

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Posgrados

Portafolio de inversiones con modelos de Inteligencia Artificial

Proyecto de Titulación

Gustavo Patricio Recalde Vásquez

Alejandro Proaño, Ph.D.

Director de Trabajo de Titulación

Trabajo de titulación de posgrado presentado como requisito para la obtención del título de Magíster
en Inteligencia Artificial

Quito, 02 Diciembre de 2024

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ
COLEGIO DE POSGRADOS

HOJA DE APROBACIÓN DE TRABAJO DE TITULACIÓN
Portafolio de inversiones con modelos de Inteligencia Artificial

Gustavo Patricio Recalde Vásquez

Nombre del Director del Programa:	Felipe Grijalva
Título académico:	Ph.D. en Ingeniería Eléctrica
Director del programa de:	Inteligencia Artificial
Nombre del Decano del colegio Académico:	Eduardo Alba
Título académico:	Doctor en Ciencias Matemáticas
Decano del Colegio:	Ciencias e Ingenierías
Nombre del Decano del Colegio de Posgrados:	Dario Niebieskikwiat
Título académico:	Doctor en Física

Quito, diciembre 2024

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombre del estudiante: Gustavo Patricio Recalde Vásquez

Código de estudiante: 00338850

C.I.: 1002252136

Lugar y fecha: Quito, 02 de Diciembre de 2024.

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

UNPUBLISHED DOCUMENT

Note: The following graduation project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

DEDICATORIA

A mi amada esposa Vanessa, Por ser mi apoyo incondicional, mi inspiración constante y mi compañera en cada paso de este camino. Tu paciencia, aliento y amor fueron la fuerza que me impulsó a superar cada desafío. Este logro también es tuyo, porque sin ti no habría sido posible. Con todo mi amor y gratitud.

RESUMEN

En el presente trabajo de tesis, construimos un portafolio de inversiones utilizando redes neuronales LSTM y técnicas de Procesamiento del Lenguaje Natural (PLN). Desarrollamos modelos de predicción de precios de acciones que integran datos financieros con análisis de sentimientos extraídos de noticias y publicaciones en línea, empleando tanto métodos tradicionales de PLN como modelos avanzados basados en Transformers. Nuestros resultados indican que la incorporación del análisis de sentimientos mejora la precisión de las predicciones. Optimizamos el portafolio para maximizar el rendimiento ajustado al riesgo y lo evaluamos frente a índices de referencia como el XLK y el S&P 500. Los resultados muestran que nuestro enfoque mejora la precisión de las predicciones y el desempeño del portafolio, demostrando el potencial de combinar aprendizaje automático y PLN en estrategias de inversión.

Palabras clave: Portafolio de inversiones, Redes LSTM, Procesamiento del Lenguaje Natural, Análisis de sentimientos, Transformers, Predicción de acciones, Ratio de Sharpe

ABSTRACT

In this thesis, we constructed an investment portfolio using Long Short-Term Memory (LSTM) neural networks and Natural Language Processing (NLP) techniques. We developed stock price prediction models that integrate financial data with sentiment analysis derived from news and online posts, employing both traditional NLP methods and advanced Transformer-based models. Our findings indicate that incorporating sentiment analysis enhances the accuracy of predictions. The portfolio was optimized to maximize risk-adjusted returns and evaluated against benchmark indices such as the XLK and the S&P 500. The results demonstrate that our approach improves prediction accuracy and portfolio performance, showcasing the potential of combining machine learning and NLP in investment strategies.

Key words: Investment portfolio, LSTM networks, Natural Language Processing (NLP), Sentiment analysis, Transformers, Stock prediction, Sharpe Ratio.

TABLA DE CONTENIDO

I.	Introducción	12
I-A.	Contexto del problema	12
I-B.	Motivación	12
I-C.	Objetivo general del proyecto	12
II.	Estado del Arte	13
II-A.	Predicción de series temporales.	13
II-B.	Análisis de sentimientos en finanzas.	13
II-B1.	VADER (Valence Aware Dictionary and sEntiment Reasoner)	13
II-B2.	FinBERT	13
II-C.	Integración del Análisis de Sentimientos en la Predicción Financiera.	13
II-D.	Optimización de portafolios.	14
II-E.	Diferenciación del trabajo.	14
III.	Metodología	14
III-A.	Recolección de datos financieros.	14
III-B.	Extracción de datos textuales.	15
III-C.	Preprocesamiento de datos financieros.	15
III-D.	Preprocesamiento de datos textuales.	15
III-E.	Análisis de sentimientos con VADER.	15
III-F.	Análisis de sentimientos con Transformers (FinBERT).	15
III-G.	Integración de datos en el modelo.	16
III-H.	Entrenamiento del modelo LSTM.	16
III-H1.	Descripción de la Arquitectura LSTM	16
III-I.	Construcción del Portafolio	16
III-I1.	Criterio de Selección de Acciones	16
III-I2.	Formulación Matemática del Problema de Optimización	16
III-I3.	Implementación y Solución del Problema de Optimización	17
III-I4.	Criterios de Actualización del Portafolio	17
III-I5.	Evaluación del Portafolio	17
IV.	Resultados y Discusión	18
IV-A.	Modelo 1: Datos Históricos Financieros.	18
IV-B.	Modelo 2: Inclusión de Datos de Sentimientos usando VADER.	19
IV-C.	Modelo 3: Inclusión de datos de sentimientos usando Transformers.	19
IV-D.	Portafolio.	19
IV-D1.	Rendimientos esperados diarios	19
IV-D2.	Distribución de Pesos en el Portafolio	19
IV-D3.	Desempeño del Portafolio	20
IV-D4.	Interpretación General	20
IV-E.	Comparación con los Índices de Referencia	20
IV-E1.	Rendimiento Promedio Diario	20
IV-E2.	Volatilidad Diaria	20
IV-E3.	Máximo Drawdown (MDD)	20
IV-E4.	Sharpe Ratio	20
IV-E5.	Visualización de Retornos Diarios	20

