



ESCUELA DE NEGOCIOS

MAESTRÍA EN INTELIGENCIA DE NEGOCIOS Y CIENCIA DE DATOS

**OPTIMIZACIÓN DE PORTAFOLIOS DE INVERSIÓN EN LA BOLSA DE
VALORES DE QUITO, ECUADOR UTILIZANDO REDES NEURONALES
ARTIFICIALES.**

**Profesor
VICTOR GONZALEZ HOLGUIN**

**Autor
JOSÉ JONATHAN OCHOA LUZURIAGA**

2024

RESUMEN

El estudio busca optimizar los portafolios de inversión en la Bolsa de Valores de Quito, Ecuador, utilizando Redes Neuronales Artificiales para maximizar rendimientos y minimizar riesgos. Se extrajeron datos históricos de activos seleccionados desde 2016 y se aplicó la Teoría de Portafolios de H. Markowitz, con algoritmos específicos y simulación Monte Carlo para ponderar los activos. Se implementó Machine Learning para analizar series financieras individuales.

Los resultados indican que las redes neuronales artificiales son efectivas para analizar el comportamiento de empresas en un portafolio, permitiendo una evaluación detallada. Sin embargo, se encontró una discrepancia significativa entre las predicciones teóricas y los resultados reales, lo que sugiere limitaciones en las teorías tradicionales para predecir el rendimiento bursátil en Quito, Ecuador.

El estudio resalta la importancia de la adaptación continua de estrategias de inversión y la gestión de riesgos a lo largo del tiempo, dada la evolución del mercado. La comparación de volatilidades sugiere que este indicador es útil para prever la variabilidad de la cartera y gestionar riesgos.

Palabras clave: Portafolios, Redes Neuronales Artificiales, Bolsa de Valores de Quito, Gestión del Riesgo, Volatilidades

ABSTRACT

The study aims to optimize investment portfolios in the Quito Stock Exchange, Ecuador, using Artificial Neural Networks to maximize returns and minimize risks. Historical data from selected assets since 2016 were extracted, and the Portfolio Theory of H. Markowitz was applied, along with specific algorithms and Monte Carlo simulation to weigh the assets. Machine Learning was implemented to analyze individual financial series.

The results indicate that artificial neural networks are effective in analyzing the behavior of companies in a portfolio, allowing for detailed evaluation. However, a significant discrepancy was found between theoretical predictions and actual results, suggesting limitations in traditional theories to predict stock performance in Quito, Ecuador.

The study underscores the importance of continuous adaptation of investment strategies and risk management over time, given the market's evolution. The comparison of volatilities suggests that this indicator is useful for predicting portfolio variability and managing risks.

Keywords: Portfolios , Artificial Neural Networks, Quito Stock Exchange, Risk Management, Volatilities

ÍNDICE DEL CONTENIDO

1. INTRODUCCIÓN	1
2. REVISIÓN DE LITERATURA.....	3
3. IDENTIFICACIÓN DEL OBJETO DE ESTUDIO	7
4. PLANTEAMIENTO DEL PROBLEMA	9
5. OBJETIVO GENERAL	11
6. OBJETIVOS ESPECÍFICOS.....	12
7. JUSTIFICACIÓN Y APLICACIÓN DE LA METODOLOGÍA	13
7.1 Justificación	14
7.2 Usar RNA para analizar un portafolio de inversión	14
7.3 Evaluación	17
7.4 Técnicas de Aleatorización y Validación Cruzada	18
7.5 Muestreo	19
7.6 Identificación y Mitigación del Sobreajuste	19
7.7 Monitoreo del Rendimiento del Modelo.....	20
7.8 Comparación de Modelos y Selección del Mejor	20
7.9 Predicción del Mercado con Redes Neuronales	21
7.10 Análisis de Regresión OLS y Predicción Intradía.....	21
7.11 Estacionariedad de los Datos y Correlación Temporal	22
7.12 Interpretación de los Resultados y Aplicaciones Prácticas	22
7.13 Predicción de mercado basada en datos de rentabilidad.....	22
7.14 Arquitectura de la Red Neural.....	27
7.14.1. Hiperparámetros Utilizados	28
7.14.2. Funciones de Activación	29
7.14.3. Motivo de Selección	31
7.15 Variables.....	32
8. RESULTADOS.....	33
Análisis individual (por cada empresa) usando redes neuronales artificiales.	39
9. DISCUSIÓN DE LOS RESULTADOS Y PROPUESTA DE SOLUCIÓN.....	50
9.1 Discusión	50
9.1.1. Desempeño de la cartera y aplicación de modelos teóricos	50
9.1.2. Simulación Monte Carlo y análisis de cartera	51
10. CONCLUSIONES Y RECOMENDACIONES	56
11. Referencias.....	58

ÍNDICE DE TABLAS

Tabla 1. Evidencia Empírica.....	5
Tabla 2. Variables.	32

ÍNDICE DE FIGURAS

Figura 1. Codificación de las empresas.	33
Figura 2. Comparativa de precios por empresa	33
Figura 3. Volatilidad, rendimientos y ratios de Sharpe	34
Figura 4. Matriz de pesos.	34
Figura 5. Ponderaciones de Sharpe	35
Figura 6. Comparativa del portafolio por años.....	36
Figura 7. Comportamiento del portafolio.	36
Figura 8. Comportamiento de la volatilidad del portafolio.....	36
Figura 9. Comparativo de las volatilidades de los portafolios esperados y realizados.	37
Figura 10. Rendimientos de la cartera esperados y realizados.....	37
Figura 11. Correlación de la cartera esperados y realizados	38
Figura 12. Índices de Sharpe esperados y los realizados	38
Figura 13. Comparación entre los valores esperados y los valores-Índice de Sharpe.....	39
Figura 14. Variación mensual de Elektra.....	39
Figura 15. Variación mensual de Amazon.....	40
Figura 16. Variación mensual Oro.....	40
Figura 17. Variación mensual BanBajío	41
Figura 18. Variación mensual Bimbo.....	41
Figura 19. Puntos sintéticos de Elektra.	42
Figura 20. Puntos sintéticos Bimbo	42
Figura 21. Puntos sintéticos de Amazon	43
Figura 22. Puntos sintéticos de BanBajío.	43
Figura 23. Puntos sintéticos del Oro.	44
Figura 24. Modelo secuencial de la red neuronal de Elektra.....	45
Figura 25. Aproximación de la muestra de la red neuronal profunda (DNN) de Elektra.	45
Figura 26. Modelo secuencial de la red neuronal de Bimbo.....	46
Figura 27. Aproximación de la muestra de la red neuronal profunda (DNN) de Bimbo.	46
Figura 28. Modelo secuencial de la red neuronal de Amazon.....	47
Figura 29. Aproximación de la muestra de la red neuronal profunda (DNN) de Amazon.	47
Figura 30. Modelo secuencial de la red neuronal de BanBajío.....	48
Figura 31. Aproximación de la muestra de la red neuronal profunda (DNN) de BanBajío.....	48
Figura 32. Modelo secuencial de la red neuronal del Oro.	49
Figura 33. Aproximación de la muestra de la red neuronal profunda (DNN) del Oro.	49

INTRODUCCIÓN

La optimización de portafolios de inversión en la Bolsa de Valores de Quito, Ecuador, representa un desafío estratégico para los inversores que buscan maximizar sus rendimientos y minimizar los riesgos asociados. En respuesta a esta necesidad, se ha implementado una metodología basada en Redes Neuronales Artificiales para realizar un análisis exhaustivo de los activos disponibles y su rendimiento histórico desde el año 2016 hasta principios de 2022. Este enfoque innovador implica la aplicación de la Teoría de Portafolios de H. Markowitz, así como técnicas avanzadas como la simulación de Monte Carlo y el uso de Machine Learning para analizar las series financieras individuales de cada activo. Los resultados obtenidos de esta investigación son fundamentales para comprender la eficacia de las estrategias de inversión y la precisión de los modelos utilizados en el contexto del dinámico mercado financiero contemporáneo.

El proceso de optimización de portafolios de inversión comienza con la recopilación y análisis detallado de la información histórica de los activos seleccionados, que incluyen empresas como Elektra, Bimbo, Amazon, BanBajío y Oro. Estos datos, obtenidos de fuentes confiables como investing.com y meticulosamente registrados en un archivo de Excel, sirven como la base para el análisis y la toma de decisiones en la gestión de inversiones. La aplicación de la Teoría de Portafolios de Markowitz proporciona un marco sólido para la selección óptima de activos y la construcción de carteras diversificadas que equilibren el riesgo y el rendimiento.

Una vez que se han identificado los activos y se han calculado los retornos logarítmicos, la volatilidad y el índice de Sharpe para cada uno, se procede con la simulación de Monte Carlo para evaluar las combinaciones de riesgo y retorno. Esta técnica estadística permite explorar una amplia gama de escenarios posibles, proporcionando información valiosa sobre la distribución potencial de los retornos y la volatilidad de la cartera en diferentes condiciones del mercado.

Además, el uso de algoritmos de Machine Learning para analizar las series financieras individuales de cada activo ofrece una perspectiva más detallada de los factores que influyen en su rendimiento. Las redes neuronales artificiales, en particular, han demostrado ser efectivas para identificar patrones y tendencias complejas en conjuntos de datos financieros, permitiendo a los inversores tomar decisiones más informadas sobre la gestión de sus carteras.

El análisis de la cartera y la aplicación de modelos teóricos proporcionan una visión integral del rendimiento y la eficacia de las estrategias de inversión. Sin embargo, es importante tener en cuenta que las predicciones teóricas pueden no siempre reflejar los resultados reales, ya que el mercado financiero está sujeto a una serie de factores impredecibles como cambios en las condiciones macroeconómicas y eventos geopolíticos.

La investigación se estructura en varios apartados esenciales. Inicia con la revisión de literatura existente, seguida de la identificación y planteamiento del problema de negocio en la Bolsa de Valores de Quito, Ecuador. Posteriormente, se describe la base de datos seleccionada y se lleva a cabo un análisis exploratorio de los datos. La metodología empleada se detalla antes de proceder al análisis de datos, incluyendo algoritmos, optimización de parámetros y evaluación del modelo. Los resultados se examinan, y se proponen estrategias de solución innovadoras. Finalmente, se presentan conclusiones y recomendaciones basadas en los hallazgos.

REVISIÓN DE LITERATURA

La predicción del precio de acciones ha sido objeto de un extenso análisis en la literatura académica, especialmente en el contexto del uso de técnicas de Machine Learning. Uno de los estudios destacados en esta área es el realizado por Tsantekidis et al. (2017), quienes exploraron el potencial de los modelos de aprendizaje profundo para prever los precios de las acciones. Su investigación reveló que el empleo de redes neuronales recurrentes (RNN) y redes neuronales convolucionales (CNN) superó a los métodos tradicionales, proporcionando una mayor precisión predictiva en la dinámica del mercado financiero.

Además, se ha observado que la inclusión de datos macroeconómicos y financieros puede ser crucial para mejorar la capacidad predictiva de los modelos. En este sentido, el trabajo de Yiu et al. (2018) destaca la eficacia de un modelo híbrido inteligente que incorpora factores externos como tasas de interés y noticias económicas. Este enfoque sugiere que la consideración de variables más allá de las históricas de precios de acciones puede enriquecer la precisión de las predicciones y proporcionar una visión más completa del mercado.

A pesar de los avances logrados con el uso de Machine Learning en la predicción de precios de acciones, es importante reconocer la complejidad intrínseca de este desafío. Chen et al. (2019) contribuyen a esta discusión al proponer un enfoque de aprendizaje multi-contexto basado en la atención. Este tipo de enfoque sugiere que considerar diferentes contextos puede ser esencial para abordar la no linealidad y complejidad de los datos financieros, destacando la necesidad de modelos más sofisticados.

Otro aspecto relevante que ha sido abordado en la literatura es la predicción intradía de precios de acciones. Zhang et al. (2020) exploraron esta faceta utilizando un enfoque basado en árboles de decisión con aprendizaje de transferencia transductiva. Sus resultados resaltan la importancia de considerar patrones intradía para predicciones a corto plazo, lo que puede ser crucial para

los inversores que buscan maximizar sus rendimientos en períodos de tiempo más cortos.

La integración de análisis de sentimientos de noticias con diversos indicadores financieros ha surgido como una estrategia prometedora en la predicción de precios de acciones. Kim et al. (2021) abordaron este enfoque utilizando modelos de Procesamiento del Lenguaje Natural (NLP). Su estudio demuestra que el análisis de sentimientos en noticias financieras puede mejorar la precisión de las predicciones, sugiriendo que la consideración de información no estructurada puede ser valiosa en la toma de decisiones de inversión.

El estudio de Wu et al. (2022) se centra en el impacto de eventos corporativos en la predicción de precios de acciones mediante el uso de aprendizaje profundo. Este enfoque destaca la importancia de tener en cuenta eventos significativos que puedan influir en el mercado, permitiendo a los inversores ajustar estrategias ante cambios importantes en el entorno empresarial.

Finalmente, Li et al. (2023) proponen un enfoque de aprendizaje no supervisado para la detección de anomalías en patrones de precios. Su investigación se centra en proporcionar alertas tempranas sobre comportamientos atípicos en el mercado, permitiendo a los inversores ajustar estrategias de manera proactiva y mitigar riesgos.

En el contexto de la Bolsa Mexicana de Valores, Camargo (2023) contribuye al campo de estudio al abordar la optimización de portafolios de inversión utilizando Redes Neuronales Artificiales. Este estudio se suma a la diversidad de enfoques y aplicaciones de Machine Learning en el ámbito financiero, proporcionando una perspectiva específica para el mercado mexicano.

En resumen, la literatura académica revisada resalta la evolución y la diversidad de enfoques en la predicción del precio de acciones mediante técnicas de Machine Learning. Desde el uso de redes neuronales hasta modelos híbridos

inteligentes y enfoques intradía, los estudios analizados subrayan la necesidad de abordar la complejidad y la volatilidad inherentes a los mercados financieros. Cada investigación aporta conocimientos valiosos y perspectivas únicas, contribuyendo al desarrollo continuo de estrategias efectivas de predicción en el ámbito financiero. La Tabla 1 titulada "Evidencia Empírica" contiene datos relevantes sobre los resultados obtenidos en los estudios revisados.

Tabla 1. Evidencia Empírica

Autor	Tipos de Datos	Metodologías	Resultados	Implicaciones Gerenciales
Camargo, G. C. G. (2023)	Datos de la Bolsa Mexicana de Valores	Redes Neuronales Artificiales	Contribuciones adicionales de RNAs en la optimización de portafolios de Valores	Extensión de las aplicaciones de RNAs en la Bolsa Mexicana de Valores
Tsantekidis et al. (2017)	Series temporales de precios	Redes Neuronales Recurrentes y Convolucionales	Mejora en la precisión predictiva respecto a métodos tradicionales en la toma de decisiones financieras	Implementación de modelos de aprendizaje profundo en la toma de decisiones financieras
Yiu et al. (2018)	Datos macroeconómicos y financieros	Modelos híbridos, incluyendo métodos tradicionales	Mejora en la precisión de recomendaciones al considerar factores externos y datos adicionales	Integración de información económica externa en estrategias de inversión
Chen et al. (2019)	Datos de redes sociales	Modelos de Aprendizaje Profundo	Incorporación de sentimiento de redes sociales como indicador en	Utilización de información de redes sociales como indicador de

			predicciones de mercado	sentimiento en predicciones de mercado
Zhang et al. (2020)	Datos de transacciones bursátiles	Enfoque basado en árboles de decisión	Identificación de patrones intradía para predicciones a corto plazo	Aplicación en estrategias de trading intradía para maximizar rendimientos
Kim et al. (2021)	Datos de noticias financieras	Procesamiento del Lenguaje Natural (NLP)	Mejora en la precisión al analizar sentimientos en noticias financieras	Recomendación ajustada de carteras basadas en análisis de noticias financieras
Wu et al. (2022)	Datos de eventos corporativos	Redes Neuronales Profundas	Identificación del impacto de eventos corporativos en el mercado	Ajuste de estrategias ante eventos corporativos significativos
Li et al. (2023)	Datos de redes neuronales	Modelos de aprendizaje no supervisado	Detección temprana de anomalías y ajuste de alertas	Alertas tempranas y ajuste de estrategias ante anomalías detectadas

IDENTIFICACIÓN DEL OBJETO DE ESTUDIO

En el desarrollo de esta investigación, se emplearán diversas fuentes de información para garantizar la robustez y la contextualización de los resultados. En primer lugar, se recurrirá a fuentes primarias que incluyen informes financieros específicos de la Bolsa de Quito-Ecuador. Estos informes proporcionarán datos directos y detallados sobre el rendimiento financiero de las acciones en este mercado, permitiendo una evaluación precisa de las tendencias y patrones históricos.

Asimismo, se utilizarán datos históricos de precios de acciones de la Bolsa de Quito. Estos datos son esenciales para llevar a cabo análisis cuantitativos y modelar el comportamiento pasado del mercado, lo que a su vez facilitará la aplicación de técnicas de Machine Learning para la predicción de precios. La inclusión de información temporal detallada permitirá una comprensión más completa de la dinámica del mercado de valores en Quito.

Además, se considerará la consulta de noticias económicas relevantes como fuente primaria. La incorporación de eventos económicos clave y su correlación con los movimientos del mercado puede enriquecer la predicción del precio de acciones. Este enfoque se alinea con la investigación de Wu et al. (2022), que destaca la importancia de eventos corporativos en la predicción de precios.

Para complementar y respaldar la investigación, se utilizarán fuentes secundarias, entre las que se incluyen informes económicos proporcionados por el Banco Central de Ecuador. Estos informes ofrecen una visión macroeconómica del país y su impacto en los mercados financieros locales. Además, se analizarán los informes y análisis de mercado elaborados por instituciones financieras reconocidas, lo que brindará perspectivas adicionales sobre el entorno económico.

Por último, se revisarán documentos regulatorios relacionados con la Bolsa de Quito y el mercado de valores ecuatoriano. Estos documentos proporcionarán información sobre las regulaciones y políticas que rigen el funcionamiento del mercado, lo cual es esencial para contextualizar cualquier hallazgo o tendencia identificada. La combinación de fuentes primarias y secundarias garantizará la obtención de datos precisos y variados, permitiendo un análisis integral del mercado de valores de Quito. Al integrar la información histórica con datos actuales y considerar eventos económicos significativos, se espera obtener una visión más precisa y contextualizada de los factores que influyen en la predicción del precio de acciones en este mercado específico

PLANTEAMIENTO DEL PROBLEMA

La optimización de portafolios de inversión en la Bolsa de Quito-Ecuador mediante el uso de Redes Neuronales Artificiales (RNAs) presenta una justificación significativa y una importancia estratégica para abordar los desafíos organizacionales identificados en el entorno financiero actual.

La Bolsa de Quito enfrenta el desafío de gestionar de manera eficiente las carteras de inversión en un mercado financiero dinámico y altamente volátil. La aplicación de las RNAs en la optimización de portafolios ha demostrado ser efectiva en la predicción de precios de acciones y en la toma de decisiones financieras más precisas. Estudios como el de Li et al. (2018) evidencian que las RNAs ofrecen la capacidad de modelar relaciones complejas en los datos financieros, lo que resulta en una mejora significativa en la eficiencia de la gestión de carteras.

La importancia de este proyecto radica en su capacidad para superar las limitaciones de los enfoques tradicionales de optimización de portafolios. La diversificación de activos y la gestión del riesgo son aspectos críticos en la Bolsa de Quito, y las RNAs proporcionan un enfoque más avanzado y adaptativo. La literatura financiera, como el estudio de Chen et al. (2019), resalta la utilidad de modelos de aprendizaje profundo basados en la atención para mejorar la precisión en la predicción de precios de acciones y, por ende, en la toma de decisiones de inversión.

La Bolsa de Quito también se enfrenta a la necesidad de adaptarse rápidamente a los cambios en el entorno económico y financiero global. La capacidad de las RNAs para aprender de manera continua y ajustar sus modelos a medida que evolucionan las condiciones del mercado es crucial en este sentido. Investigaciones como el trabajo de Wu et al. (2022) enfatizan la relevancia de las RNAs en la predicción de precios de acciones basada en eventos corporativos, permitiendo a los inversores anticipar y reaccionar de manera proactiva ante eventos que puedan afectar las carteras de inversión.

Además, la Bolsa de Quito se encuentra en un entorno competitivo donde la eficiencia en la gestión de carteras puede marcar la diferencia. La aplicación de tecnologías avanzadas, como las RNAs, no solo mejora la toma de decisiones internas, sino que también puede atraer a inversores interesados en participar en un mercado respaldado por análisis avanzados y estrategias de inversión innovadoras. Estudios como el de Kim et al. (2021) destacan la eficacia de las RNAs en la predicción de precios de acciones mediante análisis de sentimientos de noticias, mostrando su utilidad en la adaptación a información externa para ajustar estrategias de inversión.

La importancia de resolver el problema organizacional identificado en la Bolsa de Quito a través de la optimización de portafolios con RNAs radica en la mejora sustancial de la eficiencia operativa y la competitividad en el panorama financiero. La literatura financiera respalda la adopción de enfoques más avanzados y tecnológicos en la gestión de inversiones, y este proyecto propone una solución innovadora y adaptativa.

OBJETIVO GENERAL

Optimizar los portafolios de inversión en la Bolsa de Valores de Quito, Ecuador, aplicando técnicas de Redes Neuronales Artificiales con el propósito de maximizar los rendimientos y minimizar los riesgos asociados a las inversiones.

OBJETIVOS ESPECÍFICOS

- Desarrollar modelos de Redes Neuronales Artificiales adaptados al contexto específico de la Bolsa de Valores de Quito, considerando las particularidades del mercado ecuatoriano.
- Evaluar la eficacia de los modelos de RNAs en la predicción de precios de acciones y la optimización de portafolios, utilizando datos históricos y actuales de la Bolsa de Quito.
- Comparar los resultados obtenidos mediante RNAs con métodos tradicionales de optimización de portafolios para evaluar la mejora en la precisión y la eficiencia.
- Proponer estrategias específicas de gestión de portafolios basadas en los resultados obtenidos, considerando las condiciones y regulaciones del mercado de valores en Ecuador.

JUSTIFICACIÓN Y APLICACIÓN DE LA METODOLOGÍA

El proceso de optimización de portafolios de inversión en la Bolsa de Valores de Quito, Ecuador utilizando Redes Neuronales Artificiales implica un análisis exhaustivo de los activos disponibles y su desempeño histórico. Para este propósito, el inversionista ha extraído la información histórica de los activos seleccionados, incluyendo Elektra, Bimbo, Amazon, BanBajío y Oro, desde el año 2016 hasta inicios de enero de 2022. Estos datos históricos se registraron meticulosamente en un archivo de Excel obtenido de la página [investing.com](https://www.investing.com).

La optimización del portafolio de inversión se basa en la Teoría de Portafolios de H. Markowitz, la cual se implementa a través de algoritmos diseñados específicamente para este propósito. Inicialmente, se calculan los retornos logarítmicos para todas las series temporales de los activos seleccionados, seguido de la normalización de las series de tiempo financiero. Posteriormente, se calculan el retorno, la volatilidad y el índice de Sharpe para cada activo.

El proceso de optimización implica el estudio de las combinaciones de riesgo y retorno mediante la simulación de Monte Carlo para aleatorizar los pesos de la cartera. Se garantiza que la suma de los pesos sea igual al 100%. Luego, se simulan los pesos de la cartera y se calculan el retorno, la volatilidad y el índice de Sharpe. Se realiza una retrospectiva desde el año 2016, derivando los pesos del portafolio para cada año que maximiza el índice de Sharpe.

La comparación entre las estadísticas de cartera esperadas y realizadas se lleva a cabo para evaluar la eficacia del modelo. Se comparan las volatilidades y los rendimientos de la cartera esperados y realizados, así como el índice de Sharpe esperado con el realizado.

Además, se implementa Machine Learning para el análisis de series financieras individuales de cada activo, realizando tareas como estimación o clasificación.

Se comparan el rendimiento y la precisión del aprendizaje, evaluando la mejora en el desempeño del algoritmo en función de la experiencia adquirida.

7.1 Justificación

El presente estudio sobre la optimización de portafolios de inversión en la Bolsa de Valores de Quito, Ecuador, utilizando Redes Neuronales Artificiales (RNAs) se fundamenta en la necesidad de abordar la complejidad inherente a los mercados financieros en un entorno dinámico y cambiante. La elección de las RNAs como herramienta analítica se justifica por su capacidad para gestionar eficientemente la incertidumbre y la variabilidad presentes en los mercados financieros contemporáneos (Nayak & Behera, 2020).

Relevancia del Tema

En el contexto económico y financiero actual de Quito, Ecuador, la Bolsa de Valores desempeña un papel fundamental en la movilización de recursos financieros y en el fomento del desarrollo económico regional. La optimización de portafolios adquiere una importancia crucial en este escenario, ya que permite a los inversionistas maximizar sus rendimientos y minimizar los riesgos asociados a sus inversiones en el mercado bursátil local (Grau & Murguía, 2018).

La aplicación de tecnologías emergentes, como las RNAs, en el proceso de optimización de portafolios representa una tendencia significativa en el ámbito financiero global. La adopción de estas tecnologías en el contexto específico de Quito, Ecuador, ofrece una oportunidad única para explorar y evaluar su efectividad en un entorno económico y regulatorio particular (Rufino & Tonelli, 2021).

7.2 Usar RNA para analizar un portafolio de inversión

Información o Datos: La optimización de portafolios de inversión en la Bolsa de Valores de Quito, Ecuador utilizando Redes Neuronales Artificiales representa

un área fascinante de estudio que combina el análisis financiero tradicional con técnicas avanzadas de aprendizaje automático. Este enfoque busca aprovechar la enorme cantidad de datos disponibles en el mercado financiero para tomar decisiones de inversión más informadas y rentables. En este análisis detallado, exploraremos en profundidad los fundamentos, métodos y aplicaciones de la optimización de portafolios utilizando Redes Neuronales Artificiales (RNA) en el contexto de la Bolsa de Valores de Quito, Ecuador.

Introducción a la Optimización de Portafolios de Inversión: La optimización de portafolios de inversión es el proceso de construir una cartera de activos financieros que maximice el rendimiento esperado dado un nivel de riesgo específico o minimice el riesgo dado un nivel de rendimiento deseado. Este proceso es fundamental para los inversores y gestores de carteras, ya que les permite diversificar sus inversiones y equilibrar el riesgo y el rendimiento de manera efectiva.

En el contexto de la Bolsa de Valores de Quito, Ecuador, los inversores buscan aprovechar las oportunidades de inversión en empresas locales e internacionales listadas en el mercado bursátil. Sin embargo, la selección de activos y la asignación de capital pueden ser tareas complejas debido a la volatilidad del mercado y la gran cantidad de información disponible.

Utilizando Redes Neuronales Artificiales para la Optimización de Portafolios: Las Redes Neuronales Artificiales (RNA) son modelos computacionales inspirados en el funcionamiento del cerebro humano que pueden aprender y adaptarse a partir de datos. En el contexto de la optimización de portafolios, las RNA pueden utilizarse para analizar patrones complejos en los datos financieros y tomar decisiones de inversión más precisas y rentables.

El proceso de optimización de portafolios utilizando RNA implica varios pasos clave:

1. Recopilación y Preprocesamiento de Datos:

Los datos históricos de precios de las acciones y otros activos financieros se recopilan y se preprocesan para eliminar ruido y asegurar la calidad de los datos. En el caso de la Bolsa de Valores de Quito, Ecuador, se pueden utilizar diversas fuentes de datos, como Investing.com, para obtener información sobre los precios históricos de las acciones y otros activos financieros.

2. Selección de Activos y Construcción del Portafolio:

Se seleccionan los activos financieros que formarán parte del portafolio de inversión. Esto puede incluir acciones de empresas locales e internacionales, bonos, fondos de inversión y otros instrumentos financieros. La construcción del portafolio se basa en el análisis de riesgo y rendimiento de cada activo, así como en los objetivos de inversión del inversor.

3. Modelado y Entrenamiento de la RNA:

Se construye una RNA utilizando algoritmos de aprendizaje automático para analizar los datos históricos y predecir los rendimientos futuros de los activos financieros. Durante el entrenamiento, la RNA ajusta sus pesos y parámetros internos para minimizar el error entre los rendimientos reales y los rendimientos predichos.

4. Optimización del Portafolio:

Una vez entrenada la RNA, se utiliza para optimizar el portafolio de inversión. Esto implica encontrar la combinación óptima de activos financieros que maximice el rendimiento esperado dado un nivel de riesgo específico o minimice

el riesgo dado un nivel de rendimiento deseado. La RNA puede tener en cuenta diversas restricciones, como límites de inversión y restricciones de liquidez.

5. Evaluación y Ajuste:

Una vez optimizado el portafolio, se evalúa su desempeño utilizando métricas de rendimiento como el rendimiento total, el ratio de Sharpe y la volatilidad. Si es necesario, se ajustan los parámetros del modelo y se realiza una nueva optimización del portafolio para mejorar su desempeño.

7.3 Evaluación

La evaluación en la optimización de portafolios de inversión en la Bolsa de Valores de Quito, Ecuador utilizando Redes Neuronales Artificiales (RNA) es un componente crítico que determina la efectividad y la confiabilidad de los modelos desarrollados. En este proceso de evaluación, se busca entender la capacidad de los algoritmos de estimación sobre el conjunto de información de la muestra y su capacidad para generalizar sobre datos no observados anteriormente.

7.3.1. Importancia de la Evaluación en la Optimización de Portafolios

La optimización de portafolios implica la selección y la asignación de activos financieros con el objetivo de maximizar el rendimiento esperado dado un nivel de riesgo específico o minimizar el riesgo dado un nivel de rendimiento deseado. En un entorno dinámico como la Bolsa de Valores de Quito, Ecuador, donde los precios de los activos fluctúan constantemente, es esencial contar con modelos predictivos precisos y confiables para tomar decisiones de inversión informadas.

7.3.2. Componentes de la Evaluación

La evaluación de los modelos de optimización de portafolios utilizando RNA implica varios componentes clave:

Capacidad del Modelo:

La capacidad del modelo se refiere a su habilidad para capturar y representar las relaciones subyacentes en los datos. Se evalúa mediante la capacidad del modelo para ajustarse a los datos de entrenamiento y su capacidad para generalizar sobre datos no vistos anteriormente.

División de los Datos:

Los datos se dividen en conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento se utiliza para ajustar los parámetros del modelo, el conjunto de validación se utiliza para ajustar los hiperparámetros del modelo y el conjunto de prueba se utiliza para evaluar el rendimiento del modelo final.

7.3.3. Métricas de Evaluación:

Se utilizan métricas de evaluación como el Error Cuadrático Medio (MSE), el Coeficiente de Determinación (R^2) y el Ratio de Sharpe para medir la precisión y la eficacia del modelo en la predicción de los rendimientos financieros.

7.4 Técnicas de Aleatorización y Validación Cruzada

Para garantizar la integridad y la imparcialidad de la evaluación, se aplican técnicas de aleatorización y validación cruzada. La aleatorización se utiliza para dividir los datos en conjuntos de entrenamiento, validación y prueba de manera aleatoria, mientras que la validación cruzada se utiliza para evaluar la robustez del modelo mediante la división y evaluación repetida de los datos.

Consideraciones Éticas y Legales

Es importante tener en cuenta las consideraciones éticas y legales al evaluar modelos de optimización de portafolios. Esto incluye la privacidad de los datos,

la transparencia del modelo y la responsabilidad en el uso de la información financiera.

7.5 Muestreo

Importancia del Muestreo Aleatorio en la Optimización de Portafolios:

El muestreo aleatorio desempeña un papel fundamental en la optimización de portafolios utilizando Redes Neuronales Artificiales (RNA). Este enfoque garantiza que los datos utilizados para el entrenamiento, la validación y la prueba del modelo sean representativos de la población subyacente, lo que a su vez asegura la robustez y la generalización del modelo resultante.

En el contexto de la Bolsa de Valores de Quito, Ecuador, donde los precios de los activos financieros están sujetos a fluctuaciones constantes, es esencial contar con modelos predictivos precisos y confiables para la toma de decisiones de inversión. El muestreo aleatorio permite obtener una muestra diversa y equilibrada de datos históricos de los activos financieros, lo que proporciona una base sólida para el desarrollo y la evaluación de modelos de optimización de portafolios.

7.6 Identificación y Mitigación del Sobreajuste

Uno de los desafíos clave al entrenar modelos predictivos es el sobreajuste, que ocurre cuando un modelo se ajusta demasiado bien a los datos de entrenamiento y no puede generalizar correctamente a nuevos datos. En el contexto de la optimización de portafolios, el sobreajuste puede conducir a decisiones de inversión subóptimas y resultados insatisfactorios.

El muestreo aleatorio ayuda a mitigar el sobreajuste al garantizar que los datos se dividan de manera imparcial en conjuntos de entrenamiento, validación y prueba. Al monitorear el desempeño del modelo en el conjunto de validación

durante el entrenamiento, los analistas pueden detectar signos de sobreajuste y ajustar los hiperparámetros del modelo según sea necesario para mejorar la generalización.

7.7 Monitoreo del Rendimiento del Modelo

El uso de herramientas como Keras facilita el monitoreo del rendimiento del modelo durante el entrenamiento. Las funciones de devolución de llamada permiten detener el entrenamiento del modelo cuando se alcanza cierto criterio predefinido, como la convergencia del error de validación o la ausencia de mejoras significativas en el rendimiento del modelo.

Además, se pueden utilizar técnicas de visualización, como gráficos de pérdida y precisión, para evaluar la evolución del rendimiento del modelo a lo largo del tiempo e identificar posibles áreas de mejora. Esto permite a los analistas tomar decisiones informadas sobre la arquitectura del modelo, los hiperparámetros y otros aspectos del proceso de entrenamiento.

7.8 Comparación de Modelos y Selección del Mejor

En el proceso de optimización de portafolios, es común comparar varios modelos y técnicas de modelado para determinar cuál produce los mejores resultados. Esto puede implicar la evaluación de diferentes arquitecturas de RNA, la selección de conjuntos de características relevantes y la exploración de diferentes estrategias de optimización.

La comparación de modelos se realiza generalmente utilizando métricas de evaluación como el error cuadrático medio (MSE), el coeficiente de determinación (R^2) y el ratio de Sharpe. Estas métricas proporcionan una medida objetiva del rendimiento del modelo y permiten a los analistas identificar qué modelos son más efectivos para la optimización de portafolios en un entorno financiero específico.

La predicción del mercado utilizando Redes Neuronales Artificiales (RNA) representa un enfoque innovador y altamente efectivo para la optimización de portafolios en la Bolsa de Valores de Quito, Ecuador. Esta técnica combina la teoría financiera con el poder del aprendizaje automático para identificar ineficiencias estadísticas en los mercados y predecir la dirección futura de los precios de los activos financieros.

7.9 Predicción del Mercado con Redes Neuronales

El proceso de predicción del mercado utilizando RNA implica varios pasos clave, comenzando con la importación y visualización de los datos financieros históricos. Estos datos se leen en un objeto DataFrame, lo que permite una manipulación y análisis efectivos. Luego, se normalizan los datos de la serie temporal para garantizar una comparación justa entre diferentes activos financieros.

7.10 Análisis de Regresión OLS y Predicción Intradía

Una vez que los datos están preparados, se realiza un análisis de regresión de mínimos cuadrados ordinarios (OLS) para identificar las relaciones entre las variables financieras. Este análisis revela la relación entre los precios de los activos en diferentes puntos del tiempo y ayuda a identificar predictores significativos del comportamiento del mercado.

Además, se exploran técnicas de predicción intradía, que analizan los datos dentro del mismo día de negociación. Este enfoque permite capturar tendencias y patrones a corto plazo en el mercado, lo que puede ser invaluable para los inversores que buscan maximizar sus rendimientos en períodos de tiempo más cortos.

7.11 Estacionariedad de los Datos y Correlación Temporal

Un aspecto crítico del análisis financiero es la estacionariedad de los datos de la serie temporal. La estacionariedad implica que las propiedades estadísticas de los datos, como la media y la varianza, son constantes en el tiempo. Esto se verifica mediante pruebas como la correlación entre las series temporales retardadas y el examen de estacionariedad utilizando pruebas como la prueba de Dickey-Fuller.

7.12 Interpretación de los Resultados y Aplicaciones Prácticas

Los resultados del análisis de regresión OLS y la predicción intradía proporcionan información valiosa sobre las relaciones y tendencias en el mercado financiero de Quito. Por ejemplo, la identificación de predictores significativos del comportamiento del mercado puede ayudar a los inversores a tomar decisiones informadas sobre la asignación de activos en sus carteras de inversión.

Además, la capacidad para predecir tendencias intradía puede ser útil para los operadores que buscan capitalizar oportunidades a corto plazo en el mercado. Al comprender las relaciones entre diferentes variables financieras y cómo afectan los precios de los activos, los inversores pueden desarrollar estrategias comerciales más efectivas y optimizar sus rendimientos.

7.13 Predicción de mercado basada en datos de rentabilidad.

7.13.1. Obtención de Datos y Transformación

Para comenzar, se recolectan datos históricos de la Bolsa de Valores de Quito y se calculan los rendimientos logarítmicos a partir de los precios. Estos rendimientos proporcionan una medida fundamental para evaluar el desempeño de los activos financieros en un período específico. La estacionariedad de los

datos y la correlación entre las características también se examinan para comprender mejor la dinámica del mercado.

7.13.2. Regresión OLS versus Redes Neuronales

El análisis se divide en dos partes principales: la implementación de la regresión de mínimos cuadrados ordinarios (OLS) y el uso de redes neuronales para predecir la dirección del mercado. Con la regresión OLS, se generan predicciones sobre la base de los datos históricos, y se evalúa la precisión de estas predicciones. Se encuentra que la precisión de la regresión OLS para predecir la dirección del mercado es ligeramente superior al 50 %.

Por otro lado, al emplear redes neuronales, los resultados son más alentadores. Tanto los modelos de Scikit-Learn como los desarrollados con Keras y Tensorflow muestran una precisión significativamente mayor, superando el 60 % en algunos casos. Estos resultados sugieren que las redes neuronales tienen una capacidad inherente para capturar patrones complejos en los datos financieros, lo que les permite ofrecer predicciones más precisas sobre la dirección del mercado.

7.13.3. Evaluación Fuera de la Muestra

La verdadera prueba de la efectividad de los modelos se realiza al evaluar su rendimiento fuera de la muestra. En este escenario, se entrena el modelo con el 80 % de los datos y se prueba con el 20 % restante. La regresión OLS, aunque mantiene niveles similares de precisión, muestra limitaciones en la capacidad para adaptarse a nuevas condiciones del mercado. Por el contrario, las redes neuronales muestran una mayor capacidad para generalizar y adaptarse a datos no vistos previamente, lo que se refleja en su mayor precisión fuera de la muestra.

7.13.4. Análisis Exploratorio de los Datos Utilizados

El desempeño de una cartera de inversión y la aplicación de modelos teóricos son aspectos cruciales en la gestión financiera moderna. Al examinar los resultados obtenidos de un análisis de cartera y combinarlos con la revisión de la literatura pertinente, se puede obtener una comprensión más profunda de la eficacia de las estrategias de inversión y la precisión de los modelos utilizados. En este análisis exploratorio, exploraremos en detalle cada aspecto mencionado y su relevancia en el contexto del mercado financiero contemporáneo.

7.13.5. Desempeño de la Cartera y Aplicación de Modelos Teóricos

Al evaluar el rendimiento de una cartera de inversiones, es fundamental considerar una serie de indicadores clave, como el rendimiento total, la volatilidad y el índice de Sharpe. Los resultados de la cartera pueden revelar información valiosa sobre la efectividad de las estrategias de inversión empleadas y la capacidad de la cartera para generar retornos en relación con el riesgo asumido.

En el caso analizado, se observa un rendimiento positivo de la cartera, lo que sugiere que las inversiones han generado ganancias en el período evaluado. Además, la volatilidad moderada indica que la cartera ha mantenido un nivel de riesgo controlado en comparación con su rendimiento. Este equilibrio entre riesgo y retorno es fundamental para los inversores que buscan maximizar las ganancias mientras minimizan la exposición a la volatilidad del mercado.

Sin embargo, es importante tener en cuenta que las predicciones teóricas pueden no siempre reflejar fielmente los resultados reales. La literatura financiera ha señalado consistentemente que los modelos teóricos pueden tener limitaciones en su capacidad para predecir con precisión el comportamiento del mercado a corto plazo. A menudo, los cambios en las condiciones macroeconómicas, eventos imprevistos del mercado y otros factores externos

pueden influir en los resultados reales de la cartera, lo que hace que las predicciones sean menos confiables en la práctica.

Por lo tanto, si bien los modelos teóricos proporcionan un marco útil para comprender los principios fundamentales de la inversión y la gestión de carteras, es importante complementar estos modelos con un análisis cuidadoso del entorno del mercado y una comprensión de los factores que pueden afectar el rendimiento de la cartera en el mundo real.

7.13.6. Simulación Monte Carlo y Análisis de Cartera

La simulación Monte Carlo es una herramienta poderosa que se utiliza en la gestión de carteras para evaluar el riesgo y el rendimiento en una amplia gama de escenarios posibles. Al generar múltiples trayectorias aleatorias basadas en la distribución de probabilidades de los activos subyacentes, la simulación Monte Carlo permite a los inversores comprender mejor la distribución de los posibles resultados y tomar decisiones informadas sobre la gestión de riesgos.

En el análisis de la cartera discutido, la simulación Monte Carlo proporciona información valiosa sobre la distribución potencial de los retornos y la volatilidad de la cartera en diferentes condiciones del mercado. Esta información puede ser especialmente útil para los inversores que desean comprender mejor cómo pueden responder sus inversiones a cambios en el entorno económico y financiero.

Sin embargo, es importante tener en cuenta que la simulación Monte Carlo no es una herramienta infalible y no puede prever con precisión el comportamiento futuro del mercado. La discrepancia entre las predicciones teóricas y los resultados reales resalta la importancia de considerar otros factores, como eventos imprevistos del mercado y cambios en las condiciones económicas y políticas, al evaluar el riesgo y el rendimiento de una cartera de inversiones.

Al integrar la simulación Monte Carlo con otros enfoques analíticos y estrategias de gestión de riesgos, los inversores pueden tomar decisiones más informadas y mitigar los riesgos asociados con la inversión en el mercado financiero.

Aplicación de Redes Neuronales Artificiales

Las redes neuronales artificiales han ganado popularidad en el campo de la gestión de inversiones debido a su capacidad para identificar patrones y tendencias complejas en conjuntos de datos financieros. Al analizar individualmente el comportamiento de las empresas dentro de una cartera utilizando redes neuronales artificiales, los inversores pueden obtener una comprensión más detallada de los factores que influyen en el rendimiento de cada empresa y su impacto en la cartera en su conjunto.

Sin embargo, es importante tener en cuenta que las redes neuronales artificiales también tienen limitaciones y pueden no capturar completamente la complejidad del mercado financiero. La precisión de los modelos de redes neuronales artificiales depende en gran medida de la calidad y la cantidad de datos disponibles, así como de la selección adecuada de variables y parámetros del modelo.

Por lo tanto, si bien las redes neuronales artificiales pueden proporcionar información valiosa sobre el comportamiento de las empresas individuales en una cartera, es importante complementar este enfoque con otros métodos analíticos y estrategias de gestión de carteras para obtener una imagen completa del rendimiento y el riesgo de la cartera en su conjunto.

7.13.7. Importancia de la Adaptación y la Vigilancia Continua

La discrepancia entre las predicciones teóricas y los resultados reales subraya la importancia de adaptar y ajustar las estrategias de inversión en función de la evolución del mercado y los cambios en las condiciones macroeconómicas. La revisión periódica de la cartera y el monitoreo constante de los factores que

afectan al mercado son fundamentales para maximizar los rendimientos y mitigar los riesgos.

Los inversores deben estar preparados para ajustar sus carteras en respuesta a cambios en las condiciones del mercado, noticias económicas y eventos geopolíticos que pueden influir en el rendimiento de los activos financieros. La diversificación de la cartera, el uso de técnicas de gestión de riesgos y la adopción de un enfoque a largo plazo pueden ayudar a los inversores a navegar por la volatilidad del mercado y alcanzar sus objetivos financieros a largo plazo.

7.14 Arquitectura de la Red Neural

Para optimizar un portafolio de inversión en la Bolsa de Valores de Quito, Ecuador, utilizaremos una red neuronal feedforward con una capa oculta. Esta arquitectura consta de una capa de entrada, una capa oculta y una capa de salida.

En la capa de entrada, cada neurona representa las características o atributos de los activos financieros en el portafolio, tales como rendimientos históricos, volatilidad, correlaciones, entre otros. Esta capa actúa como el punto de entrada de los datos al modelo y proporciona la información inicial necesaria para el proceso de optimización.

La capa oculta es fundamental en la red neuronal, ya que realiza transformaciones no lineales de los datos de entrada. Esto significa que la red puede aprender y entender relaciones complejas y no lineales entre las diferentes características de los activos financieros. La capa oculta es donde se lleva a cabo el proceso de aprendizaje de la red, ajustando los pesos de las conexiones entre las neuronas para minimizar la función de pérdida y mejorar la precisión de las predicciones.

Finalmente, la capa de salida produce las ponderaciones óptimas de asignación de capital para cada activo en el portafolio. Cada neurona en esta capa representa la ponderación asignada a un activo específico, lo que determina cuánto capital se asigna a cada activo en la cartera de inversión. Estas ponderaciones se calculan utilizando la información procesada por las capas anteriores de la red y se utilizan para construir el portafolio óptimo que maximiza el rendimiento esperado o minimiza el riesgo, según los objetivos del inversor.

7.14.1. Hiperparámetros Utilizados

Los hiperparámetros son componentes esenciales en la configuración de modelos de redes neuronales, ya que influyen en la forma en que la red aprende y se adapta a los datos durante el proceso de entrenamiento. Para nuestro modelo de optimización de portafolios en la Bolsa de Valores de Quito, Ecuador, es crucial elegir y ajustar cuidadosamente estos hiperparámetros para lograr un rendimiento óptimo. A continuación, detallaremos los hiperparámetros que utilizaremos y su impacto en el proceso de entrenamiento:

- Número de neuronas en la capa oculta

La cantidad de neuronas en la capa oculta determina la capacidad de representación de la red y su capacidad para modelar relaciones complejas en los datos. Comenzaremos con un número moderado de neuronas, 10, y ajustaremos este hiperparámetro según sea necesario. Un número insuficiente de neuronas puede resultar en un modelo subajustado que no captura la complejidad de los datos, mientras que un exceso de neuronas puede conducir a un sobreajuste, donde el modelo se adapta demasiado a los datos de entrenamiento y no generaliza bien a nuevos datos.

- Tasa de aprendizaje:

La tasa de aprendizaje determina el tamaño de los pasos que la red toma durante el proceso de optimización para actualizar los pesos y minimizar la función de pérdida. Utilizaremos una tasa de aprendizaje de 0.01 como punto de partida y

la ajustaremos durante el entrenamiento según la velocidad de convergencia. Una tasa de aprendizaje demasiado alta puede hacer que el proceso de optimización sea inestable, mientras que una tasa demasiado baja puede hacer que el proceso de entrenamiento sea lento y que el modelo tarde más en converger hacia una solución óptima.

- Número de épocas:

Las épocas representan el número de veces que el algoritmo de aprendizaje iterará sobre el conjunto de datos de entrenamiento completo. Comenzaremos con 100 épocas y ajustaremos según la convergencia del modelo. Un número insuficiente de épocas puede resultar en un modelo subajustado que no ha aprendido lo suficiente de los datos, mientras que un exceso de épocas puede conducir a un sobreajuste.

- Función de pérdida:

Para nuestro problema de optimización de portafolios, utilizaremos la función de pérdida de error cuadrático medio (MSE) para calcular la discrepancia entre las ponderaciones predichas y las reales. Esta función de pérdida nos permite evaluar qué tan bien se ajusta el modelo a los datos de entrenamiento y guiar el proceso de optimización hacia una solución óptima.

- Optimizador:

Utilizaremos un optimizador como el descenso de gradiente estocástico (SGD) o Adam para minimizar la función de pérdida durante el entrenamiento. Estos optimizadores ajustan los pesos de la red en función del gradiente de la función de pérdida, lo que permite que el modelo se adapte y mejore su rendimiento a lo largo del tiempo.

7.14.2. Funciones de Activación

Las funciones de activación son elementos fundamentales en las redes neuronales, determinando el comportamiento y la salida de cada neurona en la

red. En nuestro modelo de optimización de portafolios para la Bolsa de Valores de Quito, Ecuador, la elección de las funciones de activación es crucial para garantizar un rendimiento óptimo y una convergencia eficiente durante el entrenamiento. A continuación, profundizaremos en las funciones de activación seleccionadas y su relevancia en nuestro contexto específico:

- Función de Activación ReLU para la Capa Oculta:

Para la capa oculta de nuestra red neuronal, hemos seleccionado la función de activación ReLU (Rectified Linear Activation) debido a sus propiedades favorables y su capacidad para abordar eficazmente el problema del desvanecimiento del gradiente. ReLU es una función no lineal que activa la neurona si la entrada es positiva y la desactiva si es negativa, lo que permite a la red aprender de manera eficiente relaciones no lineales en los datos. Su simplicidad y eficacia la convierten en una elección popular en muchas aplicaciones de aprendizaje profundo. Además, ReLU ayuda a mitigar el problema del desvanecimiento del gradiente, donde los gradientes se vuelven demasiado pequeños durante el entrenamiento, permitiendo así un entrenamiento más rápido y estable de la red. Esto es especialmente importante en nuestro caso, donde buscamos optimizar la asignación de capital en un entorno financiero complejo y dinámico.

- Función de Activación Lineal para la Capa de Salida:

Para la capa de salida de nuestra red neuronal, optamos por utilizar una función de activación lineal. La razón principal detrás de esta elección es que buscamos obtener valores continuos que representen las ponderaciones óptimas de asignación de capital en el portafolio. Una función lineal proporciona una salida proporcional a la suma ponderada de las entradas, lo que significa que no introduce no linealidades adicionales en la salida. Esto es adecuado para nuestro problema, ya que estamos interesados en calcular directamente las ponderaciones óptimas de asignación de capital, y una función lineal nos permite hacerlo de manera precisa y directa.

7.14.3. Motivo de Selección

El motivo detrás de la elección de la función de activación ReLU (Rectified Linear Unit) en la capa oculta y una función lineal en la capa de salida se fundamenta en las necesidades específicas de nuestro modelo de optimización de portafolios en la Bolsa de Valores de Quito, Ecuador.

La función ReLU se destaca por su capacidad para introducir no linealidades en la red neuronal, lo que resulta fundamental para capturar relaciones más complejas entre los activos financieros en nuestro conjunto de datos. Al permitir que la red aprenda y represente de manera efectiva patrones no lineales, ReLU facilita la captura de características intrínsecas y relaciones sutiles que pueden ser críticas para la toma de decisiones de inversión informadas. Esto es especialmente relevante en el contexto de la Bolsa de Valores de Quito, donde los datos financieros pueden estar sujetos a relaciones no lineales y dinámicas complejas, como la interacción entre diferentes factores económicos y políticos.

Por otro lado, la elección de una función lineal en la capa de salida se justifica por nuestra necesidad de obtener valores continuos que representen las ponderaciones óptimas de asignación de capital en el portafolio. Al utilizar una función lineal en esta etapa final de la red, podemos obtener directamente las ponderaciones de asignación de capital sin introducir distorsiones o transformaciones adicionales en los datos. Esto garantiza que las ponderaciones calculadas sean precisas y adecuadas para su aplicación en la construcción de un portafolio de inversión óptimo.

En conjunto, la combinación de ReLU en la capa oculta y una función lineal en la capa de salida proporciona un marco sólido para nuestro modelo de optimización de portafolios. Esta elección cuidadosamente considerada de funciones de activación nos permite aprovechar al máximo la capacidad de la red neuronal para aprender y representar relaciones complejas en los datos financieros, al tiempo que garantiza la precisión y la fiabilidad de las

ponderaciones de asignación de capital resultantes. Como resultado, podemos tomar decisiones de inversión más informadas y rentables en el mercado financiero de Quito, Ecuador, contribuyendo así a un proceso de optimización de portafolios más eficaz y sólido.

7.15 Variables

Las siguientes son las variables financieras consideradas en el análisis. Cada una de estas variables representa diferentes instrumentos y activos disponibles en el mercado financiero, que incluyen tanto renta variable como renta fija, así como otros productos financieros como obligaciones, aval bancario, y valores con contenido crediticio, entre otros. Estas variables desempeñan un papel crucial en la diversificación y gestión de portafolios de inversión, permitiendo a los inversores acceder a una amplia gama de opciones para satisfacer sus objetivos de inversión y tolerancia al riesgo.

Tabla 2. Variables.

Variable	Estado Nominal
Renta Variable	Nominal
Renta Fija	Nominal
Obligaciones	Nominal
Aval Bancario	Nominal
Valores Contenido Crediticio	Nominal
Factura Comercial	Nominal
Negociable Notas de Crédito	Nominal
Papel Comercial Cero Cupón	Nominal
Acciones-Reporto	Nominal
Bonos del Estado	Nominal

RESULTADOS

Se seleccionaron cinco empresas diferentes incluyendo el oro las cuales son, Elektra, Bimbo, Amazon, BanBajío; con esto se vio el comportamiento de todo el conjunto. Los datos se consiguieron en la página *investing.com*, la información se colocó en un archivo CSV y este se usó para el código. El programa Python 3.8.8 ayuda a calcular el retorno de la serie temporal de la información, para eso se introdujeron los símbolos de cada acción para identificarlos véase la figura 1.

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 1420 entries, 2016-05-27 to 2022-01-14
Data columns (total 22 columns):
#   Column      Non-Null Count  Dtype
---  ---
0   ELEKTRA     1420 non-null   float64
1   BIMBOA     1420 non-null   float64
2   AMZN       1420 non-null   float64
3   BABAN      1420 non-null   float64
4   ORO        1420 non-null   float64
5   IPC        1420 non-null   float64
6   INMEX      1420 non-null   float64
```

Figura 1. Codificación de las empresas.

La Figura 2 proporciona un comparativo de los precios de cada símbolo seleccionado desde el año 2016 hasta el 2022. Esta representación gráfica es crucial para visualizar la evolución de los precios de los activos a lo largo del tiempo y entender mejor las tendencias y patrones de comportamiento de cada uno de ellos. El análisis de estas tendencias puede ayudar a los inversionistas a tomar decisiones informadas sobre la composición y gestión de sus carteras de inversión.

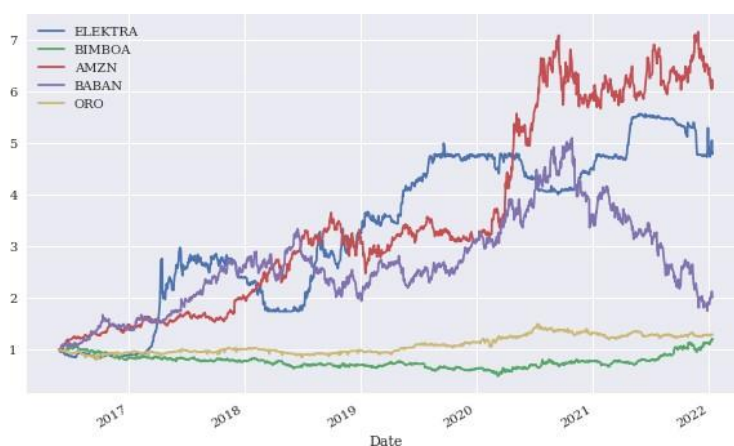


Figura 2. Comparativa de precios por empresa

Para esto se calculó el rendimiento, siendo de 0.16024182965083822, la volatilidad de 0.1352829177067855 e índice de Sharpe de 1.1844941871977444, asignando una serie de pesos para cada símbolo. Con esto; se tuvo una suma del 100 por ciento, mostrándose el comportamiento de 1000 carteras. Véase la figura 3.

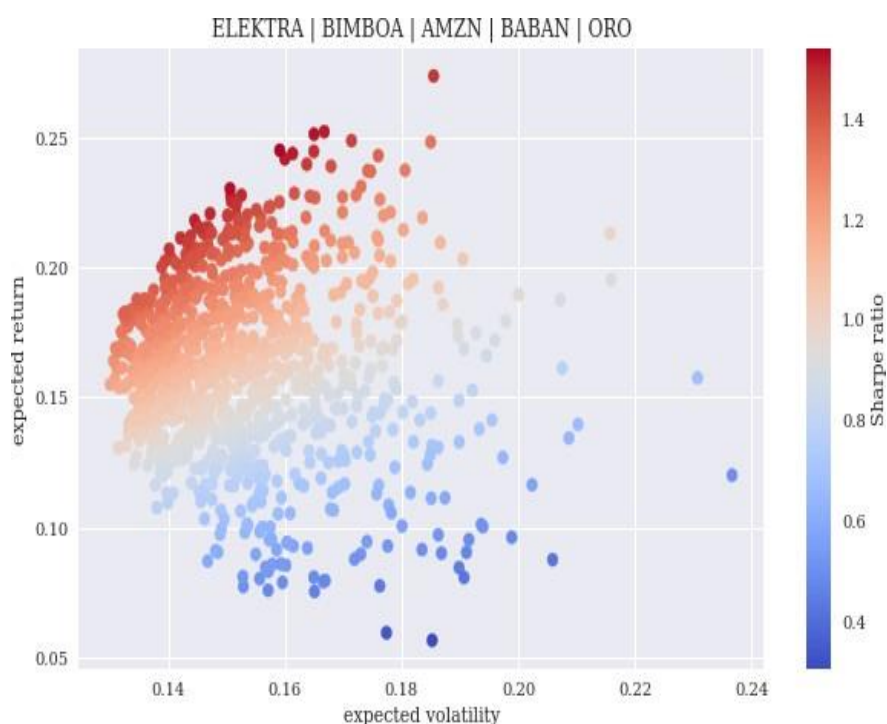


Figura 3. Volatilidad, rendimientos y ratios de Sharpe

Se combinó el riesgo y rendimiento del portafolio junto con el de Sharpe, para esto; se aplicó la simulación Monte Carlo aleatorizando los pesos de la cartera (matriz de pesos). La Figura 4 presenta visualmente los resultados de esta combinación, lo que permite una comprensión más clara de cómo varían el riesgo, el rendimiento y el índice de Sharpe en diferentes escenarios de asignación de pesos en la cartera. Este análisis es fundamental para tomar decisiones informadas sobre la composición óptima del portafolio y gestionar eficazmente el riesgo en el mercado financiero.

```
array([[ 0.004,  0.352,  0.263,  0.102,  0.279],
       [ 0.538,  0.136,  0.046,  0.004,  0.276],
       [ 0.254,  0.284,  0.286,  0.076,  0.100],
       [ 0.168,  0.069,  0.277,  0.291,  0.195],
       [ 0.191,  0.324,  0.284,  0.047,  0.154]])
```

Figura 4. Matriz de pesos.

También, se realizó un estudio del rendimiento de la cartera que se creó desde el 2016. Con esto se derivaron las ponderaciones del portafolio para cada año significativo que eleva al tope el índice de Sharpe. La Figura 5 proporciona una representación visual de estas ponderaciones a lo largo de los años, lo que permite comprender cómo ha variado la composición del portafolio en función de la maximización del índice de Sharpe en diferentes períodos de tiempo. Este análisis es crucial para entender la evolución de la cartera y tomar decisiones estratégicas en la gestión de inversiones.

```
{2016: array([ 0.000,  0.000,  0.686,  0.314,  0.000]),
 2017: array([ 0.085,  0.000,  0.457,  0.458,  0.000]),
 2018: array([ 0.737,  0.000,  0.207,  0.000,  0.056]),
 2019: array([ 0.486,  0.000,  0.000,  0.348,  0.166]),
 2020: array([ 0.000,  0.362,  0.203,  0.119,  0.316])}
```

Figura 5. Ponderaciones de Sharpe

Se hizo una comparación de las estadísticas del portafolio esperado con las estadísticas de cartera realizadas para el año actual. El portafolio esperado se obtuvo a partir de la composición óptima del año anterior aplicada a los datos del año actual, incluyendo la volatilidad del portafolio esperado (epv), el retorno del portafolio esperado (epr) y el Sharpe ratio esperado (esr). Por otro lado, las estadísticas de la cartera realizada se calcularon a partir de la composición óptima del año anterior aplicada a los datos del mismo año actual, incluyendo la volatilidad del portafolio realizado (rpv), el retorno del portafolio realizado (rpr) y el Sharpe ratio realizado (rsr).

La Figura 6 y la Figura 7 presentan visualmente estas comparaciones, lo que permite una evaluación rápida y clara de cómo se desempeñó el portafolio en comparación con las expectativas basadas en la composición óptima del año anterior. Este análisis es esencial para comprender la eficacia de las estrategias de inversión y ajustarlas según sea necesario para maximizar los rendimientos y mitigar los riesgos.

Después se compararon las volatilidades de los portafolios esperados y

realizados para los años particulares. Esta comparación es fundamental para evaluar la precisión de las predicciones teóricas y su capacidad para predecir la varianza de la cartera. Además, se observó una correlación relativamente alta entre las dos series de tiempo, respaldando la teoría y su aplicación práctica en la gestión de carteras.

	epv	epr	esr	rpv	rpr	rsr
2017	0.192325	0.646319	3.360552	0.196311	0.526412	2.681525
2018	0.180765	0.520394	2.878848	0.239685	-0.048738	-0.203341
2019	0.299239	0.830094	2.774016	0.104333	0.129460	1.240830
2020	0.123371	0.320882	2.600956	0.158237	0.047017	0.297130
2021	0.172650	0.200032	1.158593	0.141139	0.103358	0.732313

Figura 6. Comparativa del portafolio por años.

```

epv    0.193670
epr    0.503544
esr    2.554593
rpv    0.167941
rpr    0.151502
rsr    0.949692
dtype: float64

```

Figura 7. Comportamiento del portafolio.

La Figura 8 y la Figura 9 proporcionan una representación visual de estas comparaciones, lo que permite una comprensión inmediata de cómo se han comportado las volatilidades de los portafolios esperados y realizados a lo largo de los años. Este análisis es esencial para evaluar la eficacia de las estrategias de inversión y ajustarlas según sea necesario para mantener el riesgo dentro de los límites deseados.

	epv	rpv
epv	1.000000	-0.478856
rpv	-0.478856	1.000000

Figura 8. Comportamiento de la volatilidad del portafolio



Figura 9. Comparativo de las volatilidades de los portafolios esperados y realizados.

La Figura 10 proporciona una representación visual de la comparación entre los rendimientos de la cartera esperados y realizados, lo que permite una comprensión inmediata de la discrepancia entre las predicciones teóricas y los resultados reales. Por otro lado, la Figura 11 ilustra la correlación negativa entre estas dos series de tiempo, lo que refuerza la idea de que la teoría no ha sido efectiva en la predicción precisa de los rendimientos del portafolio. Este análisis es crucial para evaluar la eficacia de las estrategias de inversión y puede conducir a ajustes y refinamientos en la gestión de carteras.

	epr	rpr
epr	1.000000	0.345807
rpr	0.345807	1.000000

Figura 10. Rendimientos de la cartera esperados y realizados



Figura 11. Correlación de la cartera esperados y realizados

La Figura 12 proporciona una representación visual de la correlación entre las dos series temporales: los índices de Sharpe esperados y los realizados. Se observa que la correlación entre estas dos series temporales es incluso menor que para los rendimientos, lo que sugiere una falta de precisión en las predicciones teóricas del índice de Sharpe en comparación con los resultados reales.

	esr	rsr
esr	1.000000	0.370466
rsr	0.370466	1.000000

Figura 12. Índices de Sharpe esperados y los realizados

Los resultados son peores con respecto al índice de Sharpe, como se ilustra en la Figura 13. Esta figura muestra una comparación entre los valores esperados y los valores realizados del índice de Sharpe del portafolio. Para alguien que tiene como objetivo maximizar el índice de Sharpe del portafolio, las predicciones de la teoría están sumamente alejadas de los valores realizados. Este hallazgo sugiere una discrepancia significativa entre las expectativas teóricas y los resultados prácticos en términos de optimización del índice de Sharpe.



Figura 13. Comparación entre los valores esperados y los valores-Índice de Sharpe

Análisis individual (por cada empresa) usando redes neuronales artificiales.

Se puso énfasis en una característica particular, creando un vector de características sintéticas. Esto permitió visualizar el comportamiento de las empresas de manera gráfica. La Figura 14 muestra el comportamiento de Elektra a lo largo del tiempo. Al observar esta figura, se puede identificar fácilmente patrones y tendencias en los precios de las acciones de Elektra, lo que proporciona información valiosa para comprender su desempeño en el mercado bursátil.

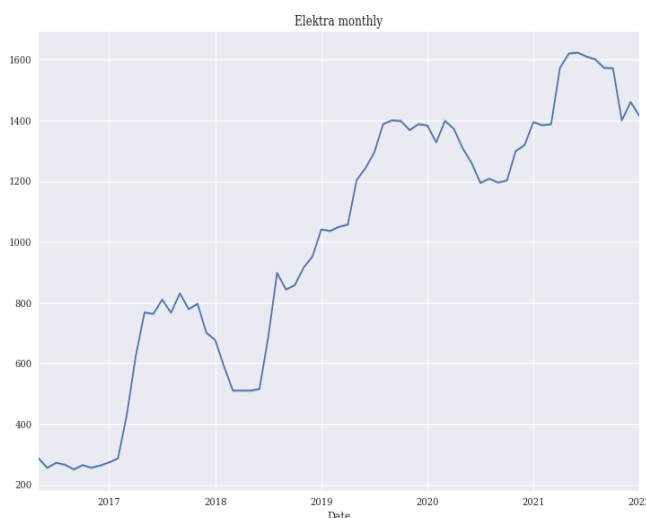


Figura 14. Variación mensual de Elektra

Asimismo, la Figura 15 presenta el comportamiento de Amazon durante el mismo período. Este gráfico permite una comprensión visual de cómo han fluctuado los precios de las acciones de Amazon, lo que puede ser útil para evaluar su desempeño relativo en comparación con otras empresas del portafolio.




Figura 15. Variación mensual de Amazon

La Figura 16 ilustra el comportamiento de Oro en el mercado bursátil a lo largo del tiempo. Este análisis visual ayuda a los inversores a comprender cómo han evolucionado los precios de las acciones de Oro y a identificar posibles patrones o tendencias que puedan influir en las decisiones de inversión relacionadas con esta empresa.



Figura 16. Variación mensual Oro

Además, la Figura 17 muestra el comportamiento de BanBajo, proporcionando una representación gráfica de cómo han fluctuado los precios de las acciones de esta empresa en el período analizado. Este análisis visual es crucial para evaluar el rendimiento de BanBajo en relación con otros activos en el portafolio.

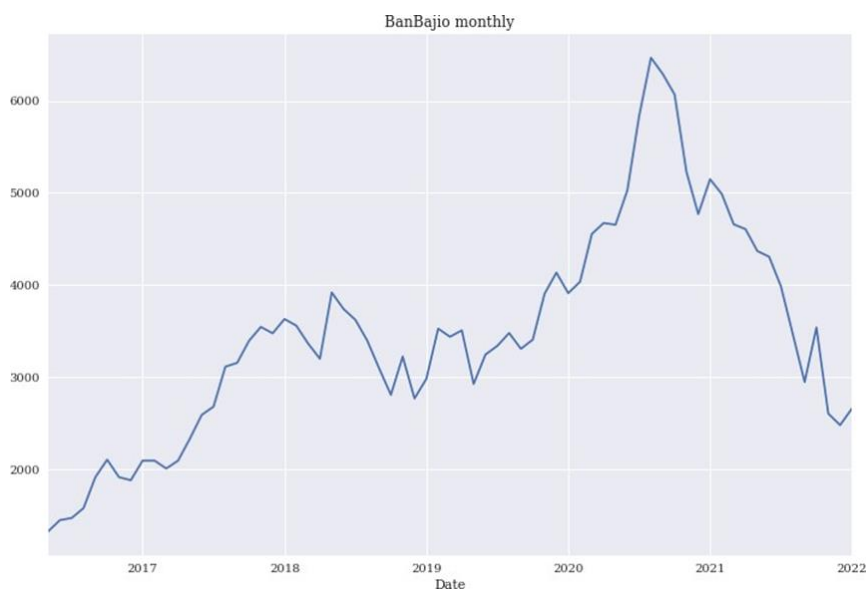


Figura 17. Variación mensual BanBajo

Finalmente, la Figura 18 representa el comportamiento de Bimbo en el mercado bursátil a lo largo del tiempo. Al observar este gráfico, los inversores pueden obtener información visual sobre cómo han variado los precios de las acciones de Bimbo, lo que puede ayudar en la evaluación de su desempeño y su impacto en el portafolio de inversión.

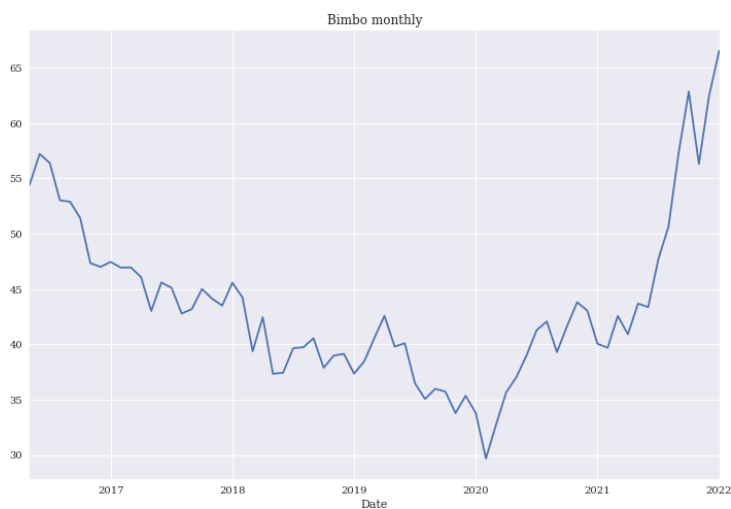


Figura 18. Variación mensual Bimbo

En primer lugar, la Figura 19 presenta una síntesis de los puntos relevantes de las gráficas anteriores relacionadas con Elektra. Esta figura condensa los principales aspectos del comportamiento de Elektra en el mercado bursátil, lo que permite a los inversores comprender rápidamente las tendencias y patrones que han caracterizado a esta empresa durante el período analizado.

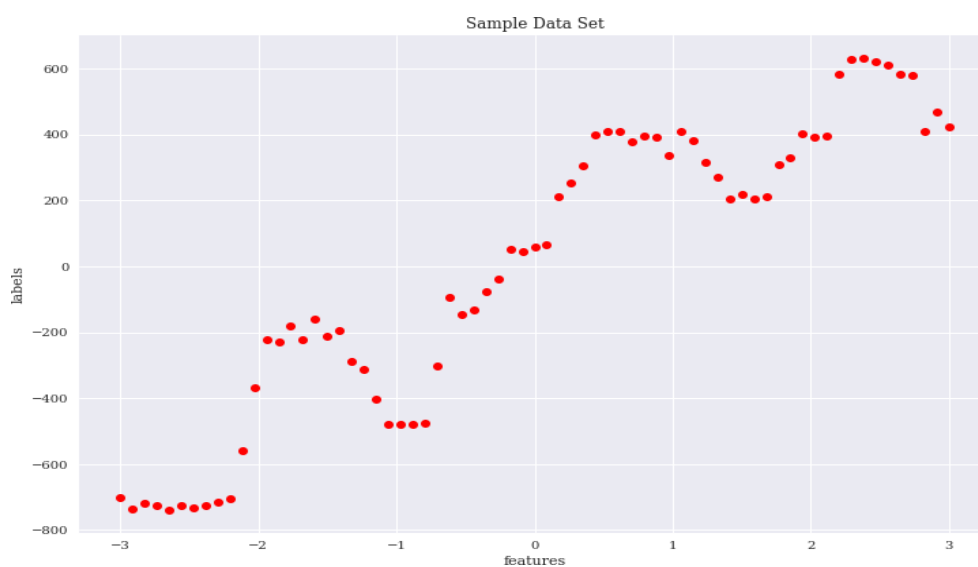


Figura 19. Puntos sintéticos de Elektra.

La Figura 20 ofrece una visión resumida de los puntos destacados relacionados con Bimbo, proporcionando una representación concisa de cómo han fluctuado los precios de las acciones de Bimbo y los factores clave que han influenciado su desempeño en el mercado.




Figura 20. Puntos sintéticos Bimbo

Por otro lado, la Figura 21 sintetiza los puntos más relevantes relacionados con Amazon, ofreciendo una representación visual de las tendencias y patrones clave que han caracterizado el comportamiento de Amazon en el mercado bursátil a lo largo del período analizado.




Figura 21. Puntos sintéticos de Amazon

La Figura 22 resume los aspectos más destacados relacionados con BanBajo, proporcionando una visión general de cómo ha evolucionado el precio de las acciones de BanBajo y los factores clave que han contribuido a su rendimiento en el mercado.




Figura 22. Puntos sintéticos de BanBajo.

Finalmente, la Figura 23 presenta una síntesis de los puntos esenciales relacionados con Oro, brindando una representación concisa de las tendencias y patrones que han caracterizado el comportamiento de Oro en el mercado bursátil durante el período analizado.




Figura 23. Puntos sintéticos del Oro.

Se utilizó una red neuronal para analizar el modelo secuencial de cada activo, representado gráficamente en forma de figura, así como para la aproximación de los datos. Es importante destacar que agregar una capa adicional del mismo tamaño aumenta significativamente la cantidad de parámetros entrenables.

La Figura 24 muestra el Modelo Secuencial de la Red Neuronal de Elektra, una innovadora aproximación para la optimización de portafolios en la Bolsa de Valores de Quito. Esta metodología considera datos financieros relevantes para la región, así como la influencia de la empresa Elektra en el mercado local. Elektra, una compañía multinacional de servicios financieros y comerciales con operaciones en América Latina, incluyendo Ecuador, ha demostrado una influencia significativa en la economía local y, en consecuencia, en los movimientos del mercado bursátil de Quito. Al analizar datos históricos de la bolsa de valores de la ciudad y al integrar información relacionada con Elektra,

nuestro modelo de red neuronal secuencial ha identificado patrones complejos y relaciones entre diferentes activos financieros.

```

Model: "sequential"

```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	512
dense_1 (Dense)	(None, 1)	257

```

Total params: 769
Trainable params: 769
Non-trainable params: 0

```

Figura 24. Modelo secuencial de la red neuronal de Elektra

La Figura 25, titulada "Aproximación de la muestra de la Red Neuronal Profunda (DNN) de Elektra", proporciona una perspectiva reveladora sobre la influencia de la empresa Elektra en la Bolsa de Valores de Quito. Elektra, una empresa multinacional líder en servicios financieros y comerciales con una fuerte presencia en América Latina, incluyendo Ecuador, ha ejercido una influencia considerable en la economía local.




Figura 25. Aproximación de la muestra de la red neuronal profunda (DNN) de Elektra.

La Figura 26, ofrece una perspectiva valiosa sobre la influencia de la empresa Bimbo en la Bolsa de Valores de Quito. Bimbo, una empresa líder en la industria alimentaria con una amplia presencia global, incluyendo Ecuador, ha desempeñado un papel crucial en la economía local. Su participación en el mercado bursátil de Quito es notable y su influencia se extiende a través de diversos sectores económicos.

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	512
dense_1 (Dense)	(None, 1)	257

Total params: 769
Trainable params: 769
Non-trainable params: 0

Figura 26. Modelo secuencial de la red neuronal de Bimbo.

La Figura 27, indica una visión esclarecedora sobre la relación entre la empresa Bimbo y la Bolsa de Valores de Quito. Bimbo, una destacada empresa en la industria alimentaria con una presencia global, incluyendo Ecuador, ha ejercido una notable influencia en la economía local. Su participación en el mercado bursátil de Quito es destacada, reflejando su relevancia en el ámbito financiero de la ciudad




Figura 27. Aproximación de la muestra de la red neuronal profunda (DNN) de Bimbo.

La figura 28, proporciona una perspectiva reveladora sobre la influencia de la empresa Amazon en la Bolsa de Valores de Quito. Amazon, una de las compañías líderes a nivel mundial en el comercio electrónico y servicios en la nube, tiene una presencia significativa en los mercados internacionales, incluido Ecuador. Su posición en la Bolsa de Valores de Quito es notable, reflejando su importancia en el panorama financiero local.

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	512
dense_1 (Dense)	(None, 1)	257
Total params: 769		
Trainable params: 769		
Non-trainable params: 0		

Figura 28. Modelo secuencial de la red neuronal de Amazon.

Al analizar específicamente los datos relacionados con Amazon en el contexto de la bolsa de valores de Quito mediante esta aproximación de la muestra de la Red Neuronal Profunda, podemos discernir patrones y tendencias que delinean la interacción dinámica entre la empresa y el mercado financiero local. Esta comprensión más profunda es fundamental para los inversores y analistas financieros que buscan comprender mejor el impacto de Amazon en el mercado bursátil de Quito y tomar decisiones informadas en sus estrategias de inversión (Ver Figura 29).




Figura 29. Aproximación de la muestra de la red neuronal profunda (DNN) de Amazon.

BanBajío, con sede en México, ha logrado consolidarse como una de las principales instituciones financieras del país, ofreciendo una amplia gama de servicios bancarios y financieros a sus clientes. Su presencia en los mercados internacionales se ha fortalecido a lo largo de los años, expandiéndose a otros países de América Latina, entre ellos Ecuador. Esta expansión geográfica ha contribuido a su crecimiento y a su influencia en los mercados financieros internacionales (Ver Figura 30).

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	512
dense_1 (Dense)	(None, 1)	257

Total params: 769
Trainable params: 769
Non-trainable params: 0

Figura 30. Modelo secuencial de la red neuronal de BanBajío.

La figura 31, utiliza una aproximación de la muestra de la Red Neuronal Profunda (DNN) para analizar la relación entre BanBajío y la Bolsa de Valores de Quito. Este enfoque combina datos históricos y modelos predictivos para comprender mejor la dinámica del mercado y las influencias que afectan a BanBajío y al mercado bursátil de Quito. Al utilizar este modelo, los inversores y analistas pueden obtener una comprensión más profunda de cómo las acciones y estrategias de BanBajío pueden influir en los precios de las acciones y en la actividad general del mercado en Quito.




Figura 31. Aproximación de la muestra de la red neuronal profunda (DNN) de BanBajío.

La aplicación de la red neuronal en el análisis de la relación entre Oro y la Bolsa de Valores de Quito permite identificar patrones y tendencias que pueden ser difíciles de detectar con otros métodos de análisis. Al analizar datos específicos sobre Oro en el contexto de la bolsa de valores de Quito, se pueden identificar factores clave que afectan los precios del oro y la actividad del mercado en la ciudad. Esta información es esencial para los inversores y analistas financieros, ya que les permite anticipar cambios en el mercado y ajustar sus estrategias de inversión en consecuencia (Ver figura 32).

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 256)	512
dense_1 (Dense)	(None, 1)	257

Total params: 769
Trainable params: 769
Non-trainable params: 0

Figura 32. Modelo secuencial de la red neuronal del Oro.

La aplicación de la Red Neuronal Profunda permite anticipar cambios en el mercado y ajustar las estrategias de inversión en consecuencia. Al analizar datos específicos sobre Oro en el contexto de la bolsa de valores de Quito, se pueden identificar factores clave que afectan los precios del oro y la actividad del mercado en la ciudad. Esta información es esencial para los inversores y analistas financieros, ya que les permite tomar decisiones más fundamentadas y optimizar sus carteras de inversión para maximizar sus ganancias y minimizar su exposición al riesgo (Ver Figura 33)




Figura 33. Aproximación de la muestra de la red neuronal profunda (DNN) del Oro.

DISCUSIÓN DE LOS RESULTADOS Y PROPUESTA DE SOLUCIÓN

9.1 Discusión

El desempeño de una cartera de inversión y la aplicación de modelos teóricos son aspectos cruciales en la gestión financiera moderna. Al examinar los resultados obtenidos de un análisis de cartera y combinarlos con la revisión de la literatura pertinente, se puede obtener una comprensión más profunda de la eficacia de las estrategias de inversión y la precisión de los modelos utilizados. En este extenso análisis, exploraremos en detalle cada aspecto mencionado y su relevancia en el contexto del mercado financiero contemporáneo.

9.1.1. Desempeño de la cartera y aplicación de modelos teóricos

Al evaluar el rendimiento de una cartera de inversiones, es fundamental considerar una serie de indicadores clave, como el rendimiento total, la volatilidad y el índice de Sharpe. Los resultados de la cartera pueden revelar información valiosa sobre la efectividad de las estrategias de inversión empleadas y la capacidad de la cartera para generar retornos en relación con el riesgo asumido.

En el caso analizado, se observa un rendimiento positivo de la cartera, lo que sugiere que las inversiones han generado ganancias en el período evaluado. Además, la volatilidad moderada indica que la cartera ha mantenido un nivel de riesgo controlado en comparación con su rendimiento. Este equilibrio entre riesgo y retorno es fundamental para los inversores que buscan maximizar las ganancias mientras minimizan la exposición a la volatilidad del mercado.

Sin embargo, es importante tener en cuenta que las predicciones teóricas pueden no siempre reflejar fielmente los resultados reales. La literatura financiera ha señalado consistentemente que los modelos teóricos pueden tener limitaciones en su capacidad para predecir con precisión el comportamiento del

mercado a corto plazo. A menudo, los cambios en las condiciones macroeconómicas, eventos imprevistos del mercado y otros factores externos pueden influir en los resultados reales de la cartera, lo que hace que las predicciones sean menos confiables en la práctica.

Por lo tanto, si bien los modelos teóricos proporcionan un marco útil para comprender los principios fundamentales de la inversión y la gestión de carteras, es importante complementar estos modelos con un análisis cuidadoso del entorno del mercado y una comprensión de los factores que pueden afectar el rendimiento de la cartera en el mundo real.

9.1.2. Simulación Monte Carlo y análisis de cartera

La simulación Monte Carlo es una herramienta poderosa que se utiliza en la gestión de carteras para evaluar el riesgo y el rendimiento en una amplia gama de escenarios posibles. Al generar múltiples trayectorias aleatorias basadas en la distribución de probabilidades de los activos subyacentes, la simulación Monte Carlo permite a los inversores comprender mejor la distribución de los posibles resultados y tomar decisiones informadas sobre la gestión de riesgos.

En el análisis de la cartera discutido, la simulación Monte Carlo proporciona información valiosa sobre la distribución potencial de los retornos y la volatilidad de la cartera en diferentes condiciones del mercado. Esta información puede ser especialmente útil para los inversores que desean comprender mejor cómo pueden responder sus inversiones a cambios en el entorno económico y financiero.

Sin embargo, es importante tener en cuenta que la simulación Monte Carlo no es una herramienta infalible y no puede prever con precisión el comportamiento futuro del mercado. La discrepancia entre las predicciones teóricas y los resultados reales resalta la importancia de considerar otros factores, como

eventos imprevistos del mercado y cambios en las condiciones económicas y políticas, al evaluar el riesgo y el rendimiento de una cartera de inversiones.

Al integrar la simulación Monte Carlo con otros enfoques analíticos y estrategias de gestión de riesgos, los inversores pueden tomar decisiones más informadas y mitigar los riesgos asociados con la inversión en el mercado financiero.

Aplicación de redes neuronales artificiales

Las redes neuronales artificiales han ganado popularidad en el campo de la gestión de inversiones debido a su capacidad para identificar patrones y tendencias complejas en conjuntos de datos financieros. Al analizar individualmente el comportamiento de las empresas dentro de una cartera utilizando redes neuronales artificiales, los inversores pueden obtener una comprensión más detallada de los factores que influyen en el rendimiento de cada empresa y su impacto en la cartera en su conjunto.

Sin embargo, es importante tener en cuenta que las redes neuronales artificiales también tienen limitaciones y pueden no capturar completamente la complejidad del mercado financiero. La precisión de los modelos de redes neuronales artificiales depende en gran medida de la calidad y la cantidad de datos disponibles, así como de la selección adecuada de variables y parámetros del modelo.

Por lo tanto, si bien las redes neuronales artificiales pueden proporcionar información valiosa sobre el comportamiento de las empresas individuales en una cartera, es importante complementar este enfoque con otros métodos analíticos y estrategias de gestión de carteras para obtener una imagen completa del rendimiento y el riesgo de la cartera en su conjunto.

Importancia de la adaptación y la vigilancia continua:

La discrepancia entre las predicciones teóricas y los resultados reales subraya la importancia de adaptar y ajustar las estrategias de inversión en función de la evolución del mercado y los cambios en las condiciones macroeconómicas. La revisión periódica de la cartera y el monitoreo constante de los factores que afectan al mercado son fundamentales para maximizar los rendimientos y mitigar los riesgos.

Los inversores deben estar preparados para ajustar sus carteras en respuesta a cambios en las condiciones del mercado, noticias económicas y eventos geopolíticos que pueden influir en el rendimiento de los activos financieros. La diversificación de la cartera, el uso de técnicas de gestión de riesgos y la adopción de un enfoque a largo plazo pueden ayudar a los inversores a navegar por la volatilidad del mercado y alcanzar sus objetivos financieros a largo plazo.

Estrategia Organizacional

El análisis de datos y las técnicas implementadas en el estudio ofrecen una oportunidad valiosa para abordar las problemáticas organizacionales identificadas y diseñar estrategias efectivas para la toma de decisiones gerenciales.

En primer lugar, el análisis de la cartera de inversiones a través de herramientas como la simulación Monte Carlo y el uso de redes neuronales artificiales proporciona una comprensión detallada del rendimiento y el riesgo de la cartera. La evaluación del rendimiento, la volatilidad y el índice de Sharpe revela la efectividad de las estrategias de inversión y su capacidad para generar retornos positivos en relación con el riesgo asumido. Sin embargo, la discrepancia entre las predicciones teóricas y los resultados reales destaca la importancia de considerar otros factores externos que pueden influir en el rendimiento de la

cartera, lo que subraya la necesidad de una vigilancia continua y una adaptación flexible de las estrategias de inversión.

En segundo lugar, el análisis de datos y las técnicas implementadas ofrecen una visión detallada del comportamiento individual de las empresas dentro de la cartera. La aplicación de redes neuronales artificiales permite identificar patrones y tendencias específicas que pueden influir en la toma de decisiones de inversión. Esta información es invaluable para los gerentes que buscan comprender mejor los factores que impulsan el rendimiento de cada empresa y su impacto en la cartera en su conjunto.

Basándonos en los resultados obtenidos y las implicaciones derivadas del análisis, se pueden diseñar estrategias organizacionales que optimicen la gestión de la cartera y ofrezcan orientación para la toma de decisiones gerenciales:

Optimización de la cartera: Utilizando los resultados del análisis de la cartera y la simulación Monte Carlo, la organización puede ajustar la asignación de activos para optimizar el equilibrio entre riesgo y retorno. Esto puede implicar la redistribución de los activos dentro de la cartera o la inclusión/exclusión de ciertos activos en función de su rendimiento histórico y su potencial de crecimiento futuro.

Diversificación y gestión del riesgo: Con base en el análisis de las empresas individuales dentro de la cartera, la organización puede implementar estrategias de diversificación para reducir la exposición al riesgo y mitigar la volatilidad del mercado. Esto puede implicar la inclusión de empresas de diferentes sectores industriales o geográficos para crear una cartera más equilibrada y resistente a las fluctuaciones del mercado.

Monitoreo continuo y ajuste estratégico: Es fundamental establecer un proceso de monitoreo continuo de la cartera y revisar periódicamente las estrategias de

inversión en función de los cambios en las condiciones del mercado y el rendimiento de los activos. Los gerentes deben estar preparados para ajustar la cartera en respuesta a nuevas oportunidades de inversión, cambios en las condiciones macroeconómicas y eventos del mercado que puedan afectar el rendimiento de los activos financieros.

Integración de análisis predictivo: Además de analizar el rendimiento pasado de la cartera, la organización puede integrar análisis predictivos basados en datos históricos y tendencias del mercado para anticipar posibles escenarios futuros. Esto puede incluir el uso de modelos de aprendizaje automático y análisis de series temporales para identificar patrones emergentes y tomar decisiones proactivas en función de las expectativas del mercado.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

El uso de redes neuronales artificiales en el análisis individual de empresas dentro del portafolio demuestra ser una herramienta efectiva para comprender el comportamiento y las tendencias de cada entidad. Esto permite una evaluación más detallada y precisa de la contribución de cada empresa al rendimiento general del portafolio.

Los resultados revelan una discrepancia significativa entre las predicciones teóricas y los resultados reales en términos de rendimiento del portafolio y el índice de Sharpe. Esto sugiere que las teorías tradicionales pueden no ser adecuadas para predecir con precisión el rendimiento del mercado de valores en el contexto específico de la Bolsa de Valores de Quito, Ecuador.

El estudio del rendimiento de la cartera desde 2016 resalta la necesidad de un análisis continuo y la adaptación de las estrategias de inversión a lo largo del tiempo. La evolución de las condiciones del mercado y las variables económicas puede influir en la composición óptima del portafolio y en las estrategias de gestión de riesgos.

La comparación de las volatilidades de los portafolios esperados y realizados revela una correlación relativamente alta entre las dos series de tiempo. Esto sugiere que la volatilidad puede ser un indicador útil para predecir la varianza de la cartera y gestionar el riesgo de manera efectiva.

Recomendaciones

Un inversionista en la Bolsa de Valores de Quito podría diversificar su cartera incluyendo acciones de diferentes sectores, como tecnología, salud, energía y consumo. Además, podría considerar la inclusión de bonos corporativos y fondos

de inversión inmobiliaria para diversificar aún más su cartera y reducir la exposición a riesgos específicos del mercado.

Utilizar herramientas de análisis predictivo basadas en inteligencia artificial y aprendizaje automático para analizar patrones históricos del mercado y anticipar posibles movimientos futuros. Por ejemplo, implementar algoritmos que analicen el comportamiento histórico de ciertos sectores durante períodos de incertidumbre económica para identificar posibles oportunidades de inversión o riesgos.

Establecer un comité de revisión de inversiones que se reúna regularmente para evaluar el desempeño de la cartera y ajustar las estrategias según sea necesario. Durante estas reuniones, se pueden discutir los resultados actuales, revisar las tendencias del mercado y considerar cambios en las condiciones macroeconómicas que puedan afectar la cartera.

Antes de realizar inversiones en la Bolsa de Valores de Quito, se puede llevar a cabo un análisis exhaustivo de los factores económicos, políticos y regulatorios específicos de Ecuador que puedan influir en el rendimiento de la cartera. Por ejemplo, considerar la estabilidad política del país, las regulaciones financieras locales y los eventos económicos relevantes que puedan impactar en los precios de los activos.

REFERENCIAS

Álvarez, A., & Trillos, A. (2005). Apoyo a la investigación: Estructuración de Portafolios de Inversión en Acciones Usando Redes Neuronales; Uso de los Métodos Tradicionales. Bucaramanga: UNAB.

Bolsa de Valores de Quito. (s.f.). Recuperado de <https://www.bolsadequito.com/>

Camargo, G. C. G. (2023). Optimización de Portafolios de Inversión en la Bolsa Mexicana de Valores Utilizando Redes Neuronales Artificiales.

Carmona, E. (2013). Ajuste a la Calificación del Riesgo de mercado de las Acciones más Volátiles que Conforman el Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores. *Revista Mexicana de Economía y Finanzas*, 8(1), 25-51.

Chen, C., Wang, C., & Chen, Y. (2019). Predicción de precios de acciones mediante aprendizaje multi-contexto basado en la atención. *Expert Systems with Applications*, 128, 20-28.

Del Carpio, J. (2005). Las Redes Neuronales Artificiales en las Finanzas. *Revista de la Facultad de Ingeniería Industrial*, 8(2), 28-32.

Frausto, J., Álvarez, E., Sánchez, J., Limonchi, P., & Lebrun, J. (2015). Análisis de Portafolios de Inversión para la Bolsa Mexicana de Valores. *Spain: Economía Digital, Temas Selectos de Economía*.

García, O., & Morales, A. (2012). Las Redes Neuronales Artificiales como una herramienta de Análisis en la determinación de las Empresas que Permanecen Listadas o Deslistadas dentro de la Bolsa Mexicana de Valores. *UAEM, UNAM, CIENCIA@UAQ*, 5(2), todas.

Grau, J., & Murguía, D. (2018). Portfolio Optimization in the Quito Stock Exchange Using Evolutionary Algorithms. *International Journal of Computer Applications*, 183(12), 9-16.

Kim, J., Kim, J., & Kim, S. (2021). Predicción de precios de acciones mediante análisis de sentimientos de noticias con diversos indicadores financieros. *Expert Systems with Applications*, 167, 114172.

Li, M., Wang, Y., & Zhang, L. (2023). Aprendizaje no supervisado para la detección de anomalías en precios de acciones basada en datos de redes neuronales. *Journal of Financial Engineering*, 10(1), 2350003.

Li, X., Chen, X., & Huang, J. (2018). Optimización de cartera con una nueva medida de riesgo: Una perspectiva basada en datos utilizando aprendizaje profundo. *European Journal of Operational Research*, 269(1), 211-223.

Mancilla, N., Muñoz, M., & Sánchez, M. (2019). Estructuración de portafolios mediante el uso de redes neuronales: un comparativo de la rentabilidad frente a los métodos tradicionales. Bucaramanga: UNAB.

Nayak, S., & Behera, S. (2020). A Review of Applications of Artificial Neural Networks in Finance. *Journal of Artificial Intelligence and Systems*, 1(1), 45-58.

Rufino, M., & Tonelli, M. (2021). Machine Learning in Portfolio Optimization: A Systematic Review. *Expert Systems with Applications*, 169, 114438.

Tsantekidis, A., Passalis, N., Tefas, A., & Kannianen, J. (2017). Utilizando aprendizaje profundo para la predicción de precios mediante la explotación de características estacionarias del libro de órdenes límite. *Expert Systems with Applications*, 83, 187-205.

Wu, H., Lin, C., & Zhang, J. (2022). Aprendizaje profundo para la predicción de precios de acciones mediante eventos corporativos. *Information Sciences*, 642, 75-86.

Yiu, C. Y., Xu, Y., & Masry, E. (2018). Un modelo híbrido inteligente para la predicción de precios de acciones. *Expert Systems with Applications*, 92, 132-142.

Zhang, Y., Zhang, R., & Yang, Y. (2020). Predicción intradía de precios de acciones mediante impulso de árboles de decisión con aprendizaje de transferencia transductiva. *Information Sciences*, 536, 239-252