la rentabilidad. El período de entrenamiento fue de dos años, desde 01-1-1995 hasta 31-12-1996; así como un período de prueba de la misma duración, desde 01-1-1997 hasta 31-12-1998. En cuanto a la arquitectura del modelo, los autores utilizaron una red neuronal de perceptrón multicapa con regla de entrenamiento de retro propagación de errores. Con una capa oculta de ocho o hasta 15 neuronas. Los pesos se inicializaron en torno al 0,3 – 0,6 y los ratios de aprendizaje se situaron en 1,5 en la capa oculta y 0,01 en la de salida. Esta técnica fue desarrollada por el Software *ThinsPro Neural Network for Windows Special Edition Versión 1.00*. Al desarrollar la técnica ya mencionada, los autores consideraron que los resultados no surtieron frutos satisfactorios, comentaron que el error en la base de entrenamiento es demasiado amplio e incluso después de modificar entradas, funciones de transferencia e incluso el algoritmo, los errores seguían siendo altos. Ruiz y Jiménez (2000) concluyeron que este tipo de técnicas pueden ser aplicables a muchos campos científicos, sin embargo,

no proporcionan buenos resultados de forma directa en el ámbito de su estudio y con las variables de estudio particular.

Del Carpio (2005) muestra de forma sencilla el cómo las RNA pueden aplicarse a las áreas financieras, particularmente en las predicciones de variables económicas, esto de forma general identificando las variables a pronosticar, obteniendo los datos, creando el aprendizaje y generando los modelos de RNA. El autor obtuvo que la mayoría de los temas relacionados tienen que ver con la predicción de quiebra o la predicción de rendimientos de valores, que ayuden a tomar mejores decisiones financieras. Asimismo, las Redes Neuronales pueden emplearse como herramientas complementarias a los enfoques tradicionales de análisis multivariante. Su trabajo trató sobre una recopilación de la técnica correcta a emplear para llegar a buenos resultados, así como una revisión de literatura en cuanto a predicciones y el uso de las RNA como herramientas complementarias a los enfoques tradicionales del análisis multivariante.

En el artículo de los autores Johnson & Padilla (2005) se mencionó la importancia actual de las RNA como instrumento para modelar y predecir rendimientos accionarios, puesto que los modelos incorporan variables no lineales en sus estudios, en su trabajo buscan las regularidades no lineales en diversos índices accionarios con el uso de RNA. Este estudio intenta encontrar regularidades en los índices accionarios de 27 países mediante un acercamiento de redes neuronales artificiales y su contraste con modelos lineales rezagados. Su investigación tiene menciones a autores como Johnson y Soriano (2004); Zekic, (1998); Trippi y De Sieno, (1992); Tkacz y Hu (1999). Hop field (1982), entre otros, que mencionan el alcance de las redes neuronales desde lo general a las áreas particulares de las finanzas y bursátil. El propósito de la investigación fue encontrar regularidades en los diferentes índices accionarios. Para este trabajo, de corte longitudinal, los datos utilizados provienen de los diversos índices de 27 países del mundo. La frecuencia de los datos es diaria, con un horizonte temporal desde enero de 1990 a finales de enero de 2004. Se realizaron predicciones extra muestrales dinámicas sustentadas también con una prueba no paramétrica, entre las dinámicas estadísticas de las que se hace uso estuvieron la desviación estándar, la curtosis y la prueba de Jarque Bera. Para la red, los autores propusieron un modelo de tipo *feedforward* con una capa oculta, y dos neuronas, su función de activación estuvo dada de la forma funcional logística. El modelo

también empleó rezagos con el propósito de observar el comportamiento al ser incluidas. Finalmente, se estiman modelos lineales regresivos (Box-Jenkins) para comparar con los modelos de RNA con un modelo ARIMA. Las variables mostraron un alto valor en la curtosis, así mismo la mitad de los datos presentó un valor negativo en el sesgo (indicando una larga cola hacia la izquierda), y en la prueba de Jarque-Bera se indicó que no hubo evidencia para aceptar el supuesto de normalidad de los rendimientos. Los criterios Akaike y r cuadrado comprobaron la eficacia de la red neuronal aplicada, mostrando un alto rendimiento en los índices pues todos entran en un rango del 64% y hasta el 90%. Así mismo, el uso de rezagos demostró una mejoría en la modelización de las RNA de índices accionarios; en cuanto a los resultados que se obtuvieron por medio del modelo ARIMA se observó un menor ajuste. Finalmente, las pruebas Pesaran y Timmermann, rechazaron la hipótesis de que las variables reales y sus respectivas predicciones son independientemente distribuidas, que obtenidas en los estadísticos y sus valores p de probabilidad son superiores en las redes que los modelos ARIMA generalmente. Los autores coincidieron con los autores mencionados, pues se concluye que los modelos y sus resultados obtenidos por medio de RNA son eficientes e incluso mejores a los obtenidos con otras técnicas, finalmente concluyeron que las redes neuronales tienen ventajas en relación con los métodos de análisis tradicionales y plantearon que las redes neuronales pueden ampliarse a efectos causados por crisis financieras económicas globales.

García (2002), desarrolló una red neuronal para generar un algoritmo que calcule el precio de una opción de compra de una compañía telefónica utilizando datos históricos del mercado. Se trató de una investigación longitudinal y multivariada, sus variables independientes fueron el precio de cierre telefónico, precio del ejercicio, volumen, open interés, entre otros. Los datos provinieron de la MEFF y los ficheros históricos de la bolsa de Madrid, mientras que la variable objetivo son las primas de las opciones de compra sobre la telefónica. La periodicidad de los datos abarcó desde el 3 de enero de 2000 hasta el 30 de junio del mismo año y finalmente el número de datos utilizados fue de 16,688. La arquitectura que se utilizó en la red neuronal fue de seis neuronas de entrada, cuatro capas ocultas y una de salida, siendo la función de activación de tipo tangente sigmoide, y el algoritmo de aprendizaje Levenberg – Marquardt con parada temprana. El software en el

que se llevó a cabo la investigación fue MatLab. García (2002) mencionó que la red neuronal supervisada fue capaz de calcular los precios con una precisión muy acertada. También comentó que la red neuronal consigue encontrar, si existe, la relación no lineal que existe entre conjuntos de datos, por ello, los analistas pueden utilizarla para encontrar relaciones no estudiadas y realizar predicciones alternativas a las del mercado. Finalmente, en sus resultados concluye que las redes neuronales bien aplicadas resultan útiles para el desarrollo de diversas técnicas, en su trabajo, se hizo uso de redes neuronales supervisadas.

Díaz H., et al (2017) construyeron un artículo enfocado en las microempresas mexicanas y su impacto en la adopción de prácticas administrativas sobre el desempeño financiero, realizaron dos análisis, uno econométrico y el otro con RNA utilizando datos de la encuesta Business Practices in Small Firms in Developing Countries del Banco Mundial, 2008-2014. Diversos autores como Álvarez, Carrasco y Córdova 2016; Barrera, Acosta, Armenteros, entre otros, han analizado el papel que tiene la adopción de prácticas administrativas en el desempeño de empresas de gran magnitud, mientras que poco se ha estudiado del mismo tema en microempresas y economías emergentes. El objetivo de la investigación radicó en analizar si algunas prácticas y variables como fueron la planeación financiera, acervo de capital, mercadotecnia, control de compras e inventarios, registro de costos y mantenimiento y la edad y educación del dueño tenían un papel determinante en el desempeño de las empresas micro. La información empleada consistió en microdatos obtenidos de la encuesta Business Practices in Small Firms in Developing Countries, desarrollada por el Banco Mundial entre los años 2008-2014 para México.

Se reunió información de variables de edad y años de educación del dueño, antigüedad de la empresa, stock de capital, beneficios brutos, ingresos, valor de inventarios, adopción de prácticas de marketing, control de compras e inventarios, registro de costos y mantenimiento y planeación financiera, entre otras, empleándose 7690 observaciones. En la aplicación fueron usadas tanto técnicas econométricas (Modelo de regresión con datos de sección cruzada) como de redes neuronales artificiales. La hipótesis para comprobarse planteó que la adopción de cierto tipo de prácticas administrativas jugaba un papel relevante para entender el desempeño financiero de este segmento de empresas pertenecientes a economías en desarrollo.

Los autores mencionan que en el análisis econométrico las variables como edad, antigüedad de la empresa son significativas, así mismo, la variable más importante para explicar el comportamiento de las ventas es la adopción de prácticas de planeación financiera. Posteriormente el tipo de RNA utilizado fue un perceptrón multicapa; la capa de entrada recibe información de las variables o factores de edad del dueño, años de educación del dueño, la antigüedad de la empresa, el stock de capital, y el grado de adopción de 4 prácticas administrativas (marketing, control de compras e inventarios, registro de costos y mantenimiento y planeación financiera). El análisis de la muestra de reserva indica que los resultados de la RNA son sólidos para estimar el comportamiento de las ventas mensuales. Los resultados obtenidos coinciden, en cierto sentido, con los obtenidos por Fajnzylber, Maloney y Montes-Rojas (2009) ya que, para que las actividades que dichos autores señalaron (participación en el mercado crediticio, pago de impuestos, acceso a capacitación y pertenencia a asociaciones de negocios) se puedan llevar a cabo, es necesario contar con ciertas prácticas al interior de las organizaciones.

Así mismo, los resultados contribuyen en aspectos clave de desempeño financiero en micro organizaciones mexicanas. Finalmente, los autores mencionaron que las futuras investigaciones pueden incluir el estudio del desempeño financiero de microempresas de otros países con fines comparativos y estudiar diferencias o similitudes que hay entre los aspectos que detonan el desempeño de dichas organizaciones de acuerdo con el sector que pertenecen.

Cabrera, A. & Ortiz, F. (2011) mostraron una investigación de aplicación de redes neuronales artificiales diferenciales para pronosticar el rendimiento del IPC, recopilando información de la bolsa mexicana de valores. Los autores hablaron de como los mercados financieros son afectados por factores económicos, sociales, políticos, etc. haciéndolos difíciles y complejos de modelar. En cuanto a los autores mencionados rescataron a Ritchie (2006), Hantias, Curtis y Thalassinios (2007) en el mercado de valores de Grecia, Mehara, Moeni, Ahrari y Ghafari (2010) en Irán. El artículo presenta dos técnicas; un modelo de identificación y un pronóstico intradía del rendimiento del IPC de la bolsa Mexicana de Valores. De este que la investigación haya sido longitudinal, tomando datos del sistema de identificación del 8 de noviembre de 1991 al 27 de enero de 2011, generando así una RNA. Por otro lado, para el pronóstico intradía se obtuvieron 6 valores

del rendimiento del IPC a lo largo de un día posterior al último día que se tuvieron datos en la serie de tiempo del IPC. Siendo entonces un análisis multivariante, por otro lado, la paquetería usada fueron los programas *MATLAB* y su *ToolBox simulink* con el algoritmo *Dormand Price*.

Los autores mencionan para sus resultados que la red neuronal produjo una buena aproximación a los valores de rendimiento reales del IPC, incluso aproximando muy parecidamente los cambios súbitos del comportamiento del rendimiento real. De igual manera en el análisis de intradía las diferencias entre los valores pronosticados y reales fueron mínimas. Los autores concluyen que los resultados obtenidos con su herramienta presentan mayor precisión que los reportados por Hantias, Curtis y Thalassinis (2007) en el mercado de valores de Grecia, quienes ocuparon un sistema de aprendizaje *backpropagation* y mejor que los obtenidos por Mehara, Moeni, Ahrari y Ghafari (2010) para el respectivo mercado de valores de Irán. Finalmente, los autores concluyen un buen desempeño en su sistema de identificación de RND, lo que los llevó a considerar esta herramienta como una nueva, viable útil y robusta para la descripción de variables financieras con un error de aproximación mejorado.

Los autores Ortiz, & López (2013) presentaron en su artículo los resultados del diseño y programación de una red neuronal diferencial, aplicada en primer lugar, a la identificación del comportamiento del índice del mercado bursátil alemán Deutscher Aktienindex (DAX) y el indicador estadounidense Standard and Poor's 500 (S&P 500). Posteriormente, dicha red se utilizó para efectuar pronósticos de los valores de ambos indicadores bursátiles para un horizonte temporal de cuatro semanas de operación posteriores a la etapa de identificación de la red. Los autores mencionaron un gran compendio de trabajos de investigación donde se utilizaron redes neuronales artificiales de tipo discreto, y recordando que los resultados arrojados por esas técnicas pueden mejorarse, dichas mejoras pueden ser hechas con redes neuronales diferenciales o dinámicas de tipo continuo. Mediante el uso de una RND se logró identificar el comportamiento de las series de los valores diarios de cierre de los índices accionarios DAX, así como del S&P 500 a lo largo del periodo comprendido entre el 3 de julio de 2000 y el 13 de enero de 2012. También se consideró un periodo de entrenamiento o aprendizaje de la red neuronal de seis meses: del 3 de enero de 2000 al 30 de junio de 2000. El sistema de ecuaciones

diferenciales no lineales, así como el conjunto de restricciones se programaron en la plataforma de *Matlab-Simulink*. La red neuronal diferencial empleada para la estimación de los estados sobre el sistema dinámico no lineal fue del tipo Hopfield, el programa de cómputo de la RND llevó a cabo el proceso de seguimiento de los valores de ambas series durante el periodo del 3 de julio de 2000 al 13 de enero de 2012. Posteriormente se reinició el programa de cómputo de la RND en Matlab y se llevó a cabo el proceso de pronóstico de los valores de cierre diario de los índices DAX y S&P 500 en cuatro grupos, cada uno con cinco días y que comprendió el periodo de cuatro semanas que van del 16 de enero al 10 de febrero de 2012. Los valores obtenidos con la RND fueron sumamente aproximados a los valores reales de la serie, y las pequeñas discrepancias fueron muy poco observables. En cuanto a los resultados proporcionados por la segunda parte del trabajo, es decir el pronóstico de valores de cierre diario de los índices DAX y S&P 500 fueron satisfactorios con errores porcentuales que oscilaban entre 0.15% y 2.37%. Los autores estuvieron de acuerdo en que las redes neuronales diferenciadas arrojan mejores resultados para el comportamiento de valores de índices bursátiles, así mismo este estudio contribuyó también a la literatura del análisis bursátil porque extendió la aplicación de las redes neuronales diferenciales al caso de los pronósticos de los valores de los índices de mercados bursátiles desarrollados.

Villamil, J. (2009), entregó un artículo donde se usaron las redes neuronales multicapa con el fin de aproximar la no linealidad en el modelo de Dornbusch (1972) propuesta por De Grauwe y Dewachter (1993). El autor construyó una muestra de 78 observaciones en frecuencia trimestral del tipo de cambio USD/COP, de los medios de pago, del producto interno bruto (desestacionalizado) y del índice de precios al consumidor (IPC) con base en 1998, desde el cuarto trimestre de 1986 hasta el primer trimestre de 2006. Se reservó el 70 % de los datos de la muestra para el ajuste de los modelos y las cifras restantes se emplean en su validación. El autor mencionó que con los datos de prueba la red entrenada por BP sigue “más de cerca” el comportamiento del USD/COP que el modelo DD y la red con función de pérdida asimétrica entrenada por chemotaxis. Se pudo afirmar, por lo menos en este caso, que optimizar la red con una función de pérdida que “castigue” las sub-predicciones no garantiza que, con datos que nunca fueron presentados a la red, surja este tipo de pronóstico. Con los parámetros se mostró que la especulación tiene una

incidencia un poco mayor sobre la tasa de cambio que la política monetaria y que la actividad de los especuladores que siguen el análisis técnico es más importante que la de quienes se guían por los fundamentales. Sin embargo, estas conclusiones son débiles debido a los altos errores de estimación. Finalmente, el autor sugirió las redes multicapa como una metodología de aproximación de formas funcionales no lineales pues goza de la propiedad de “generalización”, es decir, que aprende la relación no lineal que subyace a unas variables explicadas con unas explicativas con base en unos patrones que se le presentan.

Los autores Vicentín, J., & García, R. (2017) hablaron en su artículo sobre la importancia de predicciones sobre precios en las políticas públicas. Su trabajo se vuelve comparativo entre las herramientas de análisis y predicción comunes como lo son las series de tiempo con las RNA. Los autores ocuparon explicaciones sobre cómo obtener precios en sectores agrícolas ganaderos de Heien (1977). Así, los autores ocupan como variables para su estudio los precios mensuales pagados al productor lácteo, los precios mensuales minorista, los precios mensuales mayorista, los precios de exportación, las cantidades producidas mensuales de leche cruda y una indicadora de la estacionalidad alta en los precios al productor. Todas las variables tienen una periodicidad mensual que va desde 2000 a 2012. Los datos recopilados provienen de diferentes fuentes, como lo fueron el Ministerio de Agricultura, Ganadería y Pesca de la Nación Argentina, sección Lechería, así como de la Secretaría de Lechería de la Provincia de Santa Fe y el Instituto de Estadísticas y Censos de la Provincia de Santa Fe. Se estimó una RNA con tres capas, con cuatro nodos de entrada, dos en la oculta y uno sólo en la salida, presentando un algoritmo supervisado de *Backpropagation*. En cuanto a las técnicas usuales, se hizo uso de Modelos de Vectores de Corrección por el Error. El algoritmo de estimación de la red ha convergido bastante rápido (menos de 100 iteraciones) a errores de entrenamiento relativamente cercanos a cero, tanto en el conjunto de entrenamiento como en el de prueba. En promedio, los modelos de vectores tuvieron errores superiores a las predicciones por RNA. De igual manera se encontraron mejores aproximaciones por parte de las RNA con respecto a los precios reales. Los autores concluyen que tener predicciones confiables que permitan tomar decisiones con menor incertidumbre es precisamente muy valorado por parte de los agentes que interactúan en el sector, dado

que permitiría una planificación más seria sobre sus actividades. Finalmente, los autores mencionan la particularidad del caso aplicado, y afirman la importancia de estudiar modelizaciones más complejas y que impliquen proceso de búsquedas y arquitecturas más mecanizadas y que se sometan a procesos de evaluación más severos.

La autora Aristizábal, M (2006) exploró la relación no lineal entre el dinero y la inflación en Colombia a través de una red neuronal, su artículo incorporó algunas innovaciones en la modelación del dinero e inflación que permiten generar pronósticos más confiables, debido a que el modelo se aproxima con mayor exactitud a la realidad. El objetivo de este trabajo fue explorar la relación no lineal entre el dinero y la inflación en Colombia a través de una red neuronal artificial, utilizando información mensual de la variación del índice de Precios al Consumidor (IPC) y del agregado monetario M3, desde enero de 1982 hasta febrero de 2005. Como variables explicativas se consideraron dieciocho rezagos de la variable endógena, así como igual número de rezagos de la variable exógena M3, definida también como la primera diferencia del logaritmo de esta serie, se contó con información completa a partir de agosto de 1983, punto en el cual empezaría la base de datos de entrenamiento de la red neuronal. Dando un total de 241 observaciones y siendo una investigación de tipo longitudinal y multivariada.

Particularmente, la elección del conjunto de inputs para esta red es el resultado de la intersección de una serie de búsquedas que trae programadas SAS, como stepwise selección, forward entry o backward removal, que hacen uso de distintos criterios tales como el R cuadrado más alto, el R cuadrado ajustado o el estadístico de Mallow. En cuanto a los programas utilizados, se hizo primero la elección del mejor conjunto de variables explicativas. Se observó que aquellas redes cuyo desempeño era el mejor dentro de muestra presentaban un número elevado de unidades escondidas y, en consecuencia, una gran flexibilidad que les permitía capturar y memorizar perfectamente el comportamiento no lineal de la serie bajo estudio, pero les impedía predecir su comportamiento futuro.

Ortiz, F. (2017) en su artículo mostró las ventajas de las RND como un método alternativo eficiente en el cálculo de pronósticos de precios futuros de activos financieros. El artículo ocupa tanto modelos GARCH en comparación con los modelos de RNA

diferenciadas. Se hizo un comparativo con modelos de la familia GARCH, al llevar a cabo el pronóstico de precios de cierre de barriles de petróleo crudo de los tipos West Texas International y Brent. del 2 de enero de 2013 al 24 de febrero de 2015, y del periodo de pronóstico, del 25 de febrero al 10 de marzo de 2015. Para la serie WTI un modelo GARCH (1,1) y para la serie Brent lo más conveniente era emplear un modelo T-GARCH (1,1) (Threshold GARCH). El autor menciona que los resultados obtenidos a través de las RND y los modelos autorregresivos fueron equivalentes, sin embargo, hizo hincapié en la sencillez de obtención con la técnica de RND.

1.3 Conclusiones del Capítulo

Tras el análisis del marco teórico se puede encontrar un amplio panorama de información en las áreas financieras y su interconexión, y diversas técnicas que ayudan medir la generación de valor desde distintos enfoques y para distintas aplicaciones.

Así mismo, el marco referencial muestra las distintas aplicaciones y combinaciones que pueden ocurrir con las redes neuronales para los cálculos de rendimientos accionarios, y desempeño financiero en diversos sectores de la economía, mostrando que pueden ser aplicadas técnicas lineales y no lineales a partir de información financiera empresarial con el propósito de generar valor. Apoyando a las empresas y organizaciones en la constante búsqueda de estrategias que generen mejores decisiones financieras y administrativas de acuerdo con sus políticas y objetivos.

En conclusión, este capítulo muestra la gran área de oportunidad que se tiene para emplear las diversas técnicas de las Redes Neuronales Artificiales con resultados favorables y concisos en la medición del desempeño financiero, proporcionando herramientas para una efectiva toma de decisiones y mitigando la incertidumbre en diversas áreas empresariales.

Capítulo II: Marco contextual

Introducción

En el presente capítulo se abordan las bases conceptuales de la investigación, se presenta el desempeño financiero como núcleo para la generación de valor, se aborda la formación del mercado de capitales que hace posible la existencia de la cotización de emisoras en el país y sus implicaciones como conjunto para la economía nacional.

Así mismo, se establecen las razones financieras y su importancia para la generación de valor, se describe la participación de fenómenos intrínsecos a la que están sujetas las empresas como lo es el ciclo económico.

2.1 Desempeño Financiero

Con los diversos eventos que han ocurrido en el mundo financiero a nivel global como recesiones y crisis, las dificultades para leer los mercados y anteponerse a nuevos efectos se vuelven más cada vez más relevantes, sin embargo, los desempeños financieros bien interpretados prevén una herramienta para anteponerse a crisis que pueden llevar a la quiebra de las empresas, en este sentido, García & Morales (2014) comentan que “el desempeño financiero, desde el enfoque de quiebras empresariales no es un evento inmediato, sino más bien un proceso que evoluciona a lo largo del tiempo, lo que proporciona una base para los intentos de predecir estas quiebras”.

Por su parte, Espinosa, (2024). menciona que: “El desempeño financiero está compuesto por las metodologías utilizadas para disminuir costos e implementar las estrategias que buscan una mejora financiera a través de la planificación”

Así, se puede encontrar que el desempeño financiero es el valor de la salud económica de una empresa, pone atención a las ganancias económicas, pero también a la gestión de recursos para completar sus objetivos. Según Marcillo-Cedeño et al. (2021), es una herramienta gerencial crítica que permite detectar dificultades y aplicar correcciones oportunas.

2.1.1 Objetivos y alcances

Marcillo et al (2021) afirman que los análisis financieros son considerados una pieza fundamental para poder detectar la situación, así como el desempeño tanto económico como el financiero que tiene toda organización, por medio del cual se podrán detectar las dificultades y luego poder realizar las correcciones necesarias. El análisis financiero proporciona información clave para decisiones de inversión, financiamiento y operación. Así mismo rescatan que los objetivos que tienen los análisis financieros se encuentran encaminados en poder analizar cuáles serán las tendencias de variables financieras que se involucran en operaciones de empresas.

“El desempeño financiero de las organizaciones puede ser entendido como una mejora en el valor de los indicadores asociados a elementos que se evalúan periódicamente en la información financiera de las organizaciones en contraste a un periodo anterior.” (Rehman, 2013).

Espinosa, (2024) comenta que el desempeño financiero se utiliza para describir las metodologías y los procesos que ayudan a administrar el éxito de una organización, es importante para todas las empresas, pero especialmente para aquellas que buscan reducir los costos, actualizar sus estrategias organizacionales o mejorar su proceso de planificación financiera.

Neely et. al. (2005) mencionan que la medición del desempeño se da cuando se intenta cuantificar la eficiencia y la eficacia que tienen los procedimientos organizacionales, es decir que la medición del desempeño busca conocer en números cuanta eficiencia y eficacia tiene cada uno de los procesos de la organización.

Finalmente, Montenegro (2004) señala que la medición del desempeño es una actividad donde se determinan las medidas de desempeño necesarias para mejorar, ajustar o regular alguna actividad.

2.2 Estados Financieros

Marcillo et al (2021) comenta que a los indicadores financieros se lo reconocen como un procedimiento para realizar una evaluación de las finanzas, lo cual consiste en relacionar o combinar elementos que puedan representar los datos que son inscritos en

los estados financieros, teniendo objetivo de poder obtener resultados los cuales permitan relacionarse sobre los aspectos que se caracterizan con esta relación.

BBVA México, (2025) Clasifica los estados financieros como herramientas que proporcionan una visión clara y estructurada de la situación económica de una empresa, que permiten evaluar la salud financiera de una organización. Tienen como objetivo evaluar la rentabilidad y la solvencia de una organización, tomar decisiones de inversión y planificar estrategias financieras. La interpretación de los estados financieros es clave para la toma de decisiones, entre las herramientas que se pueden usar para ello están el análisis horizontal, vertical o el cálculo de razones financieras.

2.2.1 Activo

Citando a Alcarria (2008, p. 23) “Los activos son el conjunto de bienes, derechos y otros recursos controlados económicamente por la empresa con los que ésta desarrolla su actividad económica. Los activos provienen de transacciones o acontecimientos pasados y pueden ser propiedad de la empresa o simplemente ser controlados por la misma. Además, se requiere que tengan la capacidad de producir futuros ingresos.”

Esto quiere decir que un activo es un título que otorga a su tenedor el derecho a recibir un ingreso futuro del vendedor. Como ultima definición, Farfán y Elio (2018) comentan que los activos representan todos aquellos recursos de los que dispone una entidad para alcanzar sus objetivos a corto, mediano y largo plazo

Ecuación 2.2.1 Activo

$$\text{Activo} = \text{Pasivo} + \text{Patrimonio} \quad (2.1)$$

Alcarria, (2008) la define como “La ecuación fundamental del patrimonio en toda entidad contable se cumple que la suma del valor de sus bienes y derechos activos es igual a la suma del valor de los pasivos y el patrimonio neto”.

El autor también ejemplifica que entre las cuentas contables que pueden considerarse como activos se encuentran terrenos, locales o naves industriales, maquinas

e instalaciones, herramientas y útiles, derechos sobre marcas o patentes, mercancías para venta, inversiones en acciones, dinero en cuentas bancarias, dinero en efectivo, entre otras.

2.2.2 Pasivo

Por otro lado, Bonsón, Cortijo & Flores (2009) establecen que los pasivos son las obligaciones actuales surgidas como consecuencia de sucesos pasados, para cuya extinción la empresa espera desprenderse de recursos que puedan producir beneficios o rendimientos económicos en el futuro. Dentro de estos pasivos se incluyen también las provisiones.

Alcarria (2008) agrega que los pasivos derivan de cualquier transacción o hecho pasado que genere una segura o posible deuda que en un futuro puedan originar la entrega de activos para su cancelación. En el pasivo se incluyen los fondos con los que la empresa adquiere los diversos elementos que configuran su activo, razón por la que también se denomina estructura financiera.

2.2.3 Estado de Resultados

BBVA, (2025) establece que el estado de resultados, o estado de pérdidas y ganancias, refleja el desempeño financiero de la empresa durante un período determinado, siendo fundamental para medir la rentabilidad y eficiencia operativa de la empresa. Incluye:

- Ingresos: Dinero obtenido por ventas de productos o servicios.
- Gastos: Costos incurridos en la operación, como salarios, rentas y suministros.
- Utilidad o pérdida neta: Resultado de restar los gastos de los ingresos, indicando si hubo ganancias o pérdidas en el período analizado.

2.2.4 Flujo de Caja

Espinosa, (2024) comenta que el flujo de caja es un informe financiero que muestra las entradas y salidas de dinero en una empresa dentro de un período de tiempo. La diferencia entre los ingresos y egresos entrega un saldo, que permite conocer la liquidez

de la compañía, el flujo de fondos está compuesto por los movimientos de dinero entre la empresa y sus clientes, proveedores, personal y el estado. Cuando es positivo, indica que la organización es solvente, si por el contrario es negativo. Indica que la empresa tiene problemas para cubrir sus obligaciones.

2.3 Razones Financieras

Como se mencionó, el análisis de información financiera y contable resulta importante para cualquier empresa que busque la generación de valor, generación de utilidades y una toma de decisiones efectiva, pues como lo menciona Rivera, (2022) “La mayoría de las decisiones empresariales se miden en términos financieros; por lo tanto, el personal de todas las áreas de responsabilidad como son: contabilidad, sistemas de información, administración, marketing y operaciones deben tener un conocimiento básico de la función de administración financiera, que les permita cuantificar las consecuencias de sus acciones.” Entre las herramientas más usuales para este análisis están el cálculo de razones financieras. Entender el cálculo, uso y funciones de las razones financieras resulta de vital importancia para esta investigación.

En ese sentido, Robles, (2012) menciona que el método consiste en analizar a los dos estados financieros, es decir, al balance general y al estado de resultados, mediante la combinación entre las partidas de un estado financiero o de ambos. Por su parte, Ibarra, (2006) comenta que su fundamento se refiere a que dos datos aislados que tienen cada uno valor en sí mismo, adquieren frecuentemente una información financiera aún mayor cuando se les combina en un coeficiente.

En su clasificación general, Robles, (2012) comenta que las razones financieras donde se combinan únicamente partidas del balance general se denominan estáticas ya que están a una fecha determinada; cuando se trata de partidas del estado de resultados son llamadas dinámicas ya que corresponden a un periodo determinado; y cuando se combinan las partidas de los dos estados financieros se denominan estático-dinámicas. Finalmente, las razones financieras cumplen con los objetivos de estudiar cuatro indicadores de suma importancia para una empresa: liquidez, solvencia, actividad, endeudamiento y rentabilidad.

2.3.1 Razones de Liquidez

Son los indicadores que permiten identificar el grado de liquidez con el que cuenta una empresa, a corto plazo. Robles, (2012). Es decir, la empresa genera fondos suficientes para hacer frente al pago tal como haya sido acordado por terceros, y en el tiempo pactado. Una empresa logra cubrir sus deudas transformando sus activos corrientes en efectivo, es decir cuentas por cobrar, dinero disponible en bancos, mercancías para la venta, etc. Las razones de liquidez están relacionadas con el monto, activos y pasivos circulantes. La tabla 2-1 muestra los ratios financieros de liquidez utilizados en la investigación.

Tabla 2-1 Ratios de Liquidez

Tipo de Razón	ID Razón	Indicador Financiero: Relación Contable	Indicador Financiero: Abreviación
Liquidez	Razón 1	Activo circulante / Pasivo Circulante	AC/PC
	Razón 2	Activo Circulante / Activo Total	AC/AT
	Razón 3	Activo Circulante / Pasivo Total	AC/PT
	Razón 4	Efectivo e Inv. Temporales / Activo Total	(Efect. e Inv.) /AT
	Razón 5	(Activo Circulante - Inventarios Circulantes) / Pasivo Total	(AC-Inv) /PT
	Razón 6	Incremento (disminución) neto de efectivo y equivalentes al efectivo / Pasivo Total	VAR FE/PT

Fuente: Elaboración Propia

2.3.2 Razones de Apalancamiento

Este índice muestra en porcentaje la aportación de dinero por personas internas y externas a la empresa, que se utiliza para generar utilidades. Robles, (2012). Como su nombre lo indica, estas razones sirven para conocer los niveles de deuda que una empresa tiene.

“Las razones de apalancamiento, también llamadas razones de solvencia a largo plazo están diseñadas para determinar la capacidad de la organización en satisfacer sus obligaciones largo plazo, esto es, el apalancamiento financiero”. Ross, Westerfield & Jaffe, (2012). En la tabla 2-2 se presentan las razones financieras de apalancamiento usadas en esta investigación.

Tabla 2-2 Ratios de Apalancamiento

Tipo de Razón	ID Razón	Indicador Financiero: Relación Contable	Indicador Financiero: Abreviación
Apalancamiento	Razón 7	Pasivo Total / Activo Total	PT/AT
	Razón 8	Incremento (disminución) neto de efectivo y equivalentes al efectivo antes del efecto de los cambios en la tasa de cambio / Deudas financieras a corto plazo	Intereses pagados/Pasivos con Costo
	Razón 9	Otros cred sin costo CP + (Otros cred. sin costo LP / Pasivo Total)	Pas Mon ext./Pas Total
	Razón 10	Patrimonio Neto Consolidado / Activo Total	CAP CONT/AT
	Razón 11	Pasivo Circulante / Activo Total	PC/AT
	Razón 12	Pasivo Total / Patrimonio Neto Consolidado	PT/CAP CONT
	Razón 13	Ingresos Netos / (Plazo promedio Invent días * 1,000,000)	VN/CAP TRAB

Fuente: Elaboración Propia

2.3.3 Razones de Solvencia

Robles, (2012) comenta que se refieren a la capacidad de pago que tiene la empresa para hacer frente a sus obligaciones. Otra mención interesante es la aportación de Ross, Westerfield & Jaffe, (2012) pues mencionan que “En concordancia con su

nombre, las razones de solvencia a corto plazo, como grupo, tienen la finalidad de proporcionar información sobre la liquidez de una empresa, por lo que algunas veces se denominan medidas de liquidez. El punto de interés principal es la capacidad de la empresa para pagar sus cuentas en el corto plazo sin presiones excesivas. En consecuencia, estas razones se centran en el activo y el pasivo circulantes. Estas razones son principalmente valiosas para los acreedores a corto plazo. En la tabla 2-3 se presentan las razones financieras de solvencia usadas en esta investigación.

Tabla 2-3 Ratios de Solvencia

Tipo de Razón	ID Razón	Indicador Financiero: Relación Contable	Indicador Financiero: Abreviación
Solvencia	Razón 14	Incremento (disminución) neto de efectivo y equivalentes al efectivo antes del efecto de los cambios en la tasa de cambio / Ganancia Bruta	INT PAG/RES OPER
	Razón 15	(Pasivo Total - Pasivo Circulante) / Propiedades, planta y equipo neto + Construcción y obras infs. + Terrenos + Edificios + Maquinaria y Equipo + Vehículos + Buques + Aeronaves + Equipo de Transporte + Construcciones en proceso + Otros equipos	PLP/AF
	Razón 16	Ingresos Netos / Pasivo Total	VN/PT

Fuente: Elaboración Propia

2.3.4 Razones de Actividad

Respecto a las razones de actividad, Morales, (2007) menciona que también se conocen como razones de eficiencia, ciclo o intensidad con que se utilizan los activos y expresan la destreza que emplean o administran los diferentes activos para la obtención de ventas y utilidades de la empresa. Por su parte, Robles, (2012) menciona que estos

índices muestran el tiempo en el que algunas cuentas se convierten en efectivo o se desembolsan.

Las razones de actividad miden entonces que tan eficiente es una empresa para usar sus activos y sus pasivos para generar ventas y administrar recursos de manera eficiente. Entre las más comunes de escuchar están la rotación de inventarios, el periodo medio de cobro, la rotación de activos totales y la rotación de cuentas por pagar. En la tabla 2-4 se presentan las razones financieras de actividad usadas en esta investigación.

Tabla 2-4 Ratios de Actividad

Tipo de Razón	ID Razón	Indicador Financiero: Relación Contable	Indicador Financiero: Abreviación
Actividad	Razón 17	Ingresos Netos / Activo Total	VN/AT
	Razón 18	Ingresos Netos / Propiedades, planta y equipo neto + Construcción y obras infs. + Terrenos + Edificios + Maquinaria y Equipo + Vehículos + Buques + Aeronaves + Equipo de Transporte + Construcciones en proceso + Otros equipos	VN/AF
	Razón 19	Costo de Ventas / Inventarios Circulantes	CV/INVENT
	Razón 20	Cuentas por Cobrar Circulantes / (Ingresos netos/360)	Ctas x Cobr/(VN/360)
	Razón 21	[Cuentas por Cobrar Circulantes / (Ingresos netos/360)]*360	360/Días ventas x cobrar

Fuente: Elaboración Propia

2.3.5 Razones de Rentabilidad

“El índice de rentabilidad es uno entre varios métodos que existen para medir las utilidades de las empresas; este índice se analizará respecto a las ventas, a los activos y a la inversión de los accionistas”. Robles, (2012)

Por su parte, Espinosa, (2024) menciona que las razones de rentabilidad refieren a la capacidad de la entidad para generar utilidades o incremento en sus activos netos de la entidad en relación con sus ingresos, su capital y su patrimonio contables. Finalmente, Morales, (2007) comenta que cuando se mide la rentabilidad de una empresa, se estudian los beneficios producidos por la inversión de la empresa, es decir sus activos. Entre las razones de rentabilidad más comunes que podemos encontrar están el margen de utilidad bruta, el margen de utilidad operativa, el margen operativo, el margen neto y el ROA. En la tabla 2-5 se presentan las razones financieras de rentabilidad usadas en esta investigación.

Tabla 2-5 Ratios de Rentabilidad

Tipo de Razón	ID Razón	Indicador Financiero: Relación Contable	Indicador Financiero: Abreviación
Rentabilidad	Razón 22	Ganancia (pérdida) neta / Ingresos Netos	Resultados Netos/VN
	Razón 23	Ganancia (pérdida) neta / Activo Total	Resultados Netos/AT
	Razón 24	Ganancia (pérdida) neta / Patrimonio Neto Consolidado	RESN/CAPCONT
	Razón 25	Ganancia (pérdida) neta / Propiedades, planta y equipo neto + Construcción y obras infs. + Terrenos + Edificios + Maquinarias y Equipos + Vehículos + Buques + Aeronaves + Equipo de transporte + Construcciones en proceso + Otros Equipos	RESN/AF
	Razón 26	Ganancia Bruta / Propiedades, planta y equipo neto + Construcción y obras infs. + Terrenos + Edificios + Maquinarias y Equipos + Vehículos + Buques + Aeronaves + Equipo de transporte + Construcciones en proceso + Otros Equipos	RESOPER/AF
	Razón 27	Dividendos / Utilidad Consolidada	DIVIDEFEC/RES EJER ANT

Fuente: Elaboración Propia

2.4 Política monetaria

Se puede definir la política monetaria como la “administración del dinero y las tasas de interés... La política monetaria suele afectar los precios de las acciones cuando se reducen las tasas de interés, disminuyendo el rendimiento de los bonos” (Mishkin, 2014).

Díaz Mondragón, (2014) comenta que, para el caso de México, la política monetaria se entiende como el conjunto de acciones que lleva a cabo el Banco de México para influir sobre las tasas de interés y las expectativas del público, con el fin de que la evolución de los precios sea congruente con el objetivo de mantener un entorno de inflación baja y estable.

2.5 Banco de México

Sus antecedentes se remontan a principios del siglo XIX, donde en Europa los bancos centrales comenzaron a constituirse, se consideró algo similar en México, pero los bancos comerciales continuaron operando. Posterior a la revolución mexicana se estableció en el artículo 28 de la Carta Magna de 1917 la creación de un banco privado controlado por el gobierno, sin embargo, la creación del banco tardó siete años más hasta la fundación del Banco Único de Emisión, sin embargo, dicho proyecto fue pausado debido a la falta de recursos económicos en el erario. El establecimiento del Banco de México se consolidó hasta 1925, gracias a los esfuerzos del secretario de hacienda Alberto J. Pani, el entonces presidente Plutarco Elías Calles y las economías presupuestales logradas en el ejército. Banco de México, (2025).

Empezó a operar el 1 de septiembre de 1925. Fue desde 1994 que tuvo autonomía para sus funciones y administración. Está estructurado por una junta de gobierno con cinco miembros (un gobernador y cuatro subgobernadores). Su misión es promover la moneda nacional y la economía del país y su objetivo procurar la estabilidad del poder adquisitivo de dicha moneda, así como promover el sano desarrollo del sistema financiero y propiciar el buen funcionamiento de los sistemas de pago.

2.6 Mercados financieros

Mishkin, (2014) comenta que “los mercados financieros son aquellos donde se transfieren fondos desde personas que tienen un exceso de fondos disponibles hacia

personas que tienen una escasez de estos...son fundamentales para promover mayor eficiencia económica”.

Díaz Mondragón, (2014) define los mercados como cualquier mecanismo a través del cual entran contacto demandantes y oferentes para comprar o vender respectivamente algo, si es un conjunto de activos financieros se denomina mercados financieros. Por ello, entiende por mercados financieros internacionales aquellos en los que los activos financieros son denominados en moneda extranjera y/o los agentes económicos operan algún tipo de dinero distinto al del país de origen.

2.6.1 Mercado de capitales

Mishkin, (2014) se refiere al mercado de capitales como el mercado financiero donde se negocian instrumentos de deudas a largo plazo y de participantes. Se entiende como largo plazo a los instrumentos que tienen un vencimiento mayor a un año. Díaz Mondragón, (2014) comenta que este mercado está segmentado en dos tipos de títulos; las acciones por un lado y los bonos.

2.6.1.1 Activos Financieros

El Fondo Monetario Internacional, (2001) define los activos financieros como “un subconjunto de los activos económicos: entidades sobre las que las unidades institucionales ejercen derechos de propiedad, individual o colectivamente, y de las que sus propietarios pueden obtener beneficios económicos por su posesión o uso durante un período de tiempo.”, de la misma forma, se menciona que “Un activo es cualquier derecho financiero o trozo de propiedad que este sujeto a propiedad” (Mishkin, 2014).

Los activos financieros pueden clasificarse según su liquidez o las características que describen al acreedor deudor. Así, los activos financieros son:

- Oro monetario y DEG.
- Billetes y monedas y depósitos.
- Valores distintos de acciones.
- Prestamos.

- Acciones y otras participaciones de capital.
- Reservas técnicas de seguros.
- Derivados financieros.
- Otras cuentas por cobrar/pagar.

2.6.1.2 Acciones y valores

Mishkin, (2014) comenta que una acción representa una participación en la propiedad de una corporación, es un valor que representa un derecho sobre las utilidades y los activos de la corporación. Como complementación, Díaz Mondragón, (2014) comenta que las acciones proporcionan en propiedad una parte alícuota de los activos de una empresa y menciona que los títulos accionarios se clasifican en acciones comunes que otorgan derecho a voz pero no voto y las acciones preferentes, que reciben de manera preferente y acumulable el pago de un dividendo.

Una última definición es la de Díaz Mata, (2013) que define “las acciones de empresas, comerciales, industriales o de servicio, son títulos que representan la propiedad de sus tenedores sobre una de las partes iguales en que se divide el capital de la sociedad anónima correspondiente.”

2.6.1.3 Índices bursátiles

Los índices bursátiles comenta Díaz Mondragón, (2014) son una medida del rendimiento que obtendría un grupo especial de acciones; muestran las modificaciones continuas que presentan los precios de un conjunto de acciones que son las más representativas de la bolsa en la que se aplican, con estos podemos comparar la evolución de la rentabilidad media del mercado bursátil; además de ser una herramienta estadística muy importante (pues hacen manejable una enorme cantidad de información) es un instrumento vital para todos aquellos involucrados directamente en la compra y venta de acciones. Así, cada bolsa decide el índice que utilizará para ello se analizan opciones estadísticas con el propósito de elegir cual es el más adecuado para su plaza bursátil. Para que los índices sean útiles para todos los participantes, deben ser globales, estables y reproducibles.

Entre las fórmulas más comunes para obtener dichas variaciones de precios está el índice de Laspeyres. Se trata de una de las opciones de índices estadísticos que se tiene y es definido como una medida aritmética ponderada, respecto a un año base de los índices simples de precios, se expresa como:

Ecuación 2.2.2 Índice de Laspeyres

$$L_{t/0} = \frac{\sum_{i=1}^n p_{it} q_{it}}{\sum_{i=1}^n p_{i0} q_{it}} \quad (2.2)$$

2.6.1.4 Índice de Precios y Cotizaciones (IPC)

En el caso de la BMV, se creó el índice de precios y cotizaciones, el cual existe desde el 30 de octubre de 1978 y es un índice ponderado por valor de capitalización y formado por 35 acciones (generalmente las de mayor bursatilidad y volatilidad).

Para calcular el rendimiento del IPC la fórmula es:

$$IPC_t = IPC_{t-1} \left(\frac{\sum_{i=1}^n p_{it} Q_{it}}{\sum_{i=1}^n p_{it-1} q_{it} FA_{it}} \right) \quad (2.3)$$

donde: IPC_{t-1} hace referencia al periodo anterior del IPC ,

$\sum_{i=1}^n p_{it} Q_{it}$ es la sumatoria del precio actual de la emisora i

por la cantidad de la emisora i en el precio actual (t);

y $\sum_{i=1}^n p_{it-1} q_{it} FA_{it}$ es la sumatoria del precio base por la cantidad del periodo

de la emisora i y multiplicado por el factor de ajuste

2.6.2 Mercado de valores

A pesar de ser una subcategoría del mercado de capitales, el mercado de valores destaca su importancia y entendimiento en esta investigación a la par con los indicadores financieros de cada emisora y los ciclos económicos, desde la obtención de la información y los motivos que llevan al análisis específico.

“Representa una de las más importantes fuentes de financiamiento para las organizaciones del sector público y privado, así mismo representa una amplia gama de alternativas de inversión, ahorro y manejo de excedentes monetarios”. (Díaz Mata, 2013).

Por otro lado, Díaz Mondragón (2014) menciona que el mercado de valores es cualquier mecanismo a través del cual entran en contacto compradores y vendedores de activos financieros. En este mercado, se incluyen el mercado de dinero y de capitales, así

mismo este mercado es representado por la bolsa de valores, sin embargo, no todas las empresas existentes pertenecen al mercado de valores, en este “solo las corporaciones grandes y bien establecidas tienen acceso” (Mishkin, 2014).

2.7 Bolsa de valores

Las bolsas de valores son los espacios físicos o virtuales donde se intercambian productos financieros, estos tienen la finalidad de proporcionar capital a aquellos que lo requieren para inversiones, Díaz Mondragón (2014) considera que es la bolsa de valores de cualquier país la representante formal a través de la cual se fijan las normas y esquemas operativos de comercio con valores y la interacción entre agentes económicos, como la denominación en monedas extranjeras lo que genera el grado de internalización.

“La bolsa de valores, reglamentada a través de la ley del mercado de valores, es la institución (mercado) en cuyo piso de remates se realizan transacciones de compraventa de valores de los documentos (valores) que formalizan operaciones.” Díaz Mata (2013).

Dichos espacios de intercambio de valores poseen una historia que los afirma como lugares de suma importancia a lo largo de los siglos, con una longevidad existencial de más de 400 años de antigüedad formal. Estos espacios se han reformado en conjunto con el avance social, adaptándose a las tecnologías de la época y la interconectividad para no dejar de ofrecer sus servicios de compra y venta de valores.

2.7.1 Bolsas de Valores en el mundo

A lo largo de los años han existido diversas bolsas de valores, compitiendo y vendiendo acciones de emisoras en diferentes épocas y países, a continuación, se presenta una breve descripción de algunas de las bolsas más importantes del mundo moderno basado en Cattlin (2020).

La primera bolsa de valores fue creada de manera oficial en Ámsterdam en 1602, por la compañía de las Indias Orientales, iniciando un nuevo sistema financiero de manera formal, sin embargo, existen registros de transacciones de valores a lo largo de las épocas y las civilizaciones.

2.7.1.1 Europa

El viejo continente cuenta con una amplia gama de bolsas de valores que cotizan acciones todos los días, a continuación, se presentan en la tabla 2-6 las bolsas de valores más importantes de Europa:

Tabla 2-6 Bolsas de Valores más importantes de Europa

Bolsa de Londres	Se trata de la sexta bolsa más importante a nivel mundial, fundada en 1801 pero con antecedentes desde 1698 se vuelve una de las más antiguas, su índice más importante es el FTSE 100, con las cien emisoras más importantes de dicha bolsa.
Euronext	Con sede en Ámsterdam, es una bolsa de valores que opera en diversos países europeos como Portugal, Bélgica, Países Bajos, Francia, Irlanda y Reino Unido, es la séptima bolsa más importante del mundo, pues cotizan 1300 emisoras, su índice más importante es el Euronext 100.
Frankfurt	La bolsa de se fijó como la más importante de Alemania después de la segunda guerra mundial, fundada en 1585 como mercado de bienes y materias primas, es una de las más antiguas del mundo y la décima más importante del mundo, sus índices principales son el DAX y el Euro Stoxx 50.

Fuente: Elaboración Propia

2.7.1.2 Asia

En Asia se encuentran bolsas de valores de alto impacto para la economía global, a pesar de ser más recientes que las europeas se han posicionado entre las más importantes del mundo, a continuación, se presentan las bolsas más importantes de Asia en la tabla 2-7:

Tabla 2-7 Bolsas de Valores más importantes de Asia

Bolsa de Tokio	Fundada en 1878, siendo la más importante de Japón y la tercer bolsa más importante del mundo, en ella cotizan más de 3500 empresas y su índice de referencia es el Nikkei 225.
Bolsa de Shanghái	Se trata de una de las bolsas independientes de la República Popular China, es la cuarta más importante a pesar de ser fundada en 1990, su índice es el Shanghái Composite Index (SSEC).

Fuente: Elaboración Propia

2.7.1.3 Estados Unidos

Por su basta riqueza económica, Estados Unidos posee las dos bolsas más importantes mundo, La bolsa de Nueva York y la NASDAQ, descritas brevemente en la tabla 2-8:

Tabla 2-8 Bolsas de Valores más importantes de Estados Unidos

Bolsa de Nueva York	Se encuentra situada en nueva York, fundada en 1817, ha transcurridos por periodos de mucha incertidumbre y acontecimientos diversos como su caída en 1929, en 2018 suponía casi el 40% del valor total del mercado de valores a nivel mundial, su índice más importante es el Dow Jones y actualmente es la bolsa de valores más importante del mundo.
Nasdaq	Fundada en 1971, emplea un sistema de intercambio con ordenadores o por teléfono, convirtiéndola en la primer bolsa de valore electrónica, sus siglas son por <i>National Association of Securities Dealers Automated Quotations</i> y tiene la capitalización de valores tecnológicos más relevante, el índice para medirla es el Nasdaq 100.

Fuente: Elaboración Propia

2.7.2 Bolsa Mexicana de Valores

La bolsa Mexicana de Valores es un tema crucial para el desarrollo de esta investigación pues provee los datos a consultar, hasta el momento se han revisado conceptos generales y globales que conforman el sistema bursátil, pero es necesario profundizar más desde el punto de vista nacional, desde su historia y consecuencias hasta sus repercusiones y organización.

La vida bursátil en México comienza con corredores y empresarios en la vía pública de la hoy Ciudad de México, comprando y vendiendo todo tipo de bienes y valores, un tiempo después estos se organizarían en grupos que organizaban sus ventas ahora a puerta cerrada entre accionistas y emisores. Posteriormente, en 1894 se promovió la idea de que las negociaciones de valores tuvieran un marco normativo e institucional, para ello se fundó en 1894 la Bolsa Nacional con sede en Ciudad de México. Un año después se fundaría otra sociedad bajo el nombre Bolsa de México, pasando a fusionarse en una sola institución, la Bolsa de México S.A que a principios de 1896 cotizaban tres emisoras públicas y ocho privadas. Tiempo después en 1933 se creó la Bolsa de Valores de México, S.A, supervisada por la Comisión Nacional de Valores. Gracias a una mejor regulación, el inicio del desarrollo industrial y políticas económicas estables, esta bolsa de valores generó mayor confianza en los ciudadanos y sirvió como mecanismo importante de financiamiento para empresas nacionales. En otras ciudades importantes del país, Monterrey y Guadalajara y gracias a la acumulación de capital se fundan la Bolsa de Monterrey (1950) y la Bolsa de Occidente en 1956.

Finalmente, en 1975 entra en vigor la ley del mercado de valores, buscando regular la oferta de valores, la intermediación en el mercado, las actividades de las personas que intervienen en el mercado, el registro nacional de valores e intermediarios y las autoridades competentes en materia de mercado de valores, cambiando la Bolsa de Valores de México a llamarse Bolsa Mexicana de Valores, incorporando las bolsas de Monterrey y Guadalajara.

El índice más importante que cotiza en la BMV es el índice de precios y cotizaciones, establecido en 1978, el cual “expresa el rendimiento del mercado accionario en función de las variaciones de precios de una muestra balanceada, ponderada y

representativa del conjunto de acciones cotizadas en la Bolsa. Este indicador representa las fluctuaciones del mercado accionario.” Espinosa, (2024) sin embargo, en este periodo también se entró en una etapa de incertidumbre en la economía nacional, motivado por la caída de los precios del petróleo y una alta deuda externa.

La BMV ha sido la entidad que representa el mercado bursátil y de valores en el país desde hace décadas, pasando por diversas reformas y cambios, soportando y viéndose en la necesidad de adaptarse a los cambios sociales y políticos que han transcurrido en México. A finales de los años 90 y principios de los 2000 se vio la necesidad de modernizar la banca y fomentar un uso más digital, para estar a la par con los demás mercados globales, mejorando la rapidez de las transacciones y atrayendo a un nuevo perfil de inversionistas.

“La Bolsa Mexicana de Valores (BMV) desempeña un papel crucial en la economía del país, actuando como un intermediario fundamental en la financiación de empresas y en el ahorro e inversión de los ciudadanos. A lo largo de su historia, la BMV ha evolucionado y ha enfrentado diversos desafíos, pero su función como barómetro de la salud económica de México y como facilitador del crecimiento ha permanecido constante”. México Histórico. (s.f.).

Los instrumentos que se negocian en la BMV se pueden clasificar en emitidas por entidades gubernamentales y emitidas por empresas, es en este último donde se encuentran las acciones de empresas comerciales, industriales, servicios y acciones de sociedades de inversión. La colocación de dichas acciones se lleva a cabo a través de ofertas públicas y negociaciones privadas.

Se define como “el foro en el que se llevan a cabo las operaciones del mercado de valores organizado en México, siendo su objeto el facilitar las transacciones con valores y procurar el desarrollo del mercado, fomentar su expansión y competitividad”. (Bolsa Mexicana de Valores, 2015).

Para una mejor organización, la Bolsa de Valores divide las emisoras en diez sectores, descritos en la tabla 2-9,” La clasificación permite homologar a las emisoras con

estándares internacionales, de tal manera que es posible una comparación más precisa con emisoras similares en otros mercados” (Bolsa Mexicana de Valores, 2015). Por medio de esta investigación se puede concluir que la Bolsa Mexicana de Valores ha sido de vital importancia para el desarrollo bursátil y financiero del país, ajustándose a las necesidades de la época y sirviendo como punto focal del manejo de capitales en México.

La estructura de clasificación consta igual de 24 subsectores, 78 ramos y 192 subramos, en este apartado se mencionan los sectores y sus descripciones, así como las 131 emisoras que cotizan actualmente en esta bolsa; cabe aclarar que para esta investigación no se utilizaron todas las emisoras.

Tabla 2-9 Sectores de la Bolsa Mexicana de Valores

Sector	Descripción
Energía	Industrias dedicadas a la creación de equipos para la extracción de fuentes de energía, así como empresas asociadas a su explotación, distribución y almacenamiento.
Materiales	Engloba a las empresas dedicadas a la producción de elementos secundarios de la industria (materiales) tales como productos químicos, vidrio, plástico, materiales procesados, etc.
Industrial	Engloba empresas de bienes terciarios o servicios tales como transporte, comerciales, construcción, entre otros.
Servicios y Bienes de consumo no básico	Industrias de componentes automotrices, servicios al consumidor, servicios de ventas al por menor, y bienes de consumo duradero (textiles, productos recreativos).
Productos de consumo frecuente	Empresas que crean productos de uso y consumo común, como bebidas, alimentos, tabaco y otros domésticos.
Salud	Productores o distribuidores de equipos y servicios médicos, así como productos farmacéuticos, biotecnológicos y similares.
Servicios Financieros	Agrupar las entidades financieras, agencias inmobiliarias y sociedades de inversión.
Tecnología de la información	Agrupar software y hardware asociado a tecnologías de la información y servicios que se adquieren por internet.
Servicios de telecomunicaciones	Emisoras que involucran comunicaciones a larga distancia, como servicios de comunicación inalámbricos y todos los medios de comunicación.
Servicios públicos	Aquellos servicios que satisfacen necesidades básicas, como suministro de agua, electricidad, gas, etc.

Fuente: Elaboración propia con Información de la Bolsa Mexicana de Valores

Tabla 2-10 Empresas pertenecientes a la BMV

Clave Emisora	Razón Social	Clave Emisora	Razón Social
AC	ARCA CONTINENTAL, S.A.B. DE C.V.	GOMO	GRUPO COMERCIAL GOMO, S.A. DE C.V.
ACCELSA	ACCEL, S.A.B. DE C.V.	GPH	GRUPO PALACIO DE HIERRO, S.A.B. DE C.V.
ACTINVR	CORPORACION ACTINVER, S.A.B. DE C.V.	GPROFUT	GRUPO PROFUTURO, S.A.B. DE C.V.
AGRIEXP	AGRO INDUSTRIAL EXPORTADORA, S.A. DE C.V.	GRUMA	GRUMA, S.A.B. DE C.V.
AGUA	GRUPO ROTOPLAS, S.A.B. DE C.V.	HCITY	PROMOTORA DE HOTELES NORTE 19, S.A.B. DE C.V.
AGUILAS	OLLAMANI, S.A.B.	HERDEZ	GRUPO HERDEZ, S.A.B. DE C.V.
AHMSA	ALTOS HORNOS DE MEXICO, S.A. DE C.V.	HIMEXSA	HIMEXSA, S.A.B. DE C.V.
ALFA	ALFA, S.A.B. DE C.V.	HOMEX	DESARROLLADORA HOMEX, S.A.B. DE C.V.
ALPEK	ALPEK, S.A.B. DE C.V.	HOTEL	GRUPO HOTELERO SANTA FE, S.A.B. DE C.V.
ALSEA	ALSEA, S.A.B. DE C.V.	IASASA	INDUSTRIA AUTOMOTRIZ, S.A. DE C.V.
ALTERNA	ALTERNA ASESORIA INTERNACIONAL, S.A.B. DE C.V.	ICH	INDUSTRIAS CH, S.A.B. DE C.V.
AMX	AMERICA MOVIL, S.A.B. DE C.V.	IDEAL	IMPULSORA DEL DESARROLLO Y EL EMPLEO EN AMERICA LATINA, S.A.B. DE C.V.
ANB	ANHEUSER-BUSCH INBEV SA/NV	INVEX	INVEX CONTROLADORA, S.A.B. DE C.V.
ARA	CONSORCIO ARA, S.A.B. DE C.V.	KIMBER	KIMBERLY - CLARK DE MEXICO S.A.B. DE C.V.
ARISTOS	CONSORCIO ARISTOS, S.A.B. DE C.V.	KOF	COCA-COLA FEMSA, S.A.B. DE C.V.
ASUR	GRUPO AEROPORTUARIO DEL SURESTE, S.A.B. DE C.V.	KUO	KUO, S.A.B. DE C.V.
AUTLAN	COMPAÑIA MINERA AUTLAN, S.A.B. DE C. V.	LAB	GENOMMA LAB INTERNACIONAL, S.A.B. DE C.V.
AXTEL	AXTEL, S.A.B. DE C.V.	LACOMER	LA COMER S.A.B. DE C.V.
AZTECA	TV AZTECA, S.A.B. DE C.V.	LAMOSA	GRUPO LAMOSA, S.A.B. DE C.V.
BBAJIO	BANCO DEL BAJÍO, S.A., INSTITUCIÓN DE BANCA MÚLTIPLE	LASEG	LA LATINOAMERICANA SEGUROS, S.A.
BBVA	BANCO BILBAO VIZCAYA ARGENTARIA, S.A.	LASITE	SITIOS LATINOAMÉRICA, S.A.B. DE C.V.
BEVIDES	FARMACIAS BENAVIDES, S.A.B. DE C.V.	LIVEPOL	EL PUERTO DE LIVERPOOL, S.A.B. DE C.V.
BIMBO	GRUPO BIMBO, S.A.B. DE C.V.	MEDICA	MEDICA SUR, S.A.B. DE C.V.
BOLSA	BOLSA MEXICANA DE VALORES, S.A.B. DE C.V.	MEGA	MEGACABLE HOLDINGS, S.A.B. DE C.V.
CABLE	EMPRESAS CABLEVISION, S.A. DE C.V.	MFRISCO	MINERA FRISCO, S.A.B. DE C.V.
CADU	CORPOVAEL S.A.B. DE C.V.	MINSa	GRUPO MINSa, S.A.B. DE C.V.
CEMEX	CEMEX, S.A.B. DE C.V.	NEMAK	NEMAK, S.A.B. DE C.V.
CHDRAUI	GRUPO COMERCIAL CHEDRAUI, S.A.B. DE C.V.	NUTRISA	GRUPO NUTRISA, S.A.B. DE C.V.
CIDMEGA	GRUPE, S.A.B. DE C.V.	OMA	GRUPO AEROPORTUARIO DEL CENTRO NORTE, S.A.B. DE C.V.
CIE	CORPORACION INTERAMERICANA DE ENTRETENIMIENTO, S.A.B. DE C.V.	ORBIA	ORBIA ADVANCE CORPORATION, S.A.B. DE C.V.
CMOCTEZ	CORPORACION MOCTEZUMA, S.A.B. DE C.V.	PASA	PROMOTORA AMBIENTAL, S.A.B. DE C.V.
CMR	CMR, S.A.B. DE C.V.	PE&OLES	INDUSTRIAS PEÑOLES, S. A.B. DE C. V.
COLLADO	G COLLADO, S.A.B. DE C.V.	PINFRA	PROMOTORA Y OPERADORA DE INFRAESTRUCTURA, S.A.B. DE C.V.
CONVER	CONVERTIDORA INDUSTRIAL, S.A.B. DE C.V.	PLANI	PLANIGRUPO LATAM, S.A.B. DE C.V.
CREAL	CREDITO REAL, S.A.B. DE C.V., SOFOM, E.N.R.	POCHTEC	GRUPO POCHTECA, S.A.B. DE C.V.
CTALPEK	CONTROLADORA ALPEK, S.A.B. DE C.V.	POSADAS	GRUPO POSADAS, S.A.B. DE C.V.

Clave Emisora	Razón Social	Clave Emisora	Razón Social
CTAXTEL	CONTROLADORA AXTEL, S.A.B. DE C.V.	PROCORP	PROCORP, S.A.B. DE C.V.
CUERVO	BECLE, S.A.B. DE C.V.	PV	PEÑA VERDE S.A.B.
CULTIBA	ORGANIZACIÓN CULTIBA, S.A.B. DE CV	Q	QUALITAS CONTROLADORA, S.A.B. DE C.V.
CYDSASA	CYDSA, S.A.B. DE C.V.	QBINDUS	Q.B. INDUSTRIAS, S.A. DE C.V.
DIABLOS	DIABLOS ROJOS DEL MEXICO, S.A.P.I.B. DE C.V.	QUMMA	GRUPO QUMMA, S.A. DE C.V.
DINE	DINE, S.A.B. DE C.V.	R	REGIONAL, S.A.B. DE C.V.
EDOARDO	EDOARDOS MARTIN, S.A.B. DE C.V.	RCENTRO	GRUPO RADIO CENTRO, S.A.B. DE C.V.
ELEKTRA	GRUPO ELEKTRA, S.A.B. DE C.V.	RLH	RLH PROPERTIES, S.A.B. DE C.V.
FEMSA	FOMENTO ECONÓMICO MEXICANO, S.A.B. DE C.V.	SARE	SARE HOLDING, S.A.B. DE C.V.
FINAMEX	CASA DE BOLSA FINAMEX, S.A.B. DE C.V.	SAVIA	SAVIA, S.A. DE C.V.
FINDEP	FINANCIERA INDEPENDENCIA, S.A.B. DE C.V. SOFOM, E.N.R.	SIMEC	GRUPO SIMEC, S.A.B. DE C.V.
FRAGUA	CORPORATIVO FRAGUA, S.A.B. DE C.V.	SITES1	OPERADORA DE SITES MEXICANOS, S.A.B. DE C.V.
FRES	FRESNILLO PLC	SORIANA	ORGANIZACION SORIANA, S.A.B. DE C.V.
GAP	GRUPO AEROPORTUARIO DEL PACIFICO, S.A.B. DE C.V.	SPORT	GRUPO SPORTS WORLD, S.A.B. DE C.V.
GAV	ACOSTA VERDE, S.A.B. DE C.V.	TEAK	PROTEAK UNO, S.A.B. DE C.V.
GBM	CORPORATIVO GBM, S.A.B. DE C. V.	TEKCHEM	TEKCHEM, S.A.B. DE C.V.
GCARSO	GRUPO CARSO, S.A.B. DE C.V.	TLEVISA	GRUPO TELEVISA, S.A.B.
GCC	GCC, S.A.B. DE C.V.	TMM	GRUPO TMM, S.A.
ENTERA	ENTERA, S.A.B. DE C.V.	TRAXION	GRUPO TRAXIÓN S.A.B DE C.V.
GFAMSA	GRUPO FAMSA, S.A.B. DE C.V.	TS	TENARIS S.A.
GFINBUR	GRUPO FINANCIERO INBURSA, S.A.B. DE C.V.	UNIFIN	UNIFIN FINANCIERA, S.A.B. DE C.V.
GFMULTI	GRUPO FINANCIERO MULTIVA S.A.B. DE C.V.	VALUEGF	VALUE GRUPO FINANCIERO, S.A.B. DE C.V.
GFNORTE	GRUPO FINANCIERO BANORTE, S.A.B DE C.V.	VASCONI	GRUPO VASCONIA S.A.B.
GICSA	GRUPO GICSA, S.A.B. DE C.V.	VESTA	CORPORACIÓN INMOBILIARIA VESTA, S.A.B. DE C.V.
GIGANTE	GRUPO GIGANTE, S.A.B. DE C.V.	VINTE	VINTE VIVIENDAS INTEGRALES, S.A.B. DE C.V.
GISSA	GRUPO INDUSTRIAL SALTILLO, S.A.B. DE C.V.	VISTA	VISTA ENERGY, S.A.B. DE C.V.
GMD	GRUPO MEXICANO DE DESARROLLO, S.A.B.	VITRO	VITRO, S.A.B. DE C.V.
GMEXICO	GRUPO MEXICO, S.A.B. DE C.V.	VOLAR	CONTROLADORA VUELA COMPAÑÍA DE AVIACIÓN, S.A.B. DE C.V.
GMXT	GMÉXICO TRANSPORTES, S.A.B. DE C.V.	WALMEX	WAL - MART DE MEXICO, S.A.B. DE C.V.
GNP	GRUPO NACIONAL PROVINCIAL, S.A.B.		

Fuente: Elaboración Propia con datos de la Bolsa Mexicana de valores (2025).

2.7.3 Bolsa Institucional de Valores

Hasta hace poco, en México solo existía una bolsa de valores, la Bolsa Mexicana de Valores, (BMV) que opera por concesión de la Secretaría de Hacienda y Crédito Público y es regulada por la ley del mercado de valores, sin embargo, se genera la necesidad de mayor competencia y modernización tecnológica, por ello se crea un nuevo proyecto de bolsa de valores, atractiva para empresas medianas, nuevas colocaciones y emisoras interesadas en procesos más ágiles de incorporación.

La segunda bolsa de valores que opera en México tiene sus cimientos en 2013, cuando Grupo CENCOR, una sociedad mexicana dedicada a administrar empresas para el desarrollo de infraestructura de mercados financieros, presento un proyecto para crear una nueva bolsa de Valores en México, en 2015 se solicitó formalmente una concesión para organizar la Bolsa Institucional de Valores (BIVA) , el cual se otorgó en 2017; así, el 25 de julio de 2018, BIVA inicia su operación, bajo la concesión otorgada por la Secretaría de Hacienda y Crédito Público y la regulación de la Comisión nacional Bancaria y de Valores, teniendo como propósito contribuir al crecimiento del mercado de valores a través de la innovación, el uso de la tecnología de punta y una mayor accesibilidad. (Bolsa Institucional de Valores, s.f.).

De la Garza (2025) establece que la BIVA se crea para generar competencia directa con la BMV, diversificando las opciones disponibles para emisoras e inversionistas, con un modelo operativo enfocado en la innovación, accesibilidad y costos bajos, actualmente existen listadas 95 emisoras, ofreciendo una amplia lista de instrumentos financieros, divididos en tres categorías:

- Instrumentos de Capital, como acciones, fibras, TRACs, entre otros;
- Instrumentos de deuda, a corto y largo plazo, certificados bursátiles, bonos corporativos,
- Derivados como Warrants o títulos Opcionales.

2.8 Ciclo económico

Como ya se ha investigado, el mercado de capitales coopera para mover la economía de un país y expandirla, sin embargo, existen diversos sucesos macroeconómicos que generan que no esté siempre creciendo como le gustaría a las empresas, pues INEGI (2012) menciona que lo ideal sería que la actividad económica de un país se extendiera a través del tiempo a un buen ritmo, de tal forma que genere empleo suficiente para los que buscan nuevas oportunidades sin crear presiones inflacionarias. Sin embargo, existen periodos de fluctuación en las actividades económicas a lo largo del tiempo, los cuales afectan naturalmente a la Bolsa Mexicana de Valores y las emisoras que le corresponden,

así como la economía mexicana en general, el entendimiento de estos factores resulta importante para el desarrollo de esta investigación.

2.8.1 Definición

INEGI (2012) menciona que los ciclos económicos son estos periodos de expansión y recesión altamente estudiados en la macroeconomía, pues normalmente los indicadores económicos se relacionan con ellos. Así mismo, estos pueden definirse como las oscilaciones de la actividad económica que dan lugar a la expansión y la contracción alternada de la economía en forma de eventos sucesivos.

Finalmente, INEGI (2012) comenta que la definición más usada de los ciclos económicos fue publicada en 1946 por los economistas Arthur Burns y Wesley Mitchell dice que:

“...son fluctuaciones en la actividad económica agregada de países cuya economía está organizada en empresas de negocios. Un ciclo consiste en expansiones simultáneas en muchas actividades económicas, seguidas de recesiones generales similares, contracciones y recuperaciones que fusionan en una nueva etapa de expansión en un siguiente ciclo. La duración de un ciclo varía de más de un año a periodos de diez o doce años y no son divisibles en ciclos más cortos de características similares”.


2.8.2 Fases del Ciclo Económico

El ciclo económico cuenta con dos etapas principales y opuestas entre sí, la disminución, que refiere a cuando la actividad económica entra en recesión y el periodo de expansión, de crecimiento del producto. Dichas fluctuaciones son medidas generalmente en términos del Producto Interno Bruto y pueden clasificarse en fases.

De acuerdo con el INEGI (2012), la primera fase del ciclo se denomina recesión, significando la generalidad de indicadores financieros yendo hacia abajo, es decir un decremento en la actividad económica y los precios de los productos, dicha fase concluye cuando se llega al punto más bajo, es decir el valle. La segunda fase es conocida como recuperación, y se da cuando la economía empieza a crecer, las acciones se van

recuperando y ocurre una disminución progresiva en los precios de los productos, finalmente vuelve a la etapa de expansión, caracterizada por un incremento en los precios, la producción de bienes, y la disminución de tasas de interés, en esta fase se encuentra el punto más elevado del ciclo, llamado pico. Normalmente se utiliza este punto máximo como final del ciclo actual e inicio del siguiente, de ahí que la primer fase sea la recesión. La figura 2-1 describe la gráfica común que siguen los ciclos económicos.

2-1 Etapas del ciclo económico típico



Fuente: INEGI (2012)

2.8.3 Reloj del Ciclo Económico

Para esta investigación se toma en cuenta el reloj del ciclo económico, mismo que, agrega INEGI (s.f) “Es una herramienta que apoya al análisis de los ciclos del país ya que muestra la interacción de indicadores económicos seleccionados por su relevancia en la identificación de los puntos de giro del ciclo”.

Existen indicadores estrechamente relacionados a los ciclos económicos, los más importantes se dividen en términos de dirección o en términos de tiempo. Para esta investigación no se adentrará más en los de dirección, pero sí en los indicadores en términos de tiempo; estos son los indicadores que reaccionan al tiempo que toma cada indicador en relación con el ciclo económico y se clasifican en coincidente, adelantado y rezagado.

2.8.4 Indicadores del Ciclo económico

En el indicador coincidente los tiempos de sus movimientos coinciden con el ciclo económico, y radica su importancia cuando termina la fase de expansión y comienza la recesión, o viceversa. Este índice ha logrado replicar adecuadamente los picos y valles generados por la NBER (*National Bureau of Economic Research*). Las variables que componen el Indicador Coincidente son el Indicador Global de la Actividad Económica, el Indicador de la Actividad Industrial, el Índice de Ingresos por Suministro de Bienes y Servicios al por menor, los Asegurados Trabajadores Permanentes en el IMSS, la Tasa de Desocupación Urbana y las Importaciones Totales.

Espinosa, (2024) profundiza en las variables de este indicador, describiéndolas como sigue:

- Indicador Global de la Actividad Económica (IGAE): Muestra la evolución mensual de la actividad económica del país con una oportunidad prevista entre 55 y 57 días después de concluido el mes de referencia.
- Indicador de la actividad industrial: Refleja el volumen físico de producción de las actividades industriales: Minería; Electricidad, Agua y suministro de Gas, Construcción, e Industrias Manufactureras.
- Índice de ingresos por suministro de bienes y servicios al por menor: Se refiere al monto que obtuvo la empresa de comercio al por menor derivado de todas las actividades de producción, comercialización o prestación de servicios que realizó en el mes de referencia.
- Asegurados trabajadores permanentes en el IMSS: Número de personas del ámbito urbano y del campo que están inscritos en el Instituto Mexicano del Seguro Social (IMSS).
- Tasa de desocupación urbana: Porcentaje de la población económicamente activa que se encuentra sin trabajar, pero que está buscando trabajo,

disponibles para aceptar empleo y que realizaron acciones concretas de búsqueda de trabajo.

- Importaciones totales: Es el total de mercancías expresadas en dólares que entran al territorio nacional de forma definitiva o temporal, mediante un pedimento aduanero y cumpliendo con las disposiciones de la Ley y Normatividad Aduanera vigentes.

El Indicador Adelantado por su parte, anticipa los movimientos del ciclo económico, motivo por el cual es el indicador más estudiado y aquel que se usa para esta investigación. Las variables para este indicador son: la Tendencia del Empleo en las Manufacturas, el Indicador de Confianza Empresarial: Momento Adecuado para Invertir, el Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores en términos reales, el Tipo de Cambio Real Bilateral México-EUA, la Tasa de Interés Interbancaria de Equilibrio y el Índice Standard & Poor's 500 (índice bursátil de Estados Unidos).

De igual manera que en el indicador coincidente, la descripción de las variables que comenta Espinosa, (2024) es:


- Tendencia del empleo en las manufacturas: La tendencia del empleo se calcula como la diferencia entre el porcentaje de los que opinaron que el número de trabajadores aumentó y el porcentaje de los que opinaron que el número de trabajadores disminuyó.
- Indicador de confianza empresarial momento adecuado para invertir: Su propósito es medir las opiniones de los directivos empresariales en cuanto a la situación económica que se presenta tanto en el país como en su empresa. A medida que el optimismo se generaliza, el valor del indicador 57 se hace mayor; por el contrario, a medida que el porcentaje de informantes con opiniones pesimistas se incrementa, el valor del indicador disminuirá.
- Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores en términos reales: Indicador de la evolución del mercado accionario en su

conjunto de México, deflactado por el Índice Nacional de Precios al Consumidor (INPC).

- Tipo de cambio real bilateral México-EUA: El Tipo de Cambio Real Bilateral está definido por el cociente del Índice de Precios al Consumidor de EUA y el Índice de Precios al Consumidor de México. Actualmente se expresa en pesos, a precios de 1990.- Tasa de Interés Interbancaria de Equilibrio: Es una tasa representativa de las operaciones de crédito para 28 días entre bancos. Es la tasa a la cual los bancos se prestan recursos entre sí en el mercado interbancario.
- Índice Standard & Poor's 500 (índice bursátil de Estados Unidos): Indicador del mercado de valores de los Estados Unidos de América, el cual incluye 500 compañías líderes en las principales industrias de la economía de los Estados Unidos.

Finalmente, en el indicador rezagado, el cambio de tendencia ocurre después de haberse iniciado una nueva fase en el ciclo económico, este no anticipa los cambios en el ciclo, pero sirve como señal de consolidación de una fase. En la figura 2-2 se presenta el reloj del ciclo económico del INEGI.

2-2 Reloj del Ciclo Económico del INEGI



Fuente: INEGI (2025)

Por los datos y objetivos de esta investigación, se consideran como indicadores principales el EVA y el GEO para la construcción de indicadores financieros. Ambos indicadores pueden explicar la capacidad de que una empresa sea generadora de valor como se ha visto en las investigaciones de Espinosa, (2023) y Garduño (2023).

2.9 EVA

Hinojoza y Falcon (2006) definen el EVA (Valor económico Agregado) como un indicador específico de ingreso residual que muchas empresas utilizan actualmente para medir su desempeño. Y consideran que su fundamento se halla en que la finalidad suprema de los directivos de la organización es crear valor, y por ello se le concibió como la herramienta capaz de medir si ese objetivo efectivamente se cumple.

Otra definición menciona que:

“Un índice que incorpora el cálculo del costo de los recurso propios, proporcionando una medida de rentabilidad de una empresa como el resultado del beneficio neto después de los impuestos menos el correspondiente cargo por costo de oportunidad de todo el capital que se encuentra invertido en la compañía” Saavedra et al (2012).

2.9.1 Cálculo del indicador EVA

El indicador del EVA se calcula de la siguiente manera:

Ecuación 2.2.4 Cálculo del EVA

$$EVA = UADI - (\text{Valor contable del Activo operativo} * \text{Costo del Capital}) \quad (2.4)$$

Donde:

- $K\% = (\text{Deuda} / (\text{Deuda} + \text{CS}) \cdot \text{Costo de deuda} * (1 - T) + (\text{Fondos propios} / (\text{Deuda} + \text{CS}) \cdot (\text{Costo de fondos propios}))$
- $UADI = \text{Ingresos Financieros} + \text{Otros Productos Financieros} + \text{Costos Financieros} + \text{Utilidad Antes de Impuestos}$
- $VAC = \text{Activo Total} - \text{Inversiones Financieras} + \text{Depreciación y Amortización} - \text{Deudas Financieras CP} + (\text{Intangibles Diferidos} + \text{Activos Intangibles} + \text{Otros Intangibles}) - \text{Total provisiones CP}$

2.10 GEO

El indicador de Generación Económica Operativa, su objetivo es determinar si una empresa está creando valor considerando el costo del capital invertido, esto puede traducirse en si el rendimiento operativo supera el costo del financiamiento operacional. En su cálculo se encuentra el IO, inversiones que la empresa requiere realmente para operar, es por eso que hay que descontar los excedentes de caja ya que se trata de una inversión que no interviene en la generación de utilidad operativa.

2.10.1 Cálculo del indicador GEO

El indicador del GEO se calcula de la siguiente manera:

Ecuación 2.2.5 Cálculo del GEO

$$GEO = (UO ** IO) * (RIONDI - K\%) \quad (2.5)$$

Donde:

- $UO =$ *Ganancia Bruta*
- $IO =$ *Inversiones en en años anteriores*
- $RIONDI = (RION) \cdot (1 - T) -$ *Rendimiento dela Inversión Operativa Neta Después de Impuestos.*
- $RION =$ *Utilidad antes de impuestos / Ingresos netos – Rendimiento de la Inversión Operativa Neta*
- $T =$ *Gastos por impuestos a las ganancias / Utilidad antes de impuestos – Tasa Impositiva*
- $K\% = (Deuda/Deuda + CS) \cdot Costodeuda * (1 - T) + (Fondos propios/ Deuda + CS) \cdot (Costodefondospropios)$

2.11 Conclusiones del Capítulo

Una de las metas más importantes de cualquier organización es la de generar valor, para ello existen diversas técnicas y se ven involucradas bastantes variables que van desde las organizacionales, eventos macroeconómicos y tomas de decisión por parte de la alta dirección. Entre los indicadores más destacados para evaluar la generación de valor se encuentran el EVA y el GEO, instrumentos que como ya se ha demostrado, proveen un amplio espectro para evaluar las decisiones estratégicas de una organización.

Bajo este contexto también se resalta la importancia de la información financiera, tanto para los inversionistas como para las cabezas principales de la empresa, usar dicha información para generar valor indica un mejor manejo administrativo y un fuerte compromiso con sus objetivos organizacionales. Los ratios financieros y su análisis abren las puertas a un sinnúmero de técnicas financieras capaces de generarle valor a una empresa, misma que se ve afectada por su liquidez, recursos, solvencia y estructura financiera, ayudando a un mejor entendimiento del desempeño financiero.

Finalmente, en este contexto el uso de variables macroeconómicas como lo son los ciclos económicos y sus indicadores añaden una capa más profunda a la investigación y sus posibles alcances, con estos es posible trasladar los resultados a un área del conocimiento más amplia, permitiendo disminuir la incertidumbre bajo diversas adversidades temporales.

Capítulo III: Redes Neuronales Artificiales

Introducción

Las redes neuronales artificiales han adquirido un impacto muy amplio en los modelos de clasificación y predicción, llegando a ser usadas en múltiples áreas del conocimiento, tanto científico como humano, con diversas tácticas y resultados, generando un sólido puente entre las técnicas tradicionales vistas en modelos de machine learning y las nuevas técnicas como inteligencia artificial y Deep learning, el uso de modelos y sistemas complejos inspirados en la estructura biológica y funcionamiento del cerebro ha traído nuevas arquitecturas computacionales usadas para superar barreras antes impuestas como el uso de modelos lineales para la predicción o la clasificación y la resolución de problemas con amplios volúmenes de datos que antes resultaban muy costosos y complicados de llevar a cabo.

En este capítulo se muestran breves fragmentos de las redes neuronales, su historia e inspiración, así como sus aplicaciones, y las bases teóricas y matemáticas en la que estas técnicas se sustentan para llevar a cabo sus análisis, se muestran los componentes más importantes de las redes neuronales y su arquitectura necesaria para funcionar.

3.1 Inspiración biológica

A través de siglos de evolución, los organismos vivos se han vuelto excelentes en llevar a cabo sus funciones, en adaptarse y desenvolverse de manera óptima en cualquier medio o situación buscando sobrevivir, por ello, es natural que intentemos replicar su comportamiento o componentes en las áreas del conocimiento científico, buscando optimizar herramientas o métodos de aprendizaje. Se puede observar este fenómeno desde la forma de la aguja hipodérmica, usado en las jeringas comunes, hasta la inspiración para crear las turbinas de los barcos basadas en las ballenas jorobadas.

3.1.1 Célula

Para poder comprender las redes neuronales artificiales (en adelante RNA) es necesario develar los conceptos biológicos y matemáticos en las que están basadas; comenzando con la célula, en (MedlinePlus, 2021) se comenta que la célula “es el componente básico de todos los seres vivos brindan estructura al cuerpo, absorben los

nutrientes de los alimentos, convierten estos nutrientes en energía y realizan funciones especializadas”. Existen diferentes tipos de célula, con sus componentes encargados de actividades específicas, es notable considerar que la célula puede multiplicarse y adaptarse dependiendo las necesidades del organismo. El ser humano está compuesto por millones de células, encargadas de darle vida y funcionamiento.

3.1.2 Sistema nervioso

El sistema nervioso es definido por Etecé (2021) como “el conjunto de órganos y estructuras de control e información del cuerpo humano” Este, regula las funciones del cuerpo humano, poseyendo todo un sistema complejo e increíble.

Las estructuras que componen el sistema nervioso son el cerebro, el cerebelo, el bulbo raquídeo, la médula espinal y los ganglios nerviosos, el cerebro puede ser definido como el “centro de control que almacena, calcula, integra y transmite información” (Lodish, y otros, 2019).

En este órgano como los demás componentes del sistema nervioso se encuentran las células nerviosas denominadas neuronas.

3.1.3 Neurona


Las neuronas en su expresión más básica son las células por excelencia del sistema nervioso, Núñez (2008) menciona que las neuronas “son las células del sistema nervioso encargadas de la transmisión de los mensajes entre el cerebro y el resto de los órganos que componen al cuerpo”.

En cuanto a su composición, Lodish et al (2019) mencionan que “las células están formadas por el soma (cuerpo celular) del cual surgen extensiones ramificadas llamadas dendritas las cuales son las estructuras ramificadas encargadas de recibir señales desde otras neuronas”. Así mismo, Núñez (2008) aporta que “del soma también se desprende el axón, encargado de llevar información del cerebro o hacia el cerebro desde la periferia”

“Los mensajes entre neuronas son transmitidos por medio de impulsos químicos y eléctricos, así, la comunicación entre dos o más neuronas se denomina sinapsis, que se da siempre entre el axón de una neurona y la soma de otra”. (McCulloch & Pitts, 1943).

La sinapsis eléctrica consta en que “las membranas de las células están prácticamente juntas, y en las cuales el impulso nervioso pasa de una célula a otra sin transformarse en un impulso químico.” (Núñez Gonzalez, 2008).

3-1 Activación de Neuronas



Fuente: Ponce (2010)

3.1.4 Redes neuronales biológicas

Finalmente, la mayoría de las neuronas del cerebro son interneuronas, es decir que se conecta con otras neuronas y no con el exterior.

“De esta manera se constituye un complejo sistema que tiene una entrada, que es la única manera de conocer el mundo exterior, propio receptivo e interior receptivo, y una salida, que es la manera como se responde al mundo exterior e interior y se influye sobre éste a través de la conducta motora y las respuestas reflejas” (Arango-Dávila & Pimienta J., 2004)

Finalmente, cabe resaltar que las neuronas generan una extensa red compuesta por millones de ellas, enviándose impulsos eléctricos unas con otras.

3.2 Redes Neuronales Artificiales

Las redes neuronales artificiales en su inicio surgieron como metodologías computacionales que buscaban recrear el sistema neuronal humano en cuanto al aprendizaje, procesamiento e interconexión de información. Las RNA también son conocidas como redes de aprendizaje profundo o simplemente aprendizaje profundo; esto es gracias a las grandes olas de cambios por las que han transcurrido a lo largo de los años.

3.2.1 Definición

Diversos autores tienen diferentes definiciones de las RNA, por ejemplo, Aggarwal (2008) menciona que las redes neuronales artificiales son técnicas populares de aprendizaje automático que simulan el mecanismo de aprendizaje en organismos biológicos.

Por su parte, Géron (2019) comenta que las RNA son el núcleo de las aprendizaje profundo, son versátiles, poderosas y escalables, haciéndolas ideales para abordar tareas de aprendizaje automático grandes y altamente complejas; para entender esto debemos adentrarnos más en el aprendizaje profundo y su relación con las RNA.

Una visión más sobre las RNA es de Ponce (2010) quien las define como sistemas de mapeos no lineales cuya estructura se basa en principios observados en los sistemas nerviosos de humanos y animales. Constan de un número grande de procesadores simples ligados por conexiones con pesos.

Si bien existen múltiples definiciones, se puede rescatar que las RNA usan de ejemplo problemas ya resueltos, similares a los que quieren resolver, y genera un sistema capaz de tomar decisiones y hacer clasificaciones. Las RNA tienen la capacidad de aprender a través del estudio o la experiencia, generando sus propias salidas con base en las entradas proporcionadas. A sí mismo, cuentan con procesadores ligados por pesos y se le llaman neuronas a las unidades de procesamiento, las cuales están interconectadas a través de nodos y finalizan en una o varias neuronas de salida.

$$y = f\left(\sum_k w_k x_k\right) \quad (3.1)$$

Donde:

x_k : señales de salida de otros nodos o entradas externas

w_k : pesos de las ligas de conexión

$f(\cdot)$: función no lineal simple

3.2.2 Alcance de las Redes Neuronales

Las RNA cuentan con múltiples ventajas si se comparan con otras técnicas y sistemas de procesamiento, una de estas ventajas mencionada frecuentemente es su capacidad para solucionar problemas no lineales; esto resulta de gran interés para comparar entre redes neuronales y técnicas tradicionales, así mismo, Ponce (2010) menciona que las RNA pueden sintetizar algoritmos a través de un proceso de aprendizaje, y, contrario a la programación habitual, las RNA continúan trabajando a pesar de la presencia de fallos en los elementos de procesamiento.

Por otro lado, esta técnica sigue presentando ciertos problemas, por ejemplo, la falta de generalización para solucionar cada problema, de igual manera las RNA están sometidas a diversas pruebas y errores para encontrar la arquitectura adecuada para cada problema; la necesidad de muchos datos para su entrenamiento también es una limitante. Si recordamos que la calidad de los datos juega también un papel importante para un buen modelo de red neuronal, podemos encontrar puntos para mejorar de las redes neuronales. Otra de las características en contra de las redes neuronales es la necesidad de normalización adecuada y el tratamiento de los datos para brindar un buen modelo, esto anidado a la demandante cantidad de recursos que utilizan las convirtieron en una técnica poco usada y comúnmente olvidada hasta tiempos más recientes.

3.2.3 Aplicaciones de las RNA

A lo largo de los años desde su creación, las RNA han pasado por diversas etapas que han aumentado su poder predictivo y de clasificación, temas en los que resaltan porque para eso fueron creadas, actualmente podemos verlas en aplicaciones generales como control automático, reconocimiento de voz, análisis de escritura, clasificación binaria, entre otras. Estos modelos han sido personalizados para temas de medicina, computación, desarrollo de aplicaciones, ciencias exactas como física, química, ingenierías, electrónica, robótica entre otras.

En el campo financiero y bursátil, gracias a modelos cada vez más vanguardistas que permiten a las redes resolver problemas de amplia capacidad computacional, de la mano con la modernización de las computadoras, estas técnicas han ayudado en diversos sectores, desde la inflación, el tipo de cambio, precios sectoriales y su utilidad en mercados volátiles, hasta pronósticos del PIB y temas generales financieros. Así mismo, son capaces de aprender relaciones implícitas entre variables y datos incompletos.

3.3 Entrenamiento de RNA

Ponce (2010) define el entrenamiento al “proceso de configuración de una red neuronal para que las entradas produzcan las salidas deseadas a través del fortalecimiento de las conexiones”. Menciona que, en las redes neuronales artificiales, se genera un proceso iterativo con el que se ajustan los parámetros internos (pesos sinápticos) con los ejemplos previos. En este proceso, la red modifica su estructura interna en función de los errores cometidos.

Goodfellow, et al (2016) establecen que, para el entrenamiento, las redes neuronales encuentran los parámetros (pesos y sesgos) que minimizan una función de pérdida sobre un conjunto de datos. Este es un proceso que se puede realizar mediante algoritmos de optimización, como el descenso de gradiente. Cuando la red generaliza los datos no vistos a la par de evitar el sobreajuste o sub-ajuste se puede considerar que cumple su objetivo.

El aprendizaje de los modelos puede clasificarse en supervisado y no supervisado; Ponce (2010) establece que en el aprendizaje supervisado se introducen entradas que

corresponden a determinadas salidas, ya sea por un agente externo o por el mismo sistema. En el segundo caso el entrenamiento se enfoca a encontrar características estadísticas entre agrupamientos de patrones en las entradas.”

Cuando en el modelo a entrenar, las entradas corresponden a una salida conocida se dice que estamos tratando con aprendizajes supervisado, donde se ocupa esa relación conocida para generar predicciones, en las redes neuronales este aprendizaje se encuentra en la clasificación de imágenes Goodfellow et al. (2016), declara que el aprendizaje supervisado se formaliza como la optimización de una función de coste sobre un conjunto de datos etiquetado, donde cada ejemplo x_i tiene una etiqueta y_i .

Por otro lado, en el aprendizaje no supervisado el modelo se entrena sin etiquetas en los datos, su objetivo radica en encontrar patrones en el algoritmo, procurando reducir dimensiones o detectar anomalías sin conocer las salidas expresamente. Entre los algoritmos más comunes de este tipo de aprendizaje se encuentran los K-means, autoencoders o redes SOM. Chollet (2018) destaca que los modelos no supervisados aprenden representaciones útiles mediante la reconstrucción (como en autoencoders) o la predicción de contexto (como en modelos generativos).

Entonces, el objetivo de las redes neuronales es entrenarlas encontrando pesos y sesgos que minimicen la función de costo cuadrático, para ello se puede centrar en la idea de minimizar una función con múltiples variables.

3.3.1 *Descenso de gradiente*

En el aprendizaje profundo, generalmente llega un punto en el que se requiere optimizar alguna función, es decir, maximizar o minimizar la función $f(x)$ alterando x , dicha función se llama función objetiva, o criterio, y en el caso de minimización suele conocerse como función de costo, función de pérdida o función de error.

Bajo este concepto, se hace uso de las derivadas parciales de la función, haciendo un pequeño cambio en x para cambiar y , Así, se reduce la función $f(x)$ en pasos pequeños con el signo opuesto de la derivada, generando lo que se conoce como descenso de gradiente. En el descenso de gradiente, se comienza por tomar valores aleatorios en la

función, y mejorando esos valores gradualmente, disminuyendo la función de costo hasta que converge a un mínimo.

Géron (2019) comenta que el descenso de Gradiente “es un algoritmo de optimización muy general, capaz de encontrar soluciones óptimas para una amplia variedad de problemas. La idea principal del descenso de gradiente es ajustar los parámetros de forma iterativa con el fin de minimizar una función de coste.”

El descenso de gradiente es el algoritmo más utilizado en el aprendizaje profundo, una vez que la derivada es igual a 0, se dice que se llega al mínimo global, que es el objetivo del algoritmo. Sin embargo, las funciones pueden presentar subidas y bajadas que dificultan el hallazgo del mínimo global encontrando en su lugar mínimos locales, normalmente, en redes neuronales genéricas se vuelve suficiente encontrar algún mínimo local lo suficientemente bueno.

Ecuación 3.3.2 Descenso de Gradiente

(3.2)

$$x_{n+1} = x_n - \alpha \nabla f(x_n)$$

donde

x_n := *punto actual*,

α := *representa la tasa de aprendizaje, y*

$\nabla f(x_n)$:= *vector gradiente de la función de costo en x_n*

Un parámetro importante en este algoritmo es la tasa de aprendizaje, que mide el tamaño de los pasos con los que se ajusta el gradiente en cada iteración, determinado por el hiperparámetro de la tasa de aprendizaje. Si la tasa de aprendizaje es demasiado pequeña, entonces el algoritmo tendrá que realizar muchas iteraciones para converger, lo que tomará mucho tiempo. Por otro lado, si la tasa de aprendizaje es demasiado alta, podrías saltar a través del valle y terminar en el otro lado, posiblemente incluso más arriba

que antes. Esto podría hacer que el algoritmo diverja, generando valores cada vez mayores y fallando en encontrar una buena solución.

Uno de los principales problemas en el descenso de gradiente se da porque el algoritmo ocupa el conjunto de datos completo de entrenamiento, generando el cálculo del descenso paso a paso lo que lo vuelve demasiado lento, especialmente con conjuntos de datos demasiado grandes, para ello, podemos encontrar variantes del descenso de gradiente que se enfocan según las necesidades del modelo a entrenar.

Gradiente por lotes (batch), calcula el gradiente sobre el conjunto de datos a entrenar completo, y actualiza el parámetro luego de este cálculo, en esta variante se obtiene un gradiente exacto pero muy lento en sus cálculos y costoso en memoria.

Por otro lado, el gradiente estocástico (SDG) aplica el gradiente calculado a un solo dato por iteración, es decir que se actualiza con más frecuencia, entre sus principales ventajas destacan la rapidez con la que se generan los cálculos a pesar de usar conjuntos de entrenamiento grandes y es capaz de sobreponerse a los mínimos locales, sin embargo, también produce un gradiente en ciertas ocasiones ruidoso.

Típicamente, el algoritmo del descenso de gradiente puede dividirse en 6 pasos,

1. Iniciar los parámetros, es decir la elección de los valores iniciales para los pesos y los sesgos de la red, normalmente se trata de valores aleatorios.
2. Propagación hacia adelante, donde se calcula la salida de la red para la entrada actual.
3. Cálculo del error, donde se evalúa la función de costo normalmente con el error cuadrático medio, como sigue:

$$C = \frac{1}{N} \sum_{i=1}^N (y_i - a_i)^2 \quad (3.3)$$

4. Cálculo de gradientes, donde se determina la derivada parcial de la función de costo.
5. Actualización de parámetros, donde se modifican los parámetros en función del algoritmo.

$$\theta_{n+1} = \theta_n - \alpha \frac{\partial C}{\partial \theta_n} \quad (3.4)$$

6. Verificación de criterio de parada: donde se verifica si se alcanzó la convergencia o el máximo de iteraciones, aquí se detiene el algoritmo si alguna de las condiciones se cumple.

Finalmente, Chollet (2018) menciona que, en las técnicas de redes neuronales, el descenso de gradiente significa encontrar analíticamente la combinación de pesos que produzcan la menor función de pérdida, resolviendo la ecuación en la que el resultado sea 0.

3.4 Arquitectura de Redes Neuronales

Ponce (2010) menciona que “Para enseñarle a la red neural es necesario entrenar un conjunto de datos, el cual consiste en señales de entradas $x_1, x_2 \dots, x_n$ asignadas con objetivos correspondientes (salidas deseadas) denominados z . El entrenamiento es un proceso iterativo. En cada iteración los pesos de los nodos se modifican usando nuevos datos del conjunto para el entrenamiento. Las modificaciones de los pesos se calculan empleando el algoritmo de retropropagación del error para el entrenamiento supervisado.”

(Aggarwal, 2018) expone que “en la red de una sola capa, un conjunto de entradas se asigna directamente a una salida mediante el uso de una variación generalizada de una función lineal. Esta instalación también se conoce como perceptrón. En las redes neuronales multicapa, las neuronas están dispuestas en capas, en las que las capas de entrada y salida están separadas por un grupo de capas ocultas. Esta arquitectura de capas de la red neuronal también se denomina red de retroalimentación.”

La mayoría de las redes neuronales están compuestas por una o más capas de entrada, seguidas de las capas de ocultas y funciones de activación; finalmente las respuestas son enviadas a una capa de salida. Las capas se encuentran conectadas mediante pesos o valores y dentro de cada neurona se generan funciones de entrenamiento para la activación del procesamiento.

La mayoría de las RNA cuentan con ciertas características y partes para poder realizar sus cálculos, estos son, según Ponce (2010):

- Un conjunto de unidades de procesamiento, también llamado neuronas
- Un estado de activación para cada unidad, equivalente a la salida de la unidad
- Conexiones entre unidades, generalmente definidas por un peso que determina el efecto de una señal de entrada en la unidad.
- Una regla de propagación, que determina la entrada efectiva de una unidad a partir de las entradas externas.
- Una función de activación que actualiza el nuevo nivel de activación basándose en la entrada efectiva y la activación anterior.
- Una entrada externa que corresponde a un término determinado de bias para cada unidad.
- Un método para reunir la información correspondiente a la regla de aprendizaje.
- Un ambiente en el que el sistema va a operar, con señales de entrada e incluso señales de error.

3.5 Funciones de activación

Una de las ventajas más importantes de las redes neuronales sobre otras técnicas de machine learning es el uso de no linealidad para sus modelos de aprendizaje, permitiendo relaciones de aprendizaje más complejas con menores costos y poder computacional. Las redes neuronales ocupan algo llamado funciones de activación para conseguir la no linealidad, pues se trata de operadores matemáticos que transforman las salidas de las neuronas.

Respecto a esto, Aggarwal, (2018) menciona que las funciones de activación son una parte esencial en el diseño de las RNA, estas varían dependiendo de las situaciones de variables que se quieran predecir.

Goodfellow et al. (2016) refuerzan esta idea al señalar que “sin funciones de activación no lineales, incluso una red profunda se comportaría como una simple transformación lineal, incapaz de capturar la complejidad de los datos reales”.


Por su parte, Ponce (2010) comenta que el cuerpo de las neuronas artificiales está representado como un sumador lineal de los estímulos externos z_j , seguida de una función no lineal $y_j = f(z_j)$. Dicha función es mejor conocida como *función de activación*, es la función que utiliza la suma de estímulos para determinar la actividad de salida de la neurona.

El mismo autor describe las funciones de activación más frecuentemente utilizadas, siendo estas:

3.5.1 Función escalón

Asociada a neuronas binarias, cuando la suma de las entradas es mayor o igual que el umbral de la neurona la activación es 1, si no, es 0 o -1

3-2 Función de Activación Escalón




Fuente: Ponce (2018)

3.5.2 Función lineal y mixta

La función lineal o identidad responde a la expresión $F_k(u) = u$. Por su parte, en las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la función se define 0 o -1, en caso contrario es 1. Si la suma está contenida entre dos límites la activación es 1. Si la suma de entrada está comprendida entre ambos límites, superior e inferior, entonces la activación se define como una función lineal de la suma de las señales de entrada.

3-3 Función de Activación Lineal y Mixta




Fuente: Ponce (2018)

3.5.3 Función tangente e hiperbólica

Se emplea en los casos que presentan variaciones suaves de valores positivos y negativos de la señal a clasificar, es una de las funciones más empleadas en los entrenamientos supervisados.

3-4 Función de Activación Hiperbólica




Fuente: Ponce (2018)

3.5.4 Función Sigmoidal

Con esta función, el valor dado es cercano a uno de los valores asintóticos. Esto hace que, en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. Esta función es cercana a 0 en los valores grandes, ya sean positivos o negativos.

3-5 Función de Activación Sigmoidal



Fuente: Ponce (2018)

3.6 Modelos de RNA

3.6.1 Modelo simple de neurona biológica

El primer trabajo que sentó las bases de las redes neuronales tiene sus orígenes en los años 40 de la mano de McCulloch & Pitts (1943) quienes desarrollaron un modelo computacional binario que emulaba las funciones de las neuronas del cerebro humano de manera simplificada (conocido como neurona artificial), creando una estructura matemática que constaba de sistemas con n entradas y una única salida de información, así el resultado podía ser activarse o no activarse, dependiendo del número de entradas.

Géron, (2019) menciona que “el modelo está compuesto por una o más entradas binarias (encendido/apagado) y una salida binaria. La neurona artificial simplemente activa su salida cuando más de un cierto número de sus entradas están activas.”

Sin embargo, para que este modelo lineal funcionara de manera correcta, se tenían que ingresar los pesos de forma correcta a través del usuario, lo cual resultaba complicado en muchos casos.

3.6.2 Perceptrón

Años más tarde del trabajo de McCulloch & Pitts, Frank Rosenblatt creó el que es considerado como el primer modelo de red neuronal llamado perceptrón en 1958; Ponce

(2010) menciona que el perceptrón “consiste en una suma de las señales de entrada, multiplicadas por unos valores de pesos escogidos inicialmente en forma aleatoria.”

De la misma manera, Nielsen (2018) resalta que el perceptrón toma varias entradas binarias $x_1, x_2, \dots, x_1, x_2, \dots$, y produce una sola entrada binaria.

Como última aportación, Géron, (2019) comenta que el perceptrón funciona gracias a una neurona llamada unidad lógica de umbral (TLU), las entradas y la salida ahora son números (en lugar de valores binarios de encendido/apagado) y cada conexión de entrada está asociada con un peso. La TLU calcula una suma ponderada de sus entradas entonces aplica una función escalonada a esa suma, generando un resultado.

El perceptrón puede separar conjuntos de datos linealmente separables, lo cual puede verse de forma gráfica como una línea recta que separa dos clases en dos dimensiones.

3.6.3 Perceptrón Multicapa

A pesar de las ventajas y revoluciones que generó el perceptrón, Minsky & Paper (1969) encontraron deficiencias en sus aplicaciones; Géron, (2019) comenta (basado en el trabajo de Minsky & Paper) que el perceptrón es incapaz de resolver problemas triviales de clasificación (OR, XOR). Sin embargo, estos problemas pueden ser eliminados añadiendo múltiples perceptrones a la red, esto genera una red neuronal denominada perceptrón multicapa.

Géron, (2019) considera que el perceptrón multicapa está compuesto por una capa de salida, una o más capas de unidades lógicas (neuronas) llamadas capas ocultas y una capa final de neuronas conocidas como capas de salida.

3.6.4 Redes de retropropagación (Backpropagation)

Ponce (2010) define el algoritmo de retropropagación como una red que trabaja bajo el aprendizaje supervisado empleado en redes multicapa, en donde se ajusta el valor de los pesos en función al error generado. Por tanto, necesita un conjunto de instrucciones de entrenamiento que describa cada salida y su valor esperado de salida.

Géron, (2019) menciona que el algoritmo de retropropagación es el descenso de gradiente usando una técnica eficiente para calcular los gradientes automáticamente.


Haykin (2009) define la retropropagación como “un algoritmo de aprendizaje supervisado que ajusta los pesos de una red multicapa mediante la propagación hacia atrás del error” (p. 160). Es una aplicación del descenso de gradiente para redes feedforward.

Retomando el descenso de gradiente, este resulta de vital importancia para los modelos de retropropagación, pues en este tipo de red se dan dos etapas, la propagación hacia adelante, que calcula la salida de la red para una determinada entrada y calcula el error de predicción gracias a la función de coste, posteriormente se genera la retropropagación del error, usando el descenso de gradiente y las derivadas parciales para ajustar los parámetros en dirección opuesta al gradiente y así minimizar el error, sobre esto, Nielsen (2018) menciona que el entrenamiento de una red neuronal se basa en el algoritmo de retropropagación del error, que permite calcular cómo cada peso contribuye al error total. Este proceso se combina con el descenso del gradiente estocástico, ajustando los pesos en la dirección que minimiza el error, iterativamente, hasta que la red aprende a realizar predicciones precisas.

3.7 Línea del tiempo de redes neuronales

El estudio y desarrollo de las técnicas de RNA han existido desde hace más de cincuenta años, sin embargo, este se ha visto interrumpido por diversas causas, en este sentido, (Aggarwal, 2018) menciona que las redes neuronales se desarrollaron poco después de la llegada de las computadoras en los años 50's. Sin embargo, han visto su desarrollo truncado debido a diversos factores, a continuación, se presenta una línea del tiempo recopilando las técnicas de redes neuronales más importantes.

3-6 Línea del tiempo RNA



Fuente: Elaboración propia

3.8 Conclusiones del Capítulo

Las redes neuronales muestran ser los próximos pasos en la investigación de diversas áreas del conocimiento, generando nuevos caminos para la toma de decisiones financieras, bursátiles y científicas, su capacidad de adaptación a los distintos problemas y su cada vez menor costo computacional se vuelven prometedores para futuras investigaciones. Además, la velocidad su aprendizaje se pone a prueba cada día, disminuyendo la brecha de su potencial por personas alrededor del mundo.

El estudio del descenso de gradiente ha permitido avances fundamentales en el aprendizaje automático y el entrenamiento de las redes neuronales, sin mencionar su alcance para la inteligencia artificial, convirtiéndose en un punto fuerte para el ajuste de parámetros y por ende, la mejora en la capacidad predictiva y generalización de modelos. Esta técnica ha servido como punto de inicio para la creación de modelos cada vez más sofisticados, con variaciones y adaptaciones que producen resultados sólidos en distintos campos de investigación.

Finalmente, el uso de redes neuronales ha demostrado ser de ayuda en las áreas de finanzas y bursátiles, prueba de ello son los diversos artículos e investigaciones publicados que ocupan su poder de clasificación o predicción para facilitar el análisis bursátil o financiero.

Capítulo IV: Metodología

Introducción

En este capítulo se analizará el caso empírico sobre la creación de valor basado en el EVA y en el GEO a través de las técnicas de inteligencia artificial, en específico de las RNA. En este se analizarán los siguientes apartados que lo conforman:

- Empresas que se analizaron pertenecientes a la BMV.
- Indicadores y ratios que miden el desempeño financiero.
- Construcción de la base de datos.
- Modelos de redes neuronales artificiales.

El capítulo muestra la metodología utilizada para la generación de diez modelos de redes neuronales de retropropagación, cuyas variables independientes son las razones financieras de las emisoras como variables dependientes se toman los valores binarios del GEO y el EVA.

Es importante resaltar que el objetivo de la presente investigación es utilizar las investigaciones de Espinosa, (2024) y Garduño (2023) como punto de referencia para resaltar las diferencias y similitudes entre técnicas tradicionales de clasificación como Análisis de Regresión Logística Binaria y Análisis Discriminante Múltiple y técnicas no lineales como las Redes Neuronales Artificiales de Retropropagación en la generación de valor para pertenecientes a la Bolsa Mexicana de Valores. Para cumplirlo, se hace uso de la base de datos proporcionados por las autoras en formato de hoja electrónica y usada en el desarrollo de sus modelos, ocupando sus emisoras muestreadas, horizonte temporal, cálculos de información financiera, ratios financieros y catalogación de fases de ciclos económicos, pretendiendo recrear las características de sus investigaciones para obtener resultados acorde a los objetivos e hipótesis planteadas.

4.1 Empresas que se analizaron de la Bolsa Mexicana de valores

Basado en las investigaciones de Espinosa, (2024) y Garduño (2023), se consideró el mismo cálculo de muestra para esta investigación, con la técnica de Muestreo Irrestricto Aleatorio Estratificado, arrojando como resultado una muestra representativa de las emisoras que cotizaban en la Bolsa de Valores en 2020, cuando las autoras desarrollan sus modelos.

La población inicial cuenta con 120 emisoras listadas en la BMV, de las cuales se ocupan 96 excluyendo las 24 emisoras pertenecientes al sector financiero, dado que su información contable diverge respecto a los demás sectores; esto es generado por su naturaleza de negocio de captar recursos económicos de diferentes personas físicas o morales para dejarlo a disposición de otras instituciones.

El muestreo se genera con las 96 emisoras restantes, divididas de la siguiente manera: 27 emisoras del sector industrial, 20 del sector Materiales, 19 del sector Productos de Consumo Frecuente, 5 del sector Salud, 15 del sector Servicios y Bienes de Consumo no Básico y 10 del Sector Comunicaciones

4.1.1 Muestreo Irrestricto Aleatorio Estratificado

Martin et al (2007) mencionan que el muestreo estratificado es eficaz cuando la población a estudiar se divide en subconjuntos comportándose de forma homogénea, así, se estudia una serie de estratos de la población y la muestra debe incluir representantes de cada estrato considerado.

El tamaño de la muestra se calculó con la siguiente ecuación:

Ecuación 4.4.1 Muestreo Irrestricto Aleatorio Estratificado

$$n = \frac{\sum_{i=1}^L n(pq)}{N \frac{B^2}{K^2} + \frac{1}{N} \sum_{i=1}^L n(pq)}, n_i = nw_i \quad (4.1)$$

Donde:

n = Tamaño de la muestra

N = Tamaño de la población

N_i = Tamaño del estrato i

L = Número de estratos

p = proporción estimada de éxitos

q = proporción estimada de fracasos

B^2 = Cuadrado de aceptabilidad máxima de error entre la población real y la proporción de la muestra

K^2 = Valor correspondiente de tablas para el nivel de confianza

w_i = Proporción asignada a la muestra i

En este tipo de muestreo, cada estratificación debe tener asignado un número único, (i) quedando como: 1 = Industrial, 2 = Materiales, 3 = Productos de Consumo, 4 = Salud, 5 = Servicios y bienes y 6 = Comunicaciones.

La proporción asignada del factor w_i considera la misma clasificación de las emisoras en los sectores de la BMV; Industrial, Materiales, Productos de Consumo Frecuente, Salud, Servicios y Bienes de consumo no Básico, Comunicaciones.

El nivel de confianza utilizado para la muestra fue del 90%; los parámetros de éxito y fracaso están alineados al 0.800972 y 0.199027 respectivamente. De forma resumida, la ecuación (4.1) y sus parámetros quedan ajustados como:

$$n = \frac{\sum_{i=1}^6 n(1.5941)}{96 \frac{0.1^2}{1.645^2} + \frac{1}{96} \sum_{i=1}^6 n(1.5941)}, n_i = nw_i$$

$n = 29.763681$	$N_4 = 5$	$p \approx 0.8$
$N = 96$	$N_5 = 15$	$q \approx 0.2$
$N_1 = 27$	$N_6 = 10$	$B = 0.1$
$N_2 = 20$	$L = 6$	$K = 1.645$
$N_3 = 19$		

Multiplicando el tamaño de la muestra por los estratos, se genera el número de emisoras que se pueden tomar por estrato, creando una muestra aleatoria que toma en cuenta a cada subconjunto poblacional.

$n = 29.763681$	$n_4 = 29.763681 * \frac{20}{96} = 1.55 \approx 2$
$n_1 = 29.763681 * \frac{27}{96} = 8.37 \approx 8$	$n_5 = 29.763681 * \frac{15}{96} = 4.65 \approx 5$
$n_2 = 29.763681 * \frac{20}{96} = 6.20 \approx 6$	$n_6 = 29.763681 * \frac{10}{96} = 3.10 \approx 3$
$n_3 = 29.763681 * \frac{19}{96} = 5.89 \approx 6$	

Finalmente, el muestreo irrestricto aleatorio arroja los siguientes subconjuntos que incluyen: 8 empresas del sector Industrial, 6 empresas del sector Materiales, 6 empresas del sector Productos de consumo frecuente, 2 empresas del sector Salud, 5 empresas del sector Servicios y Bienes de consumo no básico y, 3 empresas del sector de Comunicaciones; sumando un total de 30 emisoras para esta investigación, se resume en la figura 4-1:

4-1 Número de Emisoras seleccionadas por Sector

Sector	Industrial	Materiales	Productos de Consumo Frecuente	Salud	Servicios y Bienes de Consumo Frecuente	Comunicaciones	Total
Total de emisoras	28	21	23	5	19	10	106
Tamaño de la muestra	8	6	6	2	5	3	30

Fuente: Elaboración Propia

4.1.2 Descripción de la Muestra

Las emisoras que se usan en la investigación correspondientes a la BMV se presentan agrupadas por sectores en la tabla 4-1

Tabla 4-1 Lista de Emisoras por Sector

Emisoras por Sector					
Industrial	Materiales	Productos de Consumo Frecuente	Salud	Servicios y Bienes de Consumo Frecuente	Comunicaciones
ACCELSA	AH	ARCA CONTINENTAL	BEVIDES	ALSEA	AMX
AEROMEX	ALTOS HORNOS	AGRIPEX	FRAGUA	ARISTOS	AXTEL
ALFA	ALFA	BACHOCO	LAB	CIDMEGA	AXTECA
ARA	ALPEK	BAFAR	MEDICA SUR	CIE	CABLEVISION
ASUR	CEMEX	BIMBO	SAB	CMR	MAXCOM
CERAMIC	COLLADO	CHDRAUI		EDORADO	MEGA
CICSA	CONVERTIDORA	COMERCI		ELEKTRA	QUMMA
DINE	CYDSASA	FEMSA		GFAMSA	RCENTRO
GAP	FRES	GAM		GMARTI	TELMEX
GCARSO	GCC	GEUPEC		GOMO	TELEvisa
GEO	GMEXICO	GIGANTE		GPH	TV AZTECA CPO
GISSA	ICH	GMACMA		HILASAL	
GMD	MEXCHEM	GMODELO		IASASA	
GMDR	MORDISCO	GRUMA		INTERAM	
GPO AEROP	MINERA AUTLAN	HERDEZ		LIVEPOL	
HOGAR	MOCTEZUMA	KIMBER		POSADAS	
HOMEX	PPPEL	KOF		REALTUR	
ICA	PE&OLES	MASECA		SANLUIS	
IDEAL	POCHTEC	MINSa		SPORT	
INCARSO	QBINDUS	NUTRISA		VASCONI	
KUO	STEAK	SAVIA			
LAMOSA	TEKCHEM	SORIANA			
OHLMEX	TVITRO	WALMEX			
OMA					
PASA					
PINFRA					
PROP Y OP DE INFRA					
SARE					
TMM					
URBI					

Fuente: Elaboración Propia

A continuación, se presenta una breve descripción de cada emisora seleccionada por sectores, con información proporcionada por la Bolsa Mexicana de Valores.

4.1.2.1 Emisoras del sector Industrial

Clave Emisora	Nombre Comercial	Descripción	Logo
ACCELSA	ACCEL, S.A.B. DE C.V.	Grupo de empresas dedicadas principalmente a la prestar servicios de almacenaje, logística, distribución de mercancías y actividades inmobiliarias.	
CERAMIC	INTERNACIONAL DE CERAMICA, S.A.B. DE C.V.	Empresa dedicada a la producción y comercialización de loseta cerámica para pisos, paredes y recubrimientos.	
GCARSO	GRUPO CARSO, S.A.B. DE C.V.	Controladora de empresas dedicadas a diversas áreas de la actividad económica.	
GPO AEROP	GRUPO AEROPORTUARIO DEL PACIFICO, S.A.B. DE C.V.	Prestación de servicios aeroportuarios a través de los doce aeropuertos que opera la compañía en la región del pacífico.	
HOMEX	DESARROLLADORA HOMEX, S.A.B. DE C.V.	Desarrolladoras de vivienda líderes en México, que destaca también por su gran diversificación geográfica, ya que está presente en 22 estados y 38 ciudades de la república mexicana.	
LAMOSA	GRUPO LAMOSA, S.A.B. DE C.V.	Manufactura y venta de productos para la construcción como revestimientos y adhesivos cerámicos.	
OMA	GRUPO AEROPORTUARIO DEL CENTRO NORTE, S.A.B. DE C.V.	Propietario de los títulos de concesión para administrar, operar y explotar trece aeropuertos de la zona centro norte del país. OMA es una de las compañías líderes de la industria aeroportuaria mexicana, opera y administra 13 aeropuertos.	
PROP Y OP DE INFRA	PROMOTORA Y OPERADORA DE INFRAESTRUCTURA, S.A.B. DE C.V.	Compañía controladora dedicada a actividades relacionadas con la construcción de obras civiles a gran escala, instalaciones industriales y de infraestructura; al mantenimiento y operación de carreteras, puertos y aeropuertos, etc. A través de diversas concesiones otorgadas por el Gobierno Federal y Estatal en México y el extranjero.	

4.1.2.2 Emisoras del sector Materiales

Clave Emisora	Nombre Comercial	Descripción	Logo
ALTOS HORNOS	ALTOS HORNOS DE MEXICO, S.A. DE C.V.	Empresa fabricante de acero y manufacturera de productos relaminables, planos, no planos y tubería con costura, así como subproductos derivados del gas de coque.	
ALPEK	ALPEK, S.A.B. DE C.V.	Controladora de empresas dedicadas a la industria petroquímica. Productor líder en de PTA y PET a nivel mundial, uno de los mayores productores de Rpet y EPS en las Américas y único productor de polipropileno en México.	
CEMEX	CEMEX, S.A.B. DE C.V.	compañía global de materiales para la industria de la construcción que ofrece productos de alta calidad y servicios confiables a clientes y comunidades en América, Europa, África, Medio Oriente y Asia. Produce, distribuye y comercializa cemento, concreto premezclado, agregados y otros productos relacionados en más de 50 países.	
COLLADO	G COLLADO, S.A.B. DE C.V.	Compraventa, transformación, maquila y distribución de productos de acero, empleados principalmente en la industria de la construcción Proporciona procesos de valor agregado, ofreciendo una amplia gama de productos semi procesados y terminados de acero a diversas industrias.	
MINERA AUTLAN	COMPAÑIA MINERA AUTLAN, S.A.B. DE C. V.	Empresa con sede en México dedicada principalmente a la minería, explotación, producción y venta de mineral de manganeso y ferroaleaciones de manganeso.	
MOCTEZUMA	CORPORACION MOCTEZUMA, S.A.B. DE C.V.	Empresa controladora especializada a través de sus subsidiarias en la producción, transporte y bombeo de concreto premezclado. La compañía de enfoca en proveer productos de alta calidad en la industria de la construcción, comprometidos con la calidad, responsabilidad social e innovación.	

4.1.2.3 Emisoras del sector Productos de Consumo Frecuente

Clave Emisora	Nombre Comercial	Descripción	Logo
ARCA CONTINENTAL	ARCA CONTINENTAL, S.A.B. DE C.V.	Empresa controladora, cuyas principales subsidiarias se dedican a la producción y comercialización de bebidas carbonatadas, no carbonatadas propiedad de The Coca-Cola Company, así como botanas saladas bajo las marcas Bokados en México, Inalecsa en Ecuador y Wise en los Estados Unidos.	
BIMBO	GRUPO BIMBO, S.A.B. DE C.V.	Controladora de empresas dedicadas a la elaboración y distribución de productos alimenticios, fabrica más de 13,000 productos y tiene una de las redes de distribución más grandes del mundo, con más de 3 millones de puntos de venta, alrededor de 58,000 rutas y más de 133,000 colaboradores.	
FEMSA	FOMENTO ECONÓMICO MEXICANO, S.A.B. DE C.V.	embotellador independiente más grande de productos Coca-Cola en el mundo, siendo también la cadena de tiendas de conveniencia más extensa y de mayor crecimiento en América, sus principales enbotellados son Coca Cola, Sprite, Fanta, Mundet, Powerade y tiendas como Oxxo.	
HERDEZ	GRUPO HERDEZ, S.A.B. DE C.V.	Líder en el sector de alimentos procesados y uno de los principales jugadores en la categoría de helados en México, así como la empresa de mayor crecimiento en la categoría de comida mexicana en Estados Unidos. La Compañía participa en una amplia gama de categorías, que incluye salsas caseras, productos orgánicos, entre otros.	
NUTRISA	GRUPO NUTRISA, S.A.B. DE C. V.	Compra - venta, producción y comercialización de diversos productos naturistas como helado de yogurt, alimentos de origen natural complementos alimenticios y productos de cuidado personal de origen natural.	
WALMEX	WAL - MART DE MEXICO, S.A.B. DE C.V.	Una de las cadenas comerciales más importantes de la región, siendo controladora de cadena de tiendas de descuento y ropa.	

4.1.2.4 Emisoras del sector Salud

Clave Emisora	Nombre Comercial	Descripción	Logo
FRAGUA	CORPORATIVO FRAGUA, S.A.B. DE C.V.	Controladora de empresas dedicadas principalmente a la compraventa de medicinas, perfumería, fotografía, etc. Se consolida como la cadena más importante del país en ventas por su presencia nacional y la única en su concepto.	
MEDICA SUR	MEDICA SUR, S.A.B. DE C.V.	Dedicada a la prestación de servicios médicos, de diagnóstico y hospitalario; ha presentado un crecimiento sostenido en su estructura y se ha preocupado por contar con equipos médicos de vanguardia y personal altamente calificado, que enfocan su compromiso y capacidad académica y humana a la atención de los pacientes.	

4.1.2.5 Emisoras del sector Servicios y Bienes de Consumo Frecuente

Clave Emisora	Nombre Comercial	Descripción	Logo
ALSEA	ALSEA, S.A.B. DE C.V.	Alsea es el operador líder de establecimientos de comida rápida, cafeterías y comida casual en américa latina y España.	
ARISTOS	CONSORCIO ARISTOS, S.A.B. DE C.V.	Empresa de construcción de obra pública y privada, de estructuras de acero y torres de transmisión eléctrica, así como manejo de rellenos sanitarios	
CIDMEGA	GRUPE, S.A.B. DE C.V.	Controladora de acciones de empresas dedicadas a la operación de hoteles; venta de tiempo compartido; venta de bienes raíces; operación de marinas; clubs de golf y club náutico.	
ELEKTRA	GRUPO ELEKTRA, S.A.B. DE C.V.	Compañía de servicios financieros y de comercio especializado, enfocada a la base de la pirámide socioeconómica; entre sus principales productos se encuentran los de electrodomésticos, línea blanca, electrodomésticos, telefonía, computo, transferencias de dinero, seguros, préstamos prendarios, entre otros	
INTERAM	CORPORACION INTERAMERICANA DE ENTRETENIMIENTO, S.A.B. DE C.V.	Controladora dedicada a la industria del entretenimiento, promoción y organización y venta de boletos para eventos, entre sus principales servicios están los conciertos familiares, exposiciones o convenciones.	

4.1.2.6 Emisoras del sector Comunicaciones

Clave Emisora	Nombre Comercial	Descripción	Logo
AMX	AMERICA MOVIL, S.A.B. DE C.V.	Empresa dedicada a proporcionar servicios de telecomunicaciones a nivel nacional o internacional a clientes residenciales y comerciales que operan en una amplia gama de actividades. Siendo la empresa líder en servicios integrados de telecomunicaciones en Latinoamérica	
AXTEL	AXTEL, S.A.B. DE C.V.	Empresa mexicana de Tecnologías de la Información y Comunicación, atiende los mercados empresarial, gubernamental y mayorista, a través de sus unidades de negocio Alestra (servicios) y Axtel Networks (infraestructura).	
TV AZTECA CPO	TV AZTECA, S.A.B. DE C.V.	Empresa dedicada a la producción de programación para ser transmitida a través de sus propias redes, así como a la venta de esta a nivel nacional y venta de tiempo de publicidad, teniendo como principales productos y servicios novelas, noticias, deportes, entretenimiento y programación adquirida.	

4.2 Preparación de la Información

La investigación de comparación se llevó a cabo con una base de datos proporcionada previamente, por Espinosa (2024) la información fue proporcionada con la herramienta “Econométrica”, una plataforma de análisis de datos, utilizada principalmente por instituciones financieras; dicha herramienta proporciona información como estados financieros históricos, precios de cotizaciones, análisis de gráficos, razones financieras, entre otras. La herramienta se enfoca en empresas de capital abierto en Latinoamérica, como en México, Perú, Colombia, Chile, Argentina, Venezuela y Estados Unidos. Dicha información recuperada es proporcionada por la Bolsa Mexicana de Valores a la plataforma y presentada de forma trimestral.

La información financiera que se recuperó para las emisoras de la muestra fue:

- Balances Generales
- Estado de resultados
- Estado de flujo de efectivo
- Información del mercado y bursátil

La información financiera proporcionada para esta investigación se puede resumir en cuentas de activo, pasivos, estado de resultados, y flujo de caja, a continuación, se muestran las cuentas de activo, pasivo, estado de resultados y flujo de caja utilizadas para los fines de esta investigación en las figuras 4-2, 4-3, 4-4, 4-5.

4-2 Cuentas de Activo para la investigación

Cuentas de Activo
Activo Total
Activo Corriente
Efectivo y eq. Efectivo
Cuentas por cobrar corrientes
Inventarios Corrientes
Maquinaria y equipos
Propiedades, planta y equipo neto
Construccion y obras de infraestructura
Terrenos
Edificios
Maquinarias y equipos
Vehiculos
Buques
Aeronaves
Equipo de Transporte
Construcciones en proceso
Otros equipos

4-3 Cuentas de Pasivo para la investigación

Pasivo
Pasivo Total
Pasivo Corrientre
Otros Cred. Sin costo CP
Deudas Financieras CP
Otros Cred. Sin Costo LP
Patrimonio Neto Consolidado
Res d med. De planes benef

4-4 Cuentas de Edo. Resultado para la investigación

Estado de Resultados
Ingresos Netos
Costos de Ventas
Ganancia Bruta
Utilidad Consolidada
Ganancia (perdida) neta

4-5 Cuentas de Flujo de Caja para la investigación

Flujo de Caja
Flujos de Efectivo Netos procedentes de actividades de operación
Flujos de Efectivo Netos procedentes de actividades de Inversión
Dividendos
Incremento neto de efectivo y equivalentes al efectivo antes del efecto de los cambios en la tasa de cambio
Incremento neto de efectivo y equivalentes al efectivo

Fuentes: Espinosa, (2024)

La información se transformó en información contable y financiera, extrayendo las los indicadores financieros de las emisoras seleccionadas, así mismo se determinan las 33 razones financieras y sus clasificaciones en 5 tipos de razones, seis de Liquidez, siete de Apalancamiento, tres de Solvencia, cinco de Actividad, seis de Rentabilidad, cuatro de Estado de Cambio, y dos de Generación de Valor, cabe mencionar que se agregaron las variables del reloj del ciclo económico para utilizarse como variables en el modelo.

Finalmente se obtiene una base de datos general, en hoja de cálculo de Excel, que considera las empresas seleccionadas, junto con su periodo de observación y las 31 razones financieras que se toman para el estudio, así mismo, la base general presenta los resultados obtenidos de los cálculos mostrados en la figura 4-6:

4-6 Variables consideradas en la investigación

Variable	Variable
ION	Costo de financiar los activos
UO	RION
T	UO*
IO	IO*
Deuda	UADI
Fondos propios	VAC
Deuda + CS	RIONDI
Cetes	GEO
TIIE	GEO Bin
Kd: Costo de la deuda	EVA
Ks: Costo de fondos propios	EVA BIN
K	Indicador coincidente
BDI	Actividad industrial
Gastos financieros	Actividad económica
Gastos extraordinarios	Indicador adelantado
Baidt	Confianza consumidor
K%	Confianza empresarial

Fuente: Elaboración Propia

Para esta investigación, se separan las variables necesitadas, siendo estas las emisoras, y los datos resultantes de obtener las 31 razones financieras para cada emisora, como variables dependientes, los resultados de los cálculos generadores de valor como son el EVA y GEO en su forma binomial, donde 0 se considera como no generadora de valor y 1 como sí genera valor se declaran variables independientes. Hay que mencionar que la información es de tipo numérica, para esta investigación no se usan variables categóricas.

A continuación, la tabla 4-2 presenta una recopilación de la clasificación de los ratios financieros más importantes junto a su abreviación correspondiente, con el fin de entender el rumbo de la investigación.

Tabla 4-2 Descripción de Ratios Financieros

Tipo de Razón	Número de Razón	Indicador Financiero: Relación Contable
Liquidez	Razón 1	AC/PC
	Razón 2	AC/AT
	Razón 3	AC/PT
	Razón 4	(Efect e Inv)/AT
	Razón 5	(AC-INV)/PT
	Razón 6	VAR FE/PT
Apalancamiento	Razón 7	PT/AT
	Razón 8	Intereses pagados/Pasivos con Costo
	Razón 9	Pas Mon ext/Pas Total
	Razón 10	CAP CONT/AT
	Razón 11	PC/AT
	Razón 12	PT/CAP CONT
	Razón 13	VN/CAP TRAB
Solvencia	Razón 14	INT PAG/RES OPER
	Razón 15	PLP/AF
	Razón 16	VN/PT
Actividad	Razón 17	VN/AT
	Razón 18	VN/AF
	Razón 19	CV/INVENT
	Razón 20	Ctas x Cobr/(VN/360)
	Razón 21	360/Días ventas x cobrar
Rentabilidad	Razón 22	Resultados Netos/VN
	Razón 23	Resultados Netos/AT
	Razón 24	RESN/CAPCONT
	Razón 25	RESN/AF
	Razón 26	RESOPER/AF
	Razón 27	DIVIDEFEC/RES EJER ANT
Estado de Cambio	Razón 28	Fl.Der.Cp Trab/VN
	Razón 29	Rec. Gen. Oper/Int. Pag.
	Razón 30	Adq. Planta y Eq./Rec Gen Act Inver
	Razón 31	Tasa crec de util de tres años
Generador de Valor	EVA	UAIDI-(VAC*K%)
	GEO	(UO*/OI*)(RIONDI-K%)

Fuente: Elaboración Propia

La base de datos original está acompañada de otras cuatro hojas de datos, que muestran los ratios financieros de las emisoras seleccionadas en las fases del ciclo

económico mencionadas anteriormente, para un mejor manejo de la información, las autoras asignan a cada fase un carácter numérico, siendo:

1. Expansión
2. Desaceleración
3. Recesión
4. Recuperación

La base de datos general requiere un tratamiento especial, por la existencia de ciertos valores nulos en 4 razones financieras de una emisora en dos periodos; dado que una red neuronal no puede trabajar con valores nulos, estos son remplazados con la media aritmética de los 10 valores más cercanos, dichos ajustes de observan en la figura 4-7:

4-7 Modificaciones previas en BD

Emisora	Periodo	Razón 4	Razón 6	Razón 9	Razón 28
ARISTOS	03/31/2006	0.0182022	0.0136337	0.0047483	130.80304
ARISTOS	06/30/2006	0.018692	0.0110993	0.0052232	78.446161

4.3 Modelo de Redes neuronales de Retropropagación

En esta investigación se hace uso de las redes neuronales de retropropagación en lenguaje de programación Python con el uso de librerías especializadas en redes neuronales como Tensor Flow y Keras.

Tensorflow se describe como una biblioteca de código abierto, cuyo objetivo es desarrollar cálculos numéricos y la construcción de modelos de machine learning, especialmente redes neuronales, basado en operaciones con tensores, por su parte, Keras es una interfaz que funciona con Tensorflow, diseñada para el entrenamiento de redes neuronales y facilitar su construcción.

En estas herramientas, las redes de retropropagación se hacen de forma automática, es decir que el gradiente y la retropropagación del error no necesitan ser declaradas de

forma manual, sin embargo, la arquitectura del modelo, como son las capas, la función de pérdida, optimizador y métricas de evaluación si deben ser declaradas para obtener las redes neuronales deseadas. A continuación, se presentan los pasos generales para el desarrollo de las redes neuronales de retropropagación, el detalle con el código general para el entrenamiento general de la variable EVA se puede consultar en los anexos, los demás casos son generados bajo la misma metodología y arquitectura.

Entorno de trabajo: Los modelos de redes neuronales de retropropagación para esta investigación fueron desarrollados en lenguaje de programación Python 3.11.5, utilizando como entorno de visualización de código Jupyter notebook versión 6.5.4, estas versiones del lenguaje garantizan un entorno actualizado capaz de llevar a cabo los cálculos y las bibliotecas necesarias para esta investigación, así mismo se cuenta con las bibliotecas requeridas para la limpieza visualización, procesamiento de información y entrenamiento de RNA fueron Pandas, Numpy, Matplotlib, Sklearn, y Tensorflow.

Carga y limpieza de datos: El primer paso es cargar los datos a utilizar en la RNA por medio de librerías como Pandas, y modificar las columnas para evitar problemas en el entrenamiento, posteriormente se realizan los ajustes necesarios dentro de los datos, con el fin de compatibilizar el conjunto de datos y el lenguaje de redes neuronales, dentro de este paso se lleva a cabo la transformación de columnas, estandarización de valores separación entre variables predictoras y objetivo y la generación del DataFrame a utilizar.

Preparación de DataFrame: El siguiente paso consiste en generar el DataFrame a entrenar, para ello se clasifican las variables objetivo (salidas), que para la investigación están presentadas como la forma binomial de los indicadores GEO y EVA donde cero indica que no son generadoras de valor y unos que si lo son. Posteriormente se revisan los valores de la salida, garantizando que cumpla con las características necesarias para el modelo. Finalmente se unen las 31 razones financieras y la variable objetivo que se desea entrenar. Dando como resultado un DataFrame listo para entrenamiento.

Arquitectura y Entrenamiento: El siguiente apartado del código presenta la separación formal de variables agrupando las variables explicativas (de entrada) que para

todos los modelos son las razones financieras, y la variable de salida. Esto con el objetivo posterior de escalar las variables explicativas, un paso necesario en las redes neuronales.

Las redes neuronales pueden estar compuestas por cientos o miles de entradas, normalmente se dividen los datos en aquellos que se ocupan para el entrenamiento del modelo y aquellos que se ocupan para validar dicho entrenamiento, sin embargo, los casos de estudio presentan un conjunto de datos relativamente pequeño, que puede caer en un sobreajuste con mucha facilidad, por ello se requiere cierta consideración dentro del entrenamiento, como lo es la división de la información en tres subconjuntos, el primer conjunto permite entrenar el modelo de retropropagación, $(x_{\text{train}}, y_{\text{train}})$ es decir, ajusta los pesos de los datos, permitiendo el aprendizaje, el segundo conjunto $(x_{\text{val}}, y_{\text{val}})$ permite validarlo para ajustar los hiperparámetros declarados, y un tercer subconjunto, $(x_{\text{test}}, y_{\text{test}})$ encargado de la prueba, permitiendo al modelo evaluar el desempeño final en datos nuevos. Con esta división de datos, lo siguiente es revisar la distribución de clases y asegurarse de que las clases no presenten desbalanceo. En este paso existe un conjunto adicional “temp” que existe para separar los datos iniciales y generar los subconjuntos que se mencionan anteriormente. Una vez divididos los subconjuntos del modelo, se valida la estratificación de los datos, verificando el equilibrio entre clases y evitando problemas de balanceo de clases futuros.

Posteriormente se genera la arquitectura del modelo, definiendo un modelo secuencial en Keras con tres capas. En la capa de entrada se presentan 64 neuronas conectadas y 31 variables explicativas, con una función de activación Relu, asegurando la no linealidad desde el inicio; el modelo continua con una regularización que evita el sobreajuste desactivando un porcentaje de las neuronas aleatoriamente. La siguiente capa de neuronas se considera la capa oculta, que reduce la dimensión de las neuronas ocupando una función de activación Relu, seguido por una segunda regularización; finalmente se presenta una capa de salida con una neurona de salida binaria, en esta, se ocupa una función de activación sigmoideal, convirtiendo dicha salida en una probabilidad entre 0 y 1.

En resumen, la capa de entrada le permite al modelo aprender relaciones complejas entre las variables de entrada, la capa oculta refina los aprendizajes de la capa anterior, reduciendo su dimensión y manteniendo la no linealidad, y la capa de salida sirve como clasificación binaria para predecir si la razón financiera aporta a la generación de valor.

Una vez estructurada la arquitectura de la red, se compila el modelo usando el optimizador Adam, que funciona bien para problemas de clasificación, proporcionando un aprendizaje estable y una alta capacidad de adaptación, gracias a su diminuto valor, permite un ajuste automático en la actualización de cada parámetro en la retropropagación. En esta compilación se define una función de pérdida que penaliza los errores en la predicción del modelo calculando la diferencia entre la probabilidad predicha y la clase real, es decir, minimiza el error. Finalmente se agrega una métrica que indica en porcentaje de predicciones correctas sobre el total generado

El siguiente bloque del código define callbacks que permiten mejorar el modelo de red neuronal, se entiende por callbacks en Keras a las funciones ejecutadas en tiempos específicos del entrenamiento con el fin de guardar los procesos, detenerlos en caso de ser necesario o guardar los mejores modelos. En este código se usan para detener el entrenamiento automáticamente si el modelo cesa de mejorar y para guardar el mejor modelo resultante.

Posteriormente se llega al entrenamiento del modelo, utilizando las variables explicativas y objetivo definidas anteriormente, en este punto se establecen las épocas (iteraciones) deseadas en el modelo, considerando las limitaciones de sobreajuste, de la misma forma, se tiene en cuenta el equilibrio entre la velocidad de entrenamiento y la estabilidad de gradientes. Almacenando los resultados obtenidos para su análisis.

Resultados del Modelo: Una vez concluido el entrenamiento de la red neuronal, el código abarca los resultados obtenidos del modelo, presentando la precisión del modelo, función de pérdida, matriz de confusión y métricas generales. Finalmente se extraen los ratios financieros más importantes en la generación de valor del modelo, mostrando su nivel de importancia.

4.3.1 Reporte de Clasificación

El reporte de clasificación es un concentrado de métricas importantes en el modelaje de machine learning para modelos de clasificación. Este reporte incluye medidas como la precisión, exhaustividad, puntuación F1 y soporte, que son calculadas con los datos proporcionados, su interpretación ayuda en la identificación de sesgo, predicciones y desempeño del modelo. A continuación, se presenta una breve descripción de las métricas principales del modelo.

Tabla 4-3 Parámetros del reporte de clasificación

Métrica	Descripción
Precisión	Proporción de verdaderos positivos entre los positivos predichos, es decir la proporción correcta de clasificación.
Exhaustividad	Proporción de verdaderos positivos entre todos los positivos reales, es decir, cuantos elementos de esta clase se encuentran sobre el número total de elementos de esta clase.
Puntuación F1	Media armónica entre precisión y exhaustividad
Soporte	Número de ocurrencias reales entre cada clase del conjunto de prueba

Fuente: Elaboración Propia

Adicional a estas métricas, el reporte de clasificación aporta las métricas de “Macro Avg” y “Weighted Avg”, estos representan el promedio aritmético de las métricas calculadas por clase sin considerar y considerando el número de muestras de cada clase. Estas métricas son útiles por no favorecer clases mayoritarias y reflejar el desempeño global del modelo. Sin embargo, en conjuntos de datos desbalanceados no se vuelven muy eficientes.

4.3.2 Matriz de Confusión

También conocida como matriz de clasificación, Orenes (2022) comenta que es una herramienta que permite observar el desempeño de un algoritmo de aprendizaje supervisado, ordenando los casos en cuatro categorías, falso positivo, falso negativo,

verdadero positivo y verdadero negativo, así se valida si el valor real coincide con el de predicción. En esta matriz, las filas representan las clases reales mientras que las columnas indican los valores de predicción, como se puede observar en la figura 4-8.

4-8 Matriz de Confusión

Matriz de Confusión			
Valores Reales	0	Verdaderos Negativos	Falsos Positivos (Error tipo 1)
	1	Falsos Negativos (Error tipo 2)	Verdaderos Positivos
		0	1
		Valores de Predicción	

Fuente: Elaboración Propia

Aciertos: Representan el número de valores clasificados correctamente, divididos en verdaderos negativos y positivos.

- Los valores verdaderos positivos hacen referencia al número de clasificaciones correctas, aquellas clases que corresponde predecir el algoritmo y en efecto fueron predichas.
- Los valores verdaderos negativos muestran las clases que no obtienen puntuación alta del algoritmo ni pertenecen al subconjunto de pruebas.

Errores: La matriz también muestra los errores del modelo, tipo I Y II

- Error tipo I: Refiere a las clases que han sido predichas, pero no corresponde predecir, es decir, no corresponden al subconjunto de pruebas.
- Error tipo II: Refiere a las clases que no tienen una puntuación alta en el algoritmo, pero son parte del subconjunto de pruebas.

Un modelo idílico asegura que todas las predicciones correspondan a los valores reales, minimizando los errores.

4.4 Análisis de resultados

Una vez establecida la metodología de trabajo, se corrieron diez modelos de retropropagación, dos abarcando los indicadores financieros sin la presencia de ciclos económicos y ocho considerando las cuatro fases del ciclo económico mencionadas anteriormente, es importante mencionar que se utilizó la variable “Indicador Industrial” como guía para filtrar las razones financieras. Es necesario resaltar que en todos los modelos se presenta un buen balanceo de pesos para la variable objetivo, por lo que no es necesario modificar. Todos los modelos entrenados cuentan con la misma arquitectura de red presentada en la tabla 4-4:

Tabla 4-4 Arquitectura de Retropropagación

Arquitectura	Descripción	Valor
Información y entrenamiento	Columnas DF	32
	% Entrenamiento	64%
	% Validación	16%
	% Prueba	20%
	Tasa de Aprendizaje	0.001
	Épocas	100
	Batch Size	32
Capa Entrada	Neuronas Activas	64
	Función Act.	ReLu
	Drop Out	0.3
Capa Oculta	Neuronas Activas	32
	Función Act.	ReLU
	Drop Out	0.2
Capa Salida	Neuronas Activas	1
	Función Act.	Sigmoid
	Optimizador	Adam
Callbacks	Early Stop	Variable

Fuente: Elaboración Propia

En los anexos se puede encontrar el código generado para los modelos de retropropagación, para cada modelo se modifica el conjunto de datos utilizados.

De otra forma, sea $\mathbf{x} \in \mathbb{R}^{31}$ el vector de entrada. La red neuronal secuencial se compone de tres capas densas con activaciones no lineales, y se define como:

Ecuación 4.2 Modelo neuronal de retropropagación

Capa Entrada (64 neuronas, ReLU):

$$\mathbf{z}_1 = \mathbf{W}_1 \cdot \mathbf{x} + \mathbf{b}_1 \quad (4.2)$$

$$\mathbf{a}_1 = \text{ReLU}(\mathbf{z}_1)$$

Capa Oculta (32 neuronas, ReLU):

$$\mathbf{z}_2 = \mathbf{W}_2 \cdot \mathbf{a}_1 + \mathbf{b}_2$$

$$\mathbf{a}_2 = \text{ReLU}(\mathbf{z}_2)$$

Capa de salida (1 neurona, sigmoide):


$$\mathbf{z}_3 = \mathbf{W}_3 \cdot \mathbf{a}_2 + b_3$$

$$\hat{y} = \sigma(\mathbf{z}_3) = 1 / (1 + e^{(-\mathbf{z}_3)})$$

Donde:

- $\mathbf{W}_1 \in \mathbb{R}^{64 \times 31}$, $\mathbf{W}_2 \in \mathbb{R}^{32 \times 64}$, $\mathbf{W}_3 \in \mathbb{R}^{1 \times 32}$ son las matrices de pesos.
- $\mathbf{b}_1 \in \mathbb{R}^{64}$, $\mathbf{b}_2 \in \mathbb{R}^{32}$, $b_3 \in \mathbb{R}$ son los vectores de sesgo.
- $\text{ReLU}(z) = \text{Max}(0, z)$ es la función de activación rectificada.
- $\sigma(z)$ es la función sigmoide.

De manera gráfica, la arquitectura de la red neuronal utilizada en la investigación se presenta en la figura (4-9):



Fuente: Elaboración Propia

Basado en esta arquitectura se presentan los resultados de los modelos generados por retropropagación del error, con una breve descripción de los resultados generales del entrenamiento, la interpretación gráfica de la precisión y la pérdida del modelo, la matriz de confusión y su interpretación. Dichas métricas funcionan para comprobar la validez de los modelos entrenados y se consideran prácticas sólidas para validar modelos de clasificación en redes neuronales.

Dichas prácticas abren paso a la recopilación de ratios financieros que aportan un mayor peso en la generación de valor dado el caso a estudiar. Es importante mencionar que los modelos generados de forma no lineal arrojan resultados diferentes en cada corrida de información, a pesar de contar con los mismos parámetros de arquitectura, para esta investigación se toman los mejores resultados generados en su momento. Vale la pena recordar que las redes neuronales no siempre alcanzan los resultados óptimos en todos los casos presentados, sin embargo, estos cumplen con la metodología estudiada y aportan un valor significativo a la investigación.

4.4.1 Caso EVA

4.4.1.1 General sin ciclos económicos.

La red entrenada para el modelo arroja resultados satisfactorios en sus métricas de clasificación, para el mejor modelo obtenido se muestra una precisión del modelo de 85%, suficiente para ser considerado aprobatorio y una pérdida de .42 que, a pesar de no ser la más óptima si evita incidencias al generar predicciones con una buena calibración en su arquitectura.

En la tabla 4-5 se presenta el reporte de clasificación del modelo, en este se puede ver como la precisión de las clases 0 y 1 se encuentra arriba del 80%, demostrando que la red neuronal clasifica bien, el resultado se respalda con los promedios aritméticos para la precisión, Recall y puntuación F1.

Así mismo, se puede observar un buen entrenamiento del modelo a pesar de un ligero sobreajuste, que se vuelve minúsculo contra la buena precisión del modelo. De otra manera, el modelo no presenta sesgos significativos entre las clases.

Tabla 4-5 Reporte de Clasificación EVA General


EVA General	Precisión	Recall	Puntuación F1	Soporte
0	0.8324	0.8817	0.8563	169
1	0.8817	0.8324	0.8563	179
Accuracy			0.8563	348
Macro Avg	0.857	0.857	0.8563	348
Weighted Avg	0.8577	0.8563	0.8563	348

Fuente: Elaboración Propia

Por su parte, la gráfica de precisión del modelo presentada en la figura 4-10 compara el entrenamiento del modelo y la validación a través de las épocas, aplicando los callbacks indica que el mejor modelo fue encontrado en la época 12 para este caso dando a entender una buena estabilización del entrenamiento y validación a las pocas épocas.

La gráfica también concuerda en el ligero sobreajuste mencionado anteriormente. Por su parte, en la gráfica de la pérdida se puede visualizar una buena convergencia del entrenamiento, demostrado por la pérdida baja y estable alrededor de 0.25.


4-10 Precisión y Pérdida EVA General



Fuente: Elaboración Propia en Python

A continuación, se muestra la matriz de confusión generada para el modelo en la figura 4-11, en este caso se entiende un amplio parámetro de positivos y negativos siendo clasificados correctamente, se puede decir que se trata de un modelo sólido que puede mejorar. Entre las fortalezas del modelo se puede observar simetría en la clasificación indicando un buen balance de este, junto con un bajo número de errores, representando estos el 14% de tasa de error.

4-11 Matriz de Confusión EVA General



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-6 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia, en los anexos se puede consultar la lista completa de ratios financieros y su aportación a la generación de valor. Para este caso, los ratios que aportan más a la generación de valor de forma general son las razones 23, 24, 28, 22, 29, 25, 17, 14, 19 y 16. Los ratios mostrados corresponden a diversas clasificaciones, mostrando un incremento en la importancia de los ratios de rentabilidad, Estado de cambio, Actividad y Solvencia.

Tabla 4-6 Ratios más influyentes modelo EVA General

Caso EVA sin Ciclo Económico			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 23	0.311548	6.60%
2	Razón 24	0.259976	5.51%
3	Razón 28	0.217627	4.61%
4	Razón 22	0.214577	4.55%
5	Razón 29	0.191453	4.06%
6	Razón 25	0.188869	4.00%
7	Razón 17	0.161691	3.43%
8	Razón 14	0.159107	3.37%
9	Razón 19	0.154627	3.28%
10	Razón 16	0.15346	3.25%

Fuente: Elaboración Propia

4.4.1.2 Ciclo económico: Expansión

El siguiente caso incluye el estudio bajo condiciones del ciclo económico de Expansión, presenta una precisión general de 80.39%, con una pérdida de .44, esto quiere decir que el modelo clasifica de manera correcta en la mayoría de los casos, conservando una capacidad predictiva útil para el análisis de información, sin embargo, sigue abierto a la corrección de errores en predicciones. Así mismo, la clase de generación de valor presenta una mejor precisión que la clase de no generación de valor, que se compensa con una mayor exhaustividad.

Como se muestra en la tabla 4-7, la puntuación F1 del modelo indica una alta aprobación del modelo, identificando correctamente los casos positivos, derivando en una precisión del modelo suficiente para ser considerado aprobatorio, se puede notar la confiabilidad al identificar positivos. De forma independiente, la clase 0 muestra una menor precisión, y para la clase 1, el 25% de los positivos no son detectados.


Tabla 4-7 Reporte de Clasificación EVA Expansión

EVA CE 1	Precisión	Recall	Puntuación F1	Soporte
0	0.7407	0.8696	0.8	46
1	0.875	0.75	0.8077	56
Accuracy			0.8039	102
Macro Avg	0.8079	0.8098	0.8038	102
Weighted Avg	0.8145	0.8039	0.8042	102

Fuente: Elaboración Propia

La figura 4-12 nos muestra que el modelo encuentra su mejor rendimiento en las primeras épocas, para la precisión del modelo las curvas presentan una tendencia alcista en toda la gráfica, con una precisión inicial que oscila en .60, sin embargo, esta continúa mejorando, lo mismo para su validación, mostrando señales de un modelo bien entrenado. Por otro lado, en la gráfica de pérdida, se puede observar una tendencia bajista, en el entrenamiento disminuye de forma continua hasta estabilizarse cerca de 0.40, por su parte la validación se muestra a la baja hasta el .55, estas gráficas indican que el modelo converge bien en su entrenamiento, sin embargo, la validación elevada muestra variabilidad y una capacidad limitada de generalización.


4-12 Precisión y Pérdida EVA Expansión



Fuente: Elaboración Propia en Python

Como siguiente punto se presenta la matriz de confusión del modelo en la figura 4-13, el 20% de los datos utilizados como prueba se agrupan en su mayoría como verdaderos positivos y verdaderos negativos, existiendo en la matriz un menor número de errores tipo 1 y tipo 2. Confirmando que el modelo es confiable a la hora de predecir los positivos. De esta matriz se puede concluir un modelo considerado suficiente.

4-13 Matriz de Confusión EVA Expansión



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-8 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de expansión son las razones 16, 23, 9, 13, 30, 4, 18, 26, 17, 25. Los ratios mostrados corresponden a diversas clasificaciones, mostrando un incremento en la importancia de los ratios de solvencia, rentabilidad y apalancamiento.

Tabla 4-8 Ratios más influyentes modelo EVA Expansión

Caso EVA Ciclo Económico de Expansión			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 16	0.14972	3.78%
2	Razón 23	0.146515	3.70%
3	Razón 9	0.145365	3.67%
4	Razón 13	0.138776	3.51%
5	Razón 30	0.138622	3.50%
6	Razón 4	0.134877	3.41%
7	Razón 18	0.134372	3.39%
8	Razón 26	0.133845	3.38%
9	Razón 17	0.132593	3.35%
10	Razón 25	0.129948	3.28%

Fuente: Elaboración Propia

4.4.1.3 Ciclo económico: Desaceleración

El siguiente caso para estudiar es el EVA es en la etapa de desaceleración, de forma general el modelo presenta una precisión del 76% y una pérdida de 0.42; para la clase 0 el modelo acierta 70.59%, indicando un 29.41% de falsos negativos, para esta clase, el Recall de .85 indica alta sensibilidad y su puntuación F1 muestra un buen balance en la clasificación. Por su parte, la clase 1 se vuelve muy confiable al detectar los positivos, su puntuación F1 de .75 muestra una aprobación del modelo suficiente.


Tabla 4-9 Reporte de Clasificación EVA Desaceleración

EVA CE 2	Precisión	Recall	Puntuación F1	Soporte
0	0.7059	0.8571	0.7742	28
1	0.8462	0.6875	0.7586	32
Accuracy			0.7667	60
Macro avg	0.776	0.7723	0.7664	60
Weighted Avg	0.7807	0.7667	0.7659	60

Fuente: Elaboración Propia

El modelo genera las curvas de precisión y desaceleración mostradas en la gráfica 4-14, para el entrenamiento se observa que el modelo mejora progresivamente y logra alcanzar valores altos, por su parte la validación se estabiliza desde 0.75. En la pérdida del modelo existe la tendencia bajista y continua para el entrenamiento, para la validación baja para después estabilizarse, en sus interpretaciones la precisión muestra un aprendizaje estable con un ligero sobreajuste, en la pérdida hay buena convergencia a pesar de que esta no mejora después de cierto punto.


4-14 Precisión y Pérdida EVA Desaceleración



Fuente: Elaboración Propia en Python

A continuación, se presenta la matriz de confusión para el modelo en la figura 4-15 que concuerda con las métricas explicadas en el reporte de clasificación.

4-15 Matriz de Confusión EVA Desaceleración



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-10 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de desaceleración son las razones 23, 24, 22, 29, 11, 8, 21, 18, 17, 16. Los ratios mostrados corresponden a diversas clasificaciones, mostrando un incremento en la importancia de la rentabilidad y el apalancamiento cuando la economía se encuentra en etapa de desaceleración.

Tabla 4-10 Ratios más influyentes modelo EVA Desaceleración

Caso EVA Ciclo Económico de Desaceleración			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 23	0.182672	4.47%
2	Razón 24	0.168076	4.12%
3	Razón 22	0.14525	3.56%
4	Razón 29	0.144007	3.53%
5	Razón 11	0.142645	3.49%
6	Razón 8	0.142523	3.49%
7	Razón 21	0.137492	3.37%
8	Razón 18	0.13726	3.36%
9	Razón 17	0.135581	3.32%
10	Razón 16	0.135015	3.31%

Fuente: Elaboración Propia

4.4.1.4 Ciclo económico: Recesión

En la etapa de recesión, la arquitectura utilizada arroja un modelo con una precisión de 83% y una pérdida de 0.38, adentrando más en las clases particulares el modelo acierta el 81% de las veces que predice la clase 0 y 84% las clases 1, como se observa en la tabla 4-11, para la puntuación F1 se muestra un buen equilibrio entre la precisión y el Recall, con una puntuación de .8 para las clases 0 y .85 para la clase 1. Como resumen, el modelo en este caso tiene un buen desempeño en la clase 1 y el balanceo entre clases es bueno.


Tabla 4-11 Reporte de Clasificación EVA Recesión

EVA CE 3	Precisión	Recall	Puntuación F1	Soporte
0	0.8108	0.7895	0.8	38
1	0.8491	0.8654	0.8571	52
Accuracy			0.8333	90
Macro avg	0.8299	0.8274	0.8286	90
Weighted Avg	0.8329	0.8333	0.833	90

Fuente: Elaboración Propia

En la figura 4-16 se observan las curvaturas de entrenamiento y pérdida en el modelo, para la curva de precisión, en el entrenamiento se pueden notar mejoras constantes que conllevan a valores altos y la validación muestra una trayectoria estable y cercana al entrenamiento, se puede decir que el modelo generaliza de manera constante. Por su parte, la curva de pérdida para el entrenamiento disminuye de forma progresiva junto con su validación, es decir, presenta una buena convergencia.


4-16 Precisión y Pérdida EVA Recesión



Fuente: Elaboración Propia en Python

Adicionalmente se presenta la matriz de confusión para el modelo en la figura 4-17, corroborando los resultados obtenidos en el reporte de clasificación y las gráficas de precisión y pérdida del modelo, la matriz presenta 30 observaciones catalogadas como verdaderos negativos y 45 verdaderos positivos, del lado de los errores el modelo solo clasifica 8 como falsos positivos y 7 como falsos negativos, indicando ser un modelo con buen sustento y confiabilidad.

4-17 Matriz de Confusión EVA Recesión



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-12 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de recesión son las razones 23, 24, 17, 4, 22, 2, 12, 26, 30, 19. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de rentabilidad y actividad.

Tabla 4-12 Ratios más influyentes modelo EVA Recesión

Caso EVA Ciclo Económico de Recesión			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 23	0.194533	4.86%
2	Razón 24	0.153022	3.82%
3	Razón 17	0.144065	0.04%
4	Razón 4	0.140759	3.51%
5	Razón 22	0.140048	3.50%
6	Razón 2	0.14003	3.50%
7	Razón 12	0.139207	3.48%
8	Razón 26	0.138318	3.45%
9	Razón 30	0.136535	3.41%
10	Razón 19	0.134403	3.36%

Fuente: Elaboración Propia

4.4.1.5 Ciclo económico: Recuperación

El último caso que analiza el indicador EVA es el ciclo económico de recuperación, el modelo muestra una precisión del 82% y una pérdida de 0.49; particularmente, para la clase 0 el modelo acierta el 82% de las veces, con una sensibilidad del 89% en los negativos reales y una puntuación F1 sólida. En la clase de generación de valor muestra un 38% de falsos negativos y una alta confiabilidad para predecir la generación de valor.


Tabla 4-13 Reporte de Clasificación EVA Recuperación

EVA CE 4	Precisión	Recall	Puntuación F1	Soporte
0	0.8226	0.8947	0.8571	57
1	0.8235	0.7179	0.7671	39
Accuracy			0.8229	96
Macro avg	0.8231	0.8063	0.8121	96
Weighted Avg	0.823	0.8229	0.8206	96

Fuente: Elaboración Propia

La figura 4-18 muestra las curvas de entrenamiento del modelo, para la precisión muestra un aprendizaje sólido, a pesar de una variación en las épocas, que indica sensibilidad en los datos, por su parte, la gráfica de pérdida muestra una continua disminución para el entrenamiento y un leve aumento en la validación indicando el inicio de un sobreajuste para las últimas épocas.


4-18 Precisión y Pérdida EVA Recuperación



Fuente: Elaboración Propia en Python

Finalmente, en el análisis del modelo se incluye la matriz de confusión mostrada en la figura 4-19, indicando una baja tasa de falsos positivos y negativos en el modelo, reafirmando los resultados previamente explicados.

4-19 Matriz de Confusión EVA Recuperación



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-14 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de recesión son las razones 23, 31, 12, 19, 20, 1, 16, 17, 8, 26. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de rentabilidad y actividad, sumando visibilidad al apalancamiento y la solvencia, este modelo diversifica los 10 ratios más importantes en todas las clasificaciones.

Tabla 4-14 Ratios más influyentes modelo EVA Recuperación

Caso EVA Ciclo Económico de Recuperación			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 23	0.179706	4.43%
2	Razón 31	0.151375	3.73%
3	Razón 12	0.149438	3.68%
4	Razón 19	0.147432	3.63%
5	Razón 20	0.142844	3.52%
6	Razón 1	0.139673	3.44%
7	Razón 16	0.139192	3.43%
8	Razón 17	0.138151	3.40%
9	Razón 8	0.138002	3.40%
10	Razón 26	0.13632	3.36%

Fuente: Elaboración Propia

4.4.2 Caso GEO

Como siguiente indicador para la generación de valor se utiliza el indicador GEO, utilizando el mismo conjunto de datos y la misma arquitectura de red neuronal que en el indicador EVA, se obtienen los siguientes resultados para las etapas del ciclo económico.

4.4.2.1 General sin ciclos económicos.

El primer caso del indicador GEO se presenta sin ciclos económicos, en este escenario el modelo se entrena con un conjunto de 1740 datos y presenta una precisión general del 70%, acompañado de una pérdida de 0.69; de forma particular el modelo presenta una precisión moderada para la clase 0 de .68 y un Recall de 0.60, indicando que el modelo subestima la clase, ignorando casos. Para la clase 1 se obtienen parámetros más elevados, con una precisión de 0.70 y un Recall de 0.78, de forma positiva se puede recabar que el modelo no presenta desbalance entre clases, manteniendo consistencias en las categorías y una ligera ventaja a la clase 1.


Tabla 4-15 Reporte de Clasificación GEO General

GEO General	Precisión	Recall	F1-Score	Support
0	0.6889	0.6	0.6414	155
1	0.7089	0.7824	0.7438	193
Accuracy			0.7011	348
Macro avg	0.6989	0.6912	0.6926	348
Weighted Avg	0.7	0.7011	0.6982	348

Fuente: Elaboración Propia

En la figura 4-20 se encuentran las gráficas de precisión y pérdida del modelo, divididas cada una en el entrenamiento y la validación; las gráficas de precisión del modelo mejoran su rendimiento progresivamente, en la curva del entrenamiento se puede observar un buen aprendizaje, posicionándose por encima de la gráfica de validación, mientras tanto, las gráficas de pérdida del modelo disminuyen de forma estable en el modelo, indicando así mismo una generalización de la validación aceptable.

4-20 Precisión y Pérdida GEO General




Fuente: Elaboración Propia en Python

El conjunto de datos utilizados para la prueba del modelo sirve como referencia para obtener la matriz de confusión, de esta forma, se puede observar en la figura 4-21

que 151 datos son predichos pertenecientes a la clase 1 siendo que son de hecho de la clase 1, y 93 predichos de la clase 0 y corresponder en efecto a la clase 0, en este modelo, existen 62 falsos positivos y 42 falsos negativos, indicando un mejor desempeño para la clase 1 y coincidiendo en los resultados del reporte de clasificación.

4-21 Matriz de Confusión GEO General



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-16 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa general son las razones 23, 22, 8, 28, 11, 31, 6, 25, 13, 1. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de rentabilidad y apalancamiento.

Tabla 4-16 Ratios más influyentes modelo GEO General

Caso GEO sin Ciclo Económico			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 23	0.162195	3.99%
2	Razón 22	0.150025	3.69%
3	Razón 8	0.149774	3.69%
4	Razón 28	0.149544	3.68%
5	Razón 11	0.143061	3.52%
6	Razón 31	0.141687	3.49%
7	Razón 6	0.141201	3.48%
8	Razón 25	0.138519	3.41%
9	Razón 13	0.13782	3.39%
10	Razón 1	0.133596	3.29%

Fuente: Elaboración Propia

4.4.2.2 Ciclo económico: Expansión

El siguiente caso en la investigación es el modelo generado con el indicador GEO cuando el ciclo económico se encuentra en la etapa de Expansión, para este modelo el conjunto de datos resulta ser el mismo ocupado para el caso EVA en expansión, con un total de 510 datos, de ellos el modelo ocupa 102 como prueba y sirven para obtener los resultados siguientes:

En el reporte de clasificación el modelo cuenta con una precisión del 63.73% y una pérdida de 0.64, en este modelo a comparación con el indicador EVA se puede observar un desempeño menor en las métricas obtenidas con la misma arquitectura, de forma más particular la clase 0 existe una precisión estable del 60.98%, sin embargo, se puede notar un Recall bajo de 0.54 y una puntuación F1 de 0.57; por su parte, en la clase 1 del desempeño se mejora, con un Recall de .71 y una puntuación F1 de 0.68.


Tabla 4-17 Reporte de Clasificación GEO Expansión

GEO CE 1	Precisión	Recall	Puntuación F1	Soporte
0	0.6098	0.5435	0.5747	46
1	0.6557	0.7143	0.6838	56
Accuracy			0.6373	102
Macro avg	0.6327	0.6289	0.6292	102
Weighted Avg	0.635	0.6373	0.6346	102

Fuente: Elaboración Propia

Como siguiente punto se presentan las gráficas de precisión y pérdida del modelo en la figura 4-22, en la gráfica de precisión el entrenamiento mejora de forma sostenida, sin embargo, la validación presenta una tendencia al cista hasta cierta época donde se estabiliza, indicando que el modelo no mejora después de ese punto. Por otro lado, en la gráfica de pérdida el entrenamiento disminuye de forma consistente, sin embargo, el comportamiento de la validación de la pérdida indica un sobreajuste o ruido en el conjunto de datos.


4-22 Precisión y Pérdida GEO Expansión



Fuente: Elaboración Propia en Python

Finalmente se muestra la matriz de confusión del modelo de Expansión en la figura 4-23, con un total de 102 datos solo 16 resultan ser falsos negativos y 21 falsos positivos. Por otro lado, el modelo encuentra 25 observaciones en verdaderas negativas y 40 como verdaderas positivas, siendo que la proporción de errores es menor al de aciertos.

4-23 Matriz de Confusión GEO Expansión



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-18 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de expansión son las razones 7, 12, 18, 15, 66, 13, 8, 19, 23, 3. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de apalancamiento y actividad.

Tabla 4-18 Ratios más influyentes modelo GEO Expansión

Caso GEO Ciclo Económico de Expansión			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 7	0.150105	3.83%
2	Razón 12	0.144917	3.70%
3	Razón 18	0.141698	3.62%
4	Razón 15	0.139649	3.57%
5	Razón 6	0.138325	3.53%
6	Razón 13	0.13804	3.52%
7	Razón 8	0.135875	3.47%
8	Razón 19	0.132571	3.39%
9	Razón 23	0.131553	3.36%
10	Razón 3	0.130805	3.34%

Fuente: Elaboración Propia

4.4.2.3 Ciclo económico: Desaceleración

El siguiente caso recaba los resultados cuando se presenta la etapa de desaceleración como ciclo económico, el conjunto de datos analizados es de 510 entradas con las ya familiares 32 variables, generando una precisión general de 68.33% y una pérdida de 0.64. De manera más detallada el modelo tiene una precisión para la clase de generación de valor de 70.59% con un Recall bajo de 0.46, de forma detallada, la precisión para la clase 0 es de 70.59% con una puntuación F1 de 0.55, mientras que para la clase 1 la precisión disminuye a 67% con un incremento en la puntuación F1, adicional no se presenta desbalance en las clases, sin embargo, el modelo favorece a la clase 1, denotado por la diferencia entre los Recall de las clases.


Tabla 4-19 Reporte de Clasificación GEO Desaceleración

GEO CE 2	Precisión	Recall	Puntuación F1	Soporte
0	0.7059	0.4615	0.5581	26
1	0.6744	0.8529	0.7532	34
Accuracy			0.6833	60
Macro avg	0.6902	0.6572	0.6557	60
Weighted Avg	0.6881	0.6833	0.6687	60

Fuente: Elaboración Propia

Por su parte, en la figura 4-24 se presentan la gráfica del modelo generada para la precisión, que muestra que la validación supera a la generada por el entrenamiento, indicando una buena generalización del modelo, la gráfica de la pérdida se puede observar un aprendizaje efectivo, respaldado por la disminución progresiva en las curvas de entrenamiento y validación.


4-24 Precisión y Pérdida GEO Desaceleración



Fuente: Elaboración Propia en Python

Como última muestra de resultados para este modelo se presenta la matriz de confusión en la figura 4-25 generada de las 60 observaciones que el modelo utiliza como prueba, en la matriz se pueden encontrar 12 aciertos y 14 errores para la clase 0, indicando que el modelo sobreclasifica como clase 1, por otra parte, para la clase 1 se presentan 29 aciertos y 5 errores, es decir una excelente sensibilidad del modelo para clasificar la generación de valor.

4-245 Matriz de Confusión GEO Desaceleración



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-20 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de desaceleración son las razones 21, 29, 23, 24, 1, 7, 28, 2, 9, 30. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de actividad y rentabilidad, sin embargo el concentrado de estado de cambio resulta importante para esta etapa del ciclo económico.

Tabla 4-20 Ratios más influyentes modelo GEO Expansión

Caso GEO Ciclo Económico de Desaceleración			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 21	0.141258	3.67%
2	Razón 29	0.139548	3.63%
3	Razón 23	0.137517	3.57%
4	Razón 24	0.136148	3.54%
5	Razón 1	0.135164	3.51%
6	Razón 7	0.134194	3.49%
7	Razón 28	0.132095	3.43%
8	Razón 2	0.131301	3.41%
9	Razón 9	0.130345	3.39%
10	Razón 30	0.129581	3.37%

Fuente: Elaboración Propia

4.4.2.4 Ciclo económico: Recesión

El siguiente caso presenta los resultados del conjunto de datos cuando se encuentra en etapa de recesión, con un conjunto de 450 datos el número separado para los análisis de resultados es de 90 observaciones, generando una precisión general del modelo de 55.5% y un Recall de 0.71, siendo el modelo más bajo de todos los entrenados con la red neuronal de retropropagación. De forma más detallada, el modelo clasifica acertadamente el 51% de la clase de no generación de valor y 60% la precisión de la generación de valor. En este caso, el modelo presenta dificultad para generalizar y no se favorece a ninguna clase en particular.


Tabla 4-21 Reporte de Clasificación GEO Recesión

GEO CE 3	Precisión	Recall	Puntuación F1	Soporte
0	0.5111	0.561	0.5349	41
1	0.6	0.551	0.5745	49
Accuracy			0.5556	90
Macro avg	0.5556	0.556	0.5547	90
Weighted Avg	0.5595	0.5556	0.5564	90

Fuente: Elaboración Propia

En la figura 4-26 se presentan las gráficas de precisión y pérdida para el modelo, por un lado, el apartado de la precisión mejora de forma gradual a medida que continúan las iteraciones, así mismo, la validación del modelo presenta oscilaciones demostrando un aprendizaje limitado pero estable. Por otra parte, en la pérdida del modelo ambas curvas son decrecientes respecto a las épocas, y en la validación si bien no presenta sobreajuste de forma severa, en el modelo existe dificultad para generalizar en este caso.

4-26 Precisión y Pérdida GEO Recesión




Fuente: Elaboración Propia en Python

Como última validación de las métricas de este caso se presenta la matriz de confusión en la figura 4-27, esta concuerda con los resultados obtenidos en el reporte de

clasificación previamente, contando 23 verdaderos negativos t 27 verdaderos positivos, así como 18 falsos positivos y 22 falsos negativos, para este caso el número de errores es bastante cercando al número de aciertos del modelo, mostrando ser el modelo de más bajo rendimiento con la arquitectura presentada.

4-27 Matriz de Confusión GEO Recesión



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-26 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de desaceleración son las razones 15, 8, 19, 4, 27, 22, 25, 21, 7, 18. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de solvencia, apalancamiento y actividad.

Tabla 4-26 Ratios más influyentes modelo GEO Recesión

Caso GEO Ciclo Económico de Recesión			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 15	0.143189	3.62%
2	Razón 8	0.139884	3.53%
3	Razón 19	0.138625	3.50%
4	Razón 4	0.137708	3.48%
5	Razón 27	0.137293	3.47%
6	Razón 22	0.13715	3.46%
7	Razón 25	0.136393	3.44%
8	Razón 21	0.135942	3.43%
9	Razón 7	0.131365	3.32%
10	Razón 18	0.130619	3.30%

Fuente: Elaboración Propia

4.4.2.5 Ciclo económico: Recuperación

Como último caso se entrena la red neuronal en el indicador GEO para la etapa de recuperación del ciclo económico, en este caso se dispuso de 480 observaciones, dejando 96 para la prueba y obteniendo las siguientes métricas:

El modelo de forma general tiene una precisión de 64.58% y una pérdida de 0.82, siendo la perdida más elevada, de forma más particular la clase 0 cuenta con una precisión aceptable de 0.633 y un Recall bajo de 0.4524, en la generación de valor se muestra un Recall elevado de 0.79 y una puntuación F1 de 0.71, mostrando así una mayor sensibilidad a la generación de valor y captando la mayoría de los casos.


Tabla 4-22 Reporte de Clasificación GEO Recuperación

GEO CE 4	Precisión	Recall	Puntuación F1	Soporte
0	0.6333	0.4524	0.5278	42
1	0.6515	0.7963	0.7167	54
Accuracy			0.6458	96
Macro avg	0.6424	0.6243	0.6222	96
Weighted Avg	0.6436	0.6458	0.634	96

Fuente: Elaboración Propia

En la figura 4-28 se presentan las gráficas de precisión y perdida del modelo, en la precisión se puede notar como se mejora el entrenamiento y la validación, indicando estabilidad y en la perdida se observa la disminución sostenida de ambas curvaturas, indicando igual una buena generalización del modelo.

4-28 Precisión y Pérdida GEO Recuperación




Fuente: Elaboración Propia en Python

Como ultima validación se presenta la matriz de confusión del modelo en la figura 4-29, en ella se pueden observar 19 verdaderos negativos y 43 verdaderos positivos,

coincidiendo con las métricas del reporte de clasificación, igualmente se presentan 23 falsos positivos y solo 11 falsos negativos.

4-29 Matriz de Confusión GEO Recuperación



Fuente: Elaboración Propia en Python

Con estos resultados se pueden revisar los ratios financieros que resultaron ser más importantes en la generación de valor, se muestra en tabla 4-23 los diez ratios más importantes del modelo, ordenados de forma ascendente por su peso promedio y porcentaje de importancia. Para este caso, los ratios que aportan más a la generación de valor en la etapa de desaceleración son las razones 22, 31, 23, 4, 3, 20, 28, 30, 8, 21. Los ratios mostrados corresponden a diversas clasificaciones, manteniendo su importancia para los ratios de rentabilidad, estado de cambio y liquidez.

Tabla 4-23 Ratios más influyentes modelo GEO Recuperación

Caso GEO Ciclo Económico de Recuperación			
Clasificación	Razón	Peso Promedio	Importancia
1	Razón 22	0.156069	3.82%
2	Razón 31	0.152896	3.74%
3	Razón 23	0.152828	3.74%
4	Razón 4	0.149341	3.66%
5	Razón 3	0.146931	3.60%
6	Razón 20	0.146091	3.58%
7	Razón 28	0.1402	3.43%
8	Razón 30	0.139954	3.43%
9	Razón 8	0.137384	3.36%
10	Razón 21	0.134715	3.30%

Fuente: Elaboración Propia

4.4.3 Resumen de Redes Neuronales de Retropropagación

Para esta investigación los modelos de redes neuronales de retropropagación clasificaron los ratios financieros según su aportación, bajo este entendido se presentan los 10 ratios más importantes para cada modelo generado en la tabla 4-24 y se describen a continuación:

De manera general, se puede observar que la razón financiera que más aporta a la generación de valor para los indicadores EVA y GEO es la 23 que divide los resultados netos de la empresa, es decir la ganancia o pérdida neta sobre el activo total con el que se cuenta, también conocida como índice de rendimiento de la inversión total. Esta razón pertenece a los ratios de rentabilidad y se presenta en nueve de los diez modelos generados en las primeras posiciones de importancia. Su alta importancia en la generación de valor se explica porque mide el beneficio de la inversión total de una empresa, lo cual se vuelve necesario en cualquier etapa del ciclo económico, con esto, las empresas

pueden saber sus ganancias generales en un periodo de tiempo, apoyando a los analistas o directivos a tomar mejores decisiones en cualquier ciclo económico.

La siguiente razón que más aporta a la generación de valor es la razón 22, presentándose con mayor frecuencia en seis de los diez modelos generados, esta razón se conoce como margen de utilidad neta, esta razón mide la utilidad neta por cada peso de ventas netas. Y también pertenece a los ratios de rentabilidad.

En segundo plano, las razones financieras examinadas se agrupan en seis grupos, en estos se puede ver que las razones financieras que más generan valor para los modelos EVA son:

1. Rentabilidad
2. Actividad
3. Apalancamiento
4. Estado de Cambio
5. Solvencia
6. Liquidez.

La rentabilidad se vuelve importante en cualquier etapa del ciclo económico porque estos miden la capacidad de una empresa para generar utilidades con sus recursos disponibles, lo cual está estrechamente relacionado con la generación de valor de una empresa. Por su parte las razones de actividad son importantes por su capacidad para evaluar como las empresas utilizan sus activos para maximizar su rendimiento.

Por otra parte, los modelos que consideran el índice GEO muestran que las más importantes en la generación de valor tienen un orden diferente,

1. Apalancamiento

2. Rentabilidad
3. Liquidez
4. Actividad
5. Estado de Cambio
6. Solvencia.

Las razones de apalancamiento son aquellos indicadores que miden el nivel de deuda de una empresa con base en su capital y sus activos, se presentan de manera frecuente en la clasificación del GEO, puesto que este indicador procura evaluar la riqueza generada por una empresa, se correlaciona de manera natural con las deudas de esta. En los anexos se pueden consultar las frecuencias de cada razón financiera.

Con estos resultados se puede inquirir una relación entre las razones financieras y la generación de valor sin importar el ciclo económico en que se encuentre.

Tabla 4-24 Ratios financieros generadores de valor

Tipo de Razón	Número de Razón	Indice EVA						Indice GEO					
		General	CE Expansión	CE Desaceleración	CE Recesión	CE Recuperación		General	CE Expansión	CE Desaceleración	CE Recesión	CE Recuperación	
Liquidez	Razón 1				6	6		10		5			
	Razón 2								10	8			
	Razón 3											5	
	Razón 4		6		4						4		4
	Razón 5												
	Razón 6							7	5				
Apalancamiento	Razón 7								1	6	9		
	Razón 8				6	9		3	7		2	9	
	Razón 9		3							9			
	Razón 10												
	Razón 11			5				5					
	Razón 12				7	3			2				
Solvencia	Razón 13		4					9	6				
	Razón 14	8											
	Razón 15								4				
Actividad	Razón 16	10	1	10		7					1		
	Razón 17	7	9	9	3	8			3				
	Razón 18		7	8							10		
	Razón 19	9			10	4			8		3		
	Razón 20					5						6	
	Razón 21			7						1	8	10	
Rentabilidad	Razón 22	4		3	5			2			6		
	Razón 23	1	2	1	1	1		1	9	3		1	3
	Razón 24	2		2	2					4			
	Razón 25	6	10					8			7		
	Razón 26		8		8	10							
	Razón 27										5		
Estado de Cambio	Razón 28	3						4				7	
	Razón 29	5										2	
	Razón 30		5		9					10		8	
	Razón 31					2		6					2

Fuente: Elaboración Propia con resultados arrojados en Python

Conclusiones

Una vez analizados los resultados de esta investigación, en donde se han analizado los aspectos teóricos y empíricos como se generan valor de las empresas de la BMV en entornos de los cambios en los ciclos económicos y aplicándolas con técnicas no paramétricas pertenecientes a machine learning, en este caso las RNA se llegan a las siguientes conclusiones.

Esta investigación parte con el objetivo de utilizar redes neuronales de retropropagación para determinar la generación de valor de ciertas acciones participes en la BMV. Para cumplir con el objetivo se utilizó una arquitectura de red neuronal de retropropagación sobre ratios financieros recopilados por previas autoras con información bursátil de empresas que cotizan en la bolsa Mexicana de Valores en el periodo de 2006-2020.

La técnica se aplicó a 10 casos distintos con el fin de medir la importancia de las razones financieras en la generación de valor de dos índices distintos, siendo estos el EVA y el GEO, reafirmando la importancia en el desempeño financiero para las empresas y, simultáneamente, cumpliendo con los objetivos propuestos.

Las redes neuronales presentan un cambio en las técnicas de clasificación¹, siendo una herramienta potente para estos fines, con los resultados proporcionados por los modelos de retropropagación, para el caso del indicador EVA los ratios de rentabilidad, actividad y apalancamiento muestran ser importantes para el indicador, por ello la investigación concluye que existe relación entre las razones financieras de las emisoras de la BMV y el indicador EVA.

Así mismo, las razones financieras presentan relación directa y diversificada con el índice GEO, como se ha mencionado anteriormente, las razones financieras de apalancamiento y rentabilidad demuestran ser de gran importancia para el indicador y se

¹ Comparadas con los trabajos de Espinosa, P.M. (2024) y Garduño, L.P. (2024)

acepta entonces que existe relación directa entre las razones financieras y el indicador GEO de las emisoras de la BMV en este estudio.

Los resultados de la investigación clasifican la importancia de las razones financieras según la fase del ciclo económico en que se encuentre el conjunto de datos, con estos resultados se presentan para cada modelo los 10 más importantes, dejando ver que existen determinadas fases de los ciclos económicos de México que tienen relación con el indicador GEO de las emisoras de la BMV, al ser estas fases donde la generación de valor se acopla en mejores posiciones.

De manera similar se acepta que existen determinadas fases de los ciclos económicos de México que tienen relación con el indicador EVA de las emisoras de la BMV, puesto que todas las razones financieras tienen presencia en la generación de valor y en las agrupaciones de estas razones en mayor o menor medida.

De acuerdo con la primera hipótesis secundaria plantea que existen determinadas razones financieras de las emisoras de la BMV que tienen relación con el indicador GEO. Esto se acepta para la investigación, pues se demuestra que las razones financieras, en especial aquellas derivadas del apalancamiento se relacionan de manera directa con el indicador GEO en las distintas etapas del ciclo económico.

Continuando con la siguiente hipótesis secundaria planteada que afirma que existen determinadas razones financieras de las emisoras de la BMV que tienen relación con el indicador EVA se llega a su aceptación, pues los modelos de retropropagación generados con el indicador EVA presentan relación con ciertas razones financieras procedentes de las emisoras cotizantes de la BMV.

Como siguiente hipótesis secundaria se plantea que existen determinadas fases de los ciclos económicos de México que tienen relación con el indicador GEO de las emisoras de la BMV. Esta hipótesis es aceptada, derivado de la presencia concentrada de algunas razones financieras en ciertos ciclos y distribuidas de manera consistente, al favorecer ciertos conjuntos de razones se demuestra su importancia para cada ciclo. El ciclo con mayor impacto es el ciclo de recesión, acumulando una mayor presencia de clasificación

de razones en sus primeros lugares, al tener mayor peso se entiende que el ciclo de recesión toma una mayor importancia para la generación de valor.

Como última hipótesis secundaria se establece que existen determinadas fases de los ciclos económicos de México tienen relación con los indicador EVA de las emisoras de la BMV. Esta hipótesis se toma como aceptada, mostrando una mayor concentración de razones mejor clasificadas en ciertos grupos de ratios financieros y demostrando que los ciclos económicos influyen en las emisoras. Los ciclos con mayor impacto son el ciclo de recesión, seguido por el ciclo de desaceleración, esto se presenta en la frecuencia de mayor significancia por tipo de ratio, aquí, los ratios presentan una mayor frecuencia de aparición cuando se la economía se encuentra en estos ciclos económicos.

Para finalizar se planteó la hipótesis principal de este trabajo en la que se afirma que existe relación de determinadas razones financieras y ciclos económicos con los indicadores de creación de valor GEO y EVA de las emisoras de la BMV se puede decir que se pudo demostrar porque los valores con mayor aportación a la generación de valor se encuentran dispersos a lo largo de las razones financiera en mayor o menor medida, impactando en la generación de valor y demostrando su relación con la aplicación de herramientas no lineales como lo son las redes neuronales de retropropagación.

La investigación se resume en una arquitectura de retropropagación para clasificar razones financieras y percibir la generación de valor para los índices GEO y EVA, esta aportación permite a las emisoras tomar mejores decisiones financieras dependiendo el ciclo económico en el que se encuentre el país en ese momento, resulta entonces importante la investigación, proporcionando un modelo confiable que no se encuentra limitado por los parámetros tradicionales lineales, ofreciendo un ajuste de información diferente que ayude a las empresas a mejorar su generación de valor.

Sin embargo, como todo modelo tiene sus respectivas limitantes, abriendo la puerta al mejoramiento de los parámetros utilizados en el ajuste de pesos principalmente, así mismo, como cualquier modelo este se encuentra limitado al conocimiento de la naturaleza de la operación y demás variables que puedan afectar a la generación de valor desde distintas aristas.

Esta investigación presenta futuras áreas de oportunidad para mejorar su precisión y alcances académicos, que deben ser abordados en futuras investigaciones, como la inclusión de variables más particulares y modelos de aprendizaje más profundos.

Es importante que se abran nuevas líneas de investigación en relación con la generación de valor, pues se trata de un tema importante para las empresas y la salud macroeconómica en las que se encuentran, pocas veces analizadas como se pudo observar en la revisión a la literatura. Estas líneas son de diversos orígenes, que podrían ser: aplicar otras técnicas desde nuevos y mejores modelos neuronales hasta aprendizajes con inteligencia artificial u otros más tradicionales, ya sean lineales o no; modelar información con nuevos conjuntos de datos que no se limiten a la BMV, desde otra bolsa de valores como podría ser BIVA, otros mercados de valores alrededor del mundo; comparativas con diferentes horizontes temporales para tener un mejor entendimiento del movimiento de los ciclos económicos y su influencia en las empresas; otros indicadores de generación de valor o KPI's, entre otras ópticas.

Finalmente, las ciencias actuariales se pueden aplicar a diversos campos del conocimiento desde distintos puntos de vista, entre esos puntos esta investigación aporta en el sector financiero y bursátil, así como el uso de técnicas de modelación no lineales, apoyando a los mercados financieros y las emisoras a mitigar riesgos potenciales, con un análisis que permite tomar mejores decisiones a problemáticas bursátiles y financieros.

Bibliografía y Artículos de Referencia

- Aristizábal, M. C. (2006). Evaluación asimétrica de una red neuronal artificial: aplicación al caso de la inflación en Colombia. *Lecturas de Economía*, 73-116.
- Vicentin Masaro, J., & García Arancibia, R. (2017). Redes neuronales para la predicción de precios en el sector lácteo argentino. *Cuadernos del CIMBAGE*, 115-136.
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Cham: Springer.
- Alcarria Jaime, J. J. (2008). *Contabilidad financiera I*. Castellón: Publicacions de la Universitat Jaume I.
- Arango-Dávila, C. A., & Pimienta J., H. J. (2004). EL CEREBRO: DE LA ESTRUCTURA Y LA FUNCIÓN A LA PSICOPATOLOGÍA. *Revista Colombiana de Psiquiatría*, 102-125.
- Austria, M. (2007). Construcción de índices de desempeño financiero mediante el Análisis de Componentes Principales, 2004–2005. *Análisis Económico*, 199-122.
- Banco de México. (18 de Agosto de 2025). *Semblanza histórica del Banco de México*. Obtenido de <https://www.banxico.org.mx/conociendo-banxico/semblanza-historica-historia-.html>
- BBVA México. (2025). *¿Qué son los estados financieros?* Obtenido de BBVA: <https://www.bbva.mx/educacion-financiera/banca-digital/que-son-los-estados-financieros.html?msocid=28f146558c3a6b1c24aa559a8d596ab3>
- BBVA México. (s.f.). *¿Qué es la rentabilidad de una empresa?* Obtenido de Educación Financiera – BBVA México: <https://www.bbva.mx/educacion-financiera/creditos/credito-pyme-rentabilidad-de-una-empresa.html?msocid=28f146558c3a6b1c24aa559a8d596ab3>
- Bolsa Institucional de Valores. (s.f.). *BIVA*. Obtenido de Acerca de: https://www.biva.mx/nosotros/acerca_de
- Bolsa Mexicana de Valores. (2015). *Grupo BMV*. Obtenido de Grupo BMV : <https://www.bmv.com.mx/es/grupo-bmv/acerca-de>
- Bolsa Mexicana de Valores. (23 de Dic de 2015). *Grupo BMV*. Obtenido de <https://www.bmv.com.mx/>
- Bonsón, E., Cortijo, V., & Flores, F. (2009). *Análisis de estados financieros: fundamentos teóricos y casos prácticos*. Madrid: Pearson Educación, S.A.
- Cabrera Llanos, A. I., & Ortiz Arango, F. (2012). Pronóstico del rendimiento del IPC mediante el uso de redes neuronales. *Contaduría y Administración*, 63 - 81.
- Calahorrano, A., Sancan, N., & Montenegro, E. (2023). Análisis de riesgo de los bancos en Ecuador mediante la metodología CAMELS. *KAIRÓS. Revista de ciencias económicas, jurídicas y administrativas*, 116-128.

- Cattlin, B. (Julio de 2020). *¿Cuáles son las bolsas más importantes del mundo?* Obtenido de IG España: <https://www.ig.com/es/estrategias-de-trading/-cuales-son-las-bolsas-mas-importantes-del-mundo--200703?msocid=28f146558c3a6b1c24aa559a8d596ab3>
- Chollet, F. (2018). *Deep Learning With Python*. Shelter Island, NY: Manning Publications Co.
- Cryer, J., & Chan, K. (2008). *Time Series Analysis With Applications in R*. Nueva York: Springer.
- Daniel, M., & Polar, E. (2006). El EVA en la evaluación de alternativas de inversión. *Industrial Data*, 10-13.
- De la Garza, B. (16 de abril de 2025). *¿Qué es BIVA?: Emisoras, requisitos, índices y cómo invertir*. Obtenido de Rankia México: <https://www.rankia.mx/blog/como-comenzar-invertir-bolsa/4006781-que-biva-emisoras-requisitos-indices-como-invertir>
- Del Carpio Gallegos, J. (2005). Las redes neuronales artificiales en las finanzas. *Industrial Data*, 0.
- Díaz Mata, A. (2013). *Matemáticas Financieras*. Ciudad de México: Mc Graw Hill.
- Díaz Mondragón, M. (2014). *Mercados financieros internacionales*. Ciudad de México: Trillas.
- Díaz Rodríguez, H. E., Sosa Castro, M. M., & Cabello Rosales, M. A. (2019). - Desempeño financiero y prácticas administrativas en las microempresas mexicanas: un análisis con redes neuronales artificiales. *Contaduría y Administración*, 1-16.
- Espinosa Brenes, P. M. (2023). Estimación de indicadores financieros determinantes en la generación de valor de empresas de la Bolsa Mexicana de Valores, mediante GEO y ciclos económicos. 2006–2020. *Tesis de licenciatura*. Universidad Autónoma del Estado de México (UAEMex).
- Etecé. (5 de Agosto de 2021). *Sistema Nervioso*. Obtenido de concepto: <https://concepto.de/sistema-nervioso/>
- Fondo Monetario Internacional. (2001). *Manual de estadísticas monetarias y financieras*. Washington: Fondo Monetario Internacional.
- García, O. (2014). Fórmula Du Pont y su rentabilidad, vista desde la óptica administrativa. *Inquietud Empresarial*, 89-113.
- García, O., & Morales, A. (2014). Empresas exitosas y no exitosas que cotizan en la BMV del sector Comercial: Una clasificación con Análisis Discriminante Múltiple, Modelos Logit y Redes Neuronales Artificiales. *Estocástica: Finanzas y riesgo*, 33-62.
- García, P. (2002). Documento de trabajo académico. *Aplicaciones de las redes neuronales en las finanzas*. Madrid, España: Universidad Complutense de Madrid.
- Garduño Campos, L. (2023). Estimación de indicadores financieros determinantes en la generación de valor de empresas de la bolsa mexicana de valores, mediante EVA y ciclos económicos. 2006-2020. *Tesis de Licenciatura*. Universidad Autónoma del Estado de México (UAEMEX).


- Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. Sebastopol: O'Reilly.
- Gonzales Nuñez, M. L. (2008). Las Células de la Mente: El Telar de la Creación. *Acta Universitaria*, 17-20.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2008). *The Elements of Statistical Learning*. Stanford: Springer.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. New York: Prentice Hall.
- Hernández, M. (2014). Modelo financiero para la detección de quiebras con el uso de análisis discriminante múltiple. *InterSedes: Revista de las Sedes Regionales*, 4-19.
- Ibarra Mares, A. (2006). Una perspectiva sobre la evolución en la utilización de las razones financieras o ratios. *Pensamiento & Gestión*, 234-271.
- IBM. (29 de Julio de 2025). *¿Qué es el análisis de componentes principales (PCA)?* Obtenido de IBM Think.: <https://www.ibm.com/mx-es/think/topics/principal-component-analysis>
- Instituto Nacional de Estadística y Geografía (INEGI). (2012). *Lo que indican los indicadores: guía para entender la economía de México*. Aguascalientes: Instituto Nacional de Estadística y Geografía.
- Instituto Nacional de Estadística y Geografía. (s.f.). Interpretación del reloj de los ciclos económicos de México. INEGI.
- Jiménez Caballero, J. (s.f.). UTILIZACIÓN DE REDES NEURONALES EN FINANZAS. *Gestao Financeira*.
- Johnson, C., & Padilla, M. A. (2005). Regularidades no lineales en índices accionarios. Una aproximación con redes neuronales. *El Trimestre Económico*, 765-821.
- Kerst, N. (2018). La q de Tobin como Herramienta de Valuación (Tesis de Maestría). Buenos Aires: Universidad de San Andrés.
- Kirchgässner, G., Wolters, J., & Hassler, U. (2013). *Introduction to Modern Time Series Analysis*. Berlin: Springer.
- Lara Haro, A. (2019). *Medición y control de riesgos financieros*. Ciudad de México: Limusa.
- Lodish, H., Berk, A., Kaiser, C. A., Krieger, M., Bretscher, A., Ploegh, H., . . . Scott, M. P. (2019). *Biología Celular y Molecular*. Ciudad Autónoma de Buenos Aires: Médica Panamericana.
- Marcillo Cedeño, C. A., Aguilar Guijarro, C. L., & Gutiérrez-Jaramillo, N. D. (2021). Análisis financiero: una herramienta clave para la toma de decisiones de gerencia. *593 Digital Publisher CEIT*, 87-106.

- Martin, J. (2018). *Análisis Discriminante Múltiple para la estimación de la probabilidad de insolvencia en empresas del sector industrial del distrito de Bogotá (Tesis de Maestría)*. Bogotá: Universidad Nacional de Colombia.
- Mavila Hinojoza, D., & Polar Falcón, E. (2006). El EVA en la evaluación de alternativas de inversión. *Industrial Data*, 10-13.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 115-133.
- MedlinePlus. (28 de Abril de 2021). *MenlinePlus*. Obtenido de MedlinePlus en español: <https://medlineplus.gov/spanish/genetica/entender/basica/celula/>
- MexicoHistorico.com. (s.f.). *Creación del Banco de México en 1925*. Obtenido de México Histórico: https://www.mexicohistorico.com/paginas/creacin_del_banco_de_mxico_en_1925.html
- Mishkin, F. S. (2014). *Moneda, banca y mercados financieros*. México: Pearson.
- Montenegro Ribeiro, J. M. (2004). Medição de desempenho organizacional nas imobiliárias: um estudo na cidade do Natal-RN. *Dissertação de maestría*. Programa Multiinstitucional e Inter-Regional de Pós-graduação em Ciências Contábeis — Universidade de Brasília (UnB), Universidade Federal da Paraíba (UFPB), Universidade Federal de Pernambuco (UFPE), Universidade Federal do Rio Grande do Norte (UFRN).
- Morales Castro, J. A. (2007). Razones financieras que describen y clasifican a las empresas financieramente exitosas del sector comercial que cotizan en la Bolsa Mexicana de Valores. *Tesis Doctoral*. Distrito Federal: Universidad Autónoma del Estado de México.
- Neely, A., Gregory, M., & Platts, K. (2005). Performance measurement system design: A literature review and research agenda. *International Journal of Operations & Production Management*, 1228-1263.
- Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press.
- Núñez Gonzalez, M. L. (2008). LasCélulas de la Mente: El Telar de la Creación. *Acta Universitaria*, 18, 17-20. Recuperado el 21 de Febrero de 2024, de <https://www.redalyc.org/articulo.oa?id=41630176003>
- Ortiz Arango, F. (2017). Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales diferenciales. *Investigación Económica*, 105-126.
- Ortiz Arango, F., Cabrera Llanos, A., & López Herrera, F. (2013). Pronóstico de los índices accionarios DAX y S&P 500 con redes neuronales artificiales. *Contaduría y Administración*, 203 - 225.
- Ponce, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. México D.F.: Alfaomega Grupo Editor, S.A. de C.V.

- Rehman, S. S. (2013). Relationship between financial leverage and financial performance: Empirical evidence of listed sugar companies of Pakistan. *Global Journal of Management and Business Research: Finance*, 33-38.
- Rivera López, M. I. (2022). Razones financieras. *Presentación*. Universidad Autónoma del Estado de Hidalgo (UAEH), Instituto de Ciencias Económico Administrativas.
- Robles, C. (2012). *Fundamentos de administración financiera*. Tlanepantla: Red Tercer Milenio S.C.
- Rosa, E., & Caio, F. (2011). Relação dos modelos DuPont com o retorno das ações no mercado brasileiro. *Revista Contabilidade & Finanças*, 279-298.
- Rosenblatt, F. (1958). THE PERCEPTRON: A PROBABILISTIC MODEL FOR INFORMATION STORAGE AND ORGANIZATION IN THE BRAIN. *Psychological Review*.
- Ross, S. A., Westerfield, R. W., & Jaffe, J. F. (2012). *Fianzas Corporativas*. Distrito Federal: McGraw-Hill Education.
- Ruíz, R., & Jiménez, J. (2020). Las redes neuronales en su aplicación a las finanzas. *Documento Académico*. Sevilla: Universidad de Sevilla.
- Saavedra García, M. L., Morales Ramírez, A., & Bernal Domínguez, D. (2012). Valuación integral de empresas en México. *Contaduría Universidad de Antioquia*, 131-159.
- Scotiabank. (23 de Mayo de 2024). *Scotiabank*. Obtenido de Scotiabank.com: <https://www.scotiabank.com.mx/glosario-financiero/rentabilidad.aspx>
- Tapia, G. (2017). *Tratado de Finanzas. Negocios, empresas y organizaciones*. Buenos Aires: Thomson Reuters - La Ley.
- Villamil, J. (2009). Aproximación no lineal al modelo de overshooting usando redes neuronales multicapa para el tipo de cambio dólar-peso. *Cuadernos de Economía*, 117-156.

Anexos

5-1 Frecuencia de Razones financieras



En las siguientes imágenes se presenta el código generado en Python para el modelo de retropropagación General del EVA.

Modelo EVA General de Retropropagación

Objetivo: Entrenar una red neuronal de retropropagación que obtenga de salida los ratios financieros necesarios en la generación de valor de una entidad cotizante de la BMV, encontrando (o no) una relación entre las razones financieras y las fases del ciclo económico presentadas por el INEGI, con información de 2006 a 2020.

Las redes neuronales de GEO y EVA son entrenadas con el mismo modelo de red neuronal, es decir, entre los modelos se cambia el conjunto de datos a entrenar dependiendo del indicador objetivo y las fases del ciclo económico.

Para este programa se ocupa la base de datos sin considerar las fases del ciclo económico y salida EVA binomial

Entorno de Trabajo

```
In [ ]: # =====  
# 📁 Manejo de datos y limpieza  
# =====  
import pandas as pd  
import numpy as np  
import os  
  
# =====  
# 📊 Visualización  
# =====  
import matplotlib.pyplot as plt  
import seaborn as sns  
import matplotlib.image as mpimg  
  
# =====  
# 🧠 Imputación y preprocesamiento  
# =====  
from sklearn.impute import KNNImputer  
from sklearn.preprocessing import StandardScaler, MinMaxScaler, OneHotEncoder  
from sklearn.model_selection import train_test_split  
from sklearn.metrics import classification_report, confusion_matrix  
  
# =====  
# 🧠 Redes Neuronales (Keras / TensorFlow)  
# =====  
import tensorflow as tf  
from tensorflow.keras import Sequential, layers, losses, optimizers, metrics  
from tensorflow.keras.layers import Dense, Dropout  
from tensorflow.keras.optimizers import Adam  
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint  
  
# =====  
# 📊 Evaluación de modelos  
# =====  
from sklearn.model_selection import train_test_split  
from sklearn.metrics import classification_report, confusion_matrix  
  
# =====  
# 📄 Utilidades para notebooks  
# =====  
import warnings  
warnings.filterwarnings('ignore') # Silencia warnings innecesarios
```

Carga y Limpieza de Datos

```
In [ ]: # Cargar Base de Datos y mostrar 25 primeras filas.
BD = pd.read_excel('.\\BD\\BASE_DATOS.xlsx', sheet_name='BASE_DATOS')
BD[:25]
# Reemplazar saltos de líneas innecesarios
BD.columns = BD.columns.str.replace('\n', '.')
# Validación de tipos de datos cargados
BD.info()
# Validación de columnas
BD.columns
# Cambiar tipo de dato de columnas que presentan texto (0/0)
cols_to_clean = ['Razón 19', 'Razón 28', 'Razón 30', 'Razón 31']
BD[cols_to_clean] = BD[cols_to_clean].applymap(
    lambda x: x if np.issubdtype(type(x), np.number) else 0
)
BD.info()
# Estadísticas generales del DataFrame
BD.describe(include='all')
# Contar valores NA por columna
na_counts = BD.isna().sum()
print(na_counts)
```

Preparación de Data Frame para RNA

Se debe notar que las variables objetivo dependientes son: 'GEO_BIN' y 'EVA_BIN'; por lo que no son ni categoricas ni numericas. Dichas variables se consideran como salidas, donde el 0 indica que no son generadoras de valor y unos que si lo son.

```
In [ ]: # Identificación de pesos columna objetivo:
BD['EVA_BIN'].value_counts()
# Construcción de Data Frame que contenga las razones financieras y la variable objetivo.
# Lista de razones
razones_fin = [f'Razón {i}' for i in range(1, 32)]
# Columnas adicionales necesarias
objetivo = ['EVA_BIN']
# Construcción de Variables para DataFrame
variables_modelo = razones_fin + objetivo
# DataFrame a entrenar
BD_modelo_EVA_Gral = BD[variables_modelo].copy()
# Verificación de estructura
print(BD_modelo_EVA_Gral.head())
BD_modelo_EVA_Gral.describe(include='all')
# Validación de variable objetivo como tipo entero
tipo = BD_modelo_EVA_Gral['EVA_BIN'].dtypes
print(tipo)
# Validación de no valores Nulos del DataFrame
print(BD_modelo_EVA_Gral.isnull().sum())
```

Arquitectura y Entrenamiento

```
In [ ]: # Separación de variables:
X = BD_modelo_EVA_Gral.drop(['EVA_BIN'], axis=1)
y = BD_modelo_EVA_Gral['EVA_BIN']
razones_fin
# Escalar variables explicativas
# Inicializar el escalador
scaler = StandardScaler()
# Ajustar y transformar X
x_scaled = scaler.fit_transform(X)
# Divisiones de entrenamiento, validación y prueba.
# 1. División inicial: entrenamiento + prueba

# Conjunto temporal temp para separar datos
X_temp, X_test, y_temp, y_test = train_test_split(
    x_scaled, y,
    test_size=0.2,           # 20% para prueba
    random_state=42,
    stratify=y               # Mantiene proporción de clases
)

# 2. División secundaria: entrenamiento + validación
X_train, X_val, y_train, y_val = train_test_split(
    X_temp, y_temp,
    test_size=0.2,           # 20% de lo que queda + 16% del total
    random_state=42,
    stratify=y_temp
)
```

De este paso, se separa el 80% de datos iniciales para luego crear los subconjuntos de entrenamiento y validación. El 20% de datos restante se mantiene como subconjunto de prueba.

```

In [ ]: # Validación de balanceo de Clases
def resumen_clases(y_train, y_val, y_test):
    print("Distribución de clases:")
    print("Entrenamiento:\n", pd.Series(y_train).value_counts(normalize=True))
    print("\nValidación:\n", pd.Series(y_val).value_counts(normalize=True))
    print("\nPrueba:\n", pd.Series(y_test).value_counts(normalize=True))

resumen_clases(y_train, y_val, y_test)

# Arquitectura del Modelo
Eva_G = Sequential([
    Dense(64, activation='relu', input_shape=(X_train.shape[1],)), # Capa de entrada, densa de 64 neuronas con 31 variables ex
    Dropout(0.3), # Regularización para evitar sobreajuste, i.e 30% de las neuronas se desactivan aleatoriamente cada epoca,
    Dense(32, activation='relu'), # Capa oculta, reduce la dimensión y mantiene no linealidad para relaciones complejas
    Dropout(0.2), # Regularización que balancea capacidad y regularización, estabiliza aprendizaje en capas mas profundas
    Dense(1, activation='sigmoid') # Capa de salida binaria, convierte la prob en 0 y 1
])

# Compilación del Modelo
Eva_G.compile(
    optimizer=Adam(learning_rate=0.001),
    loss='binary_crossentropy',
    metrics=['accuracy'])

#Callbacks
early_stop = EarlyStopping(
    monitor='val_loss',
    patience=10,
    restore_best_weights=True
)

guardar_mejor = ModelCheckpoint(
    filepath='mejor_modelo_evaG.h5',
    monitor='val_loss',
    save_best_only=True
)

# Entrenamiento del modelo
history = Eva_G.fit(
    X_train, y_train,
    epochs=100,
    batch_size=32,
    validation_data=(X_val, y_val),
    verbose=1,
    callbacks=[early_stop, guardar_mejor]
)

```

Interpretación Gráfica

```

In [ ]: # Visualización de resultados
plt.figure(figsize=(10,4))
plt.rcParams['font.family'] = 'Times New Roman'

# Precisión
plt.subplot(1,2,1)
plt.plot(history.history['accuracy'], label='Entrenamiento')
plt.plot(history.history['val_accuracy'], label='Validación')
plt.title('Precisión - EVA General')
plt.xlabel('Épocas')
plt.ylabel('Precisión')
plt.legend()

# Pérdida
plt.subplot(1,2,2)
plt.plot(history.history['loss'], label='Entrenamiento')
plt.plot(history.history['val_loss'], label='Validación')
plt.title('Pérdida - EVA General')
plt.xlabel('Épocas')
plt.ylabel('Pérdida')
plt.legend()
plt.tight_layout()
plt.show()

```


Resultados del modelo

```
In [ ]: # Evaluación directa
loss, accuracy = Eva_G.evaluate(X_test, y_test, verbose=0)
print(f"📉 Pérdida en prueba: {loss:.4f}")
print(f"✅ Precisión en prueba: {accuracy:.4f}")
# Predicciones y Umbral
# Obtener probabilidades
y_pred_prob = Eva_G.predict(X_test)
# Convertir a clases (umbral 0.5)
y_pred = (y_pred_prob >= 0.5).astype(int).flatten()
# Matriz de confusión
# Crear la matriz de confusión
cm = confusion_matrix(y_test, y_pred)
plt.rcParams['font.family'] = 'Times New Roman'
# Visualizar la matriz de confusión
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', cmap='Greens')
plt.xlabel('Valores de Predicción')
plt.ylabel('Valores Reales')
plt.title('MC EVA General')
plt.show()
# Métricas de clasificación
# Matriz de confusión
print("Matriz de confusión:")
print(confusion_matrix(y_test, y_pred))
# Reporte detallado
print("\n Reporte de clasificación:")
print(classification_report(y_test, y_pred, digits=4))
```


Pesos de Ratios Financieros

```
In [ ]: # Extraer pesos y sesgos de la primera capa
weights, biases = Eva_G.layers[0].get_weights()
# Verificar dimensiones
print(f"📏 Dimensiones de pesos: {weights.shape}") # (n_features, n_neuronas)
# Calcular importancia promedio absoluta por variable
importance = np.mean(np.abs(weights), axis=1)
# Crear DataFrame con nombres de razones
weight_df = pd.DataFrame({
    'Razón': razones_fin,
    'Importancia (|peso| promedio)': importance
}).sort_values(by='Importancia (|peso| promedio)', ascending=False)
# Mostrar orden de razones más influyentes
print("📊 influyentes según pesos de la primera capa:")
print(weight_df.head(31))
weight_df.sum()
print(f"📋 Nombres de razones: {len(razones_fin)}")
print(f"📋 Importancia calculada: {len(importance)}")
# Normalizar para obtener porcentajes
total_importance = weight_df['Importancia (|peso| promedio)'].sum()
weight_df['Importancia (%)'] = (weight_df['Importancia (|peso| promedio)']/total_importance * 100).round(2)
weight_df[:10]
# Ordenar por importancia
weight_df = weight_df.sort_values(by='Importancia (%)', ascending=False)
# Estilo de gráfico
sns.set(style="whitegrid")
plt.figure(figsize=(10, 6))
sns.barplot(
    data=weight_df,
    x='Importancia (%)',
    y='Razón',
    palette='viridis'
)
# Títulos y etiquetas
plt.title('Importancia Relativa de Razones Financieras (%)', fontsize=14)
plt.xlabel('Importancia (%)', fontsize=12)
plt.ylabel('Razón Financiera', fontsize=12)
plt.tight_layout()
plt.show()
```


5-2 Clasificación de ratios EVA Gral.




5-3 Clasificación de ratios EVA Expansión




5-4 Clasificación de ratios EVA Desaceleración




5-5 Clasificación de ratios EVA Recesión




5-6 Clasificación de ratios EVA Recuperación




5-7 Clasificación de ratios GEO Gral.




5-8 Clasificación de ratios GEO Expansión



5-9 Clasificación de ratios GEO Desaceleración



5-10 Clasificación de ratios GEO Recesión



5-11 Clasificación de ratios GEO Recuperación