IV-E6.	Análisis de Eventos Clave	20
IV-E7.	Limitaciones y Oportunidades de Mejora	21
IV-E8.	Interpretación General	21
V.	Conclusiones	21
VI.	Apéndices	22
	Apéndice A: Gráficos de algunas acciones relevantes con cada modelo	22
A-A.	AMAZON	22
A-B.	GOOGLE	22
A-C.	NVIDIA	23
A-D.	APPLE	23
A-E.	NETFLIX	24
	Apéndice B: Rendimientos de cada acción del portafolio	24
	Apéndice C: Configuración experimental	24
	Referencias	25

ÍNDICE DE TABLAS

I.	Modelo 1: Solo Datos Históricos Financieros.	18
II.	Modelo 2: Inclusión de Datos de Sentimientos (VADER).	19
III.	Modelo 3: Inclusión de Datos de Sentimientos con Transformers (FinBERT)	19
IV.	Métricas del Portafolio Optimizado	20
V.	Métricas comparativas del Portafolio Optimizado y los Índices de Referencia	20
VI.	Rendimientos Esperados Diarios de las Acciones del Índice XLK	24

ÍNDICE DE FIGURAS

1.	Diagrama de bloques del pipeline para la predicción de precios y optimización de portafolio	14
2.	Gráfico del comportamiento de datos históricos	15
3.	Predicción acciones de NVIDIA con datos históricos	18
4.	Predicción acciones de NVIDIA con datos de sentimientos con VADER	19
5.	Predicción acciones de NVIDIA con datos de sentimientos	19
6.	Portafolio óptimo según rendimientos y ratio de sharpe	20
7.	Comparación de Retornos Diarios: Portafolio vs. XLK	21
8.	Comparación de Retornos Diarios: Portafolio vs. S&P 500	21
9.	Predicción acciones de AMAZON con datos históricos	22
10.	Predicción acciones de AMAZON incluyendo análisis de sentimientos	22
11.	Predicción acciones de AMAZON incluyendo análisis de sentimientos con Transformers	22
12.	Predicción acciones de GOOGLE con datos históricos	22
13.	Predicción acciones de GOOGLE incluyendo análisis de sentimientos	22
14.	Predicción acciones de GOOGLE incluyendo análisis de sentimientos con Transformers	22
15.	Predicción acciones de NVIDIA con datos históricos	23
16.	Predicción acciones de NVIDIA incluyendo análisis de sentimientos	23
17.	Predicción acciones de NVIDIA incluyendo análisis de sentimientos con Transformers .	23
18.	Predicción acciones de APPLE con datos históricos	23
19.	Predicción acciones de APPLE incluyendo análisis de sentimientos	23
20.	Predicción acciones de APPLE incluyendo análisis de sentimientos con Transformers . .	23
21.	Predicción acciones de NETFLIX con datos históricos	24
22.	Predicción acciones de NETFLIX incluyendo análisis de sentimientos	24
23.	Predicción acciones de NETFLIX incluyendo análisis de sentimientos con Transformers	24

Portafolio de Inversiones con Modelos de Inteligencia Artificial

Gustavo Recalde, *Universidad San Francisco de Quito USFQ*

Resumen—En el presente trabajo de tesis, construimos un portafolio de inversiones utilizando redes neuronales LSTM y técnicas de Procesamiento del Lenguaje Natural (PLN). Desarrollamos modelos de predicción de precios de acciones que integran datos financieros con análisis de sentimientos extraídos de noticias y publicaciones en línea, empleando tanto métodos tradicionales de PLN como modelos avanzados basados en Transformers. Nuestros resultados indican que la incorporación del análisis de sentimientos mejora la precisión de las predicciones. Optimizamos el portafolio para maximizar el rendimiento ajustado al riesgo y lo evaluamos frente a índices de referencia como el XLK y el S&P 500. Los resultados muestran que nuestro enfoque mejora la precisión de las predicciones y el desempeño del portafolio, demostrando el potencial de combinar aprendizaje automático y PLN en estrategias de inversión.

Index Terms—Portafolio de inversiones, Redes LSTM, Procesamiento del Lenguaje Natural, Análisis de sentimientos, Transformers, Predicción de acciones.

I. INTRODUCCIÓN

I-A. Contexto del problema

Predecir los precios de las acciones en la bolsa de valores es uno de los desafíos constantes en finanzas. Los mercados financieros están en continua fluctuación ante múltiples factores como económicos, políticos, y, más recientemente, opiniones compartidas en redes sociales y medios de comunicación. Esta naturaleza volátil y sensible a diferentes influencias requiere que inversionistas y entidades financieras empleen herramientas avanzadas que permitan anticiparse a todos estos movimientos. Esta volatilidad se debe a que el mercado opera bajo la ley de la oferta y la demanda: las decisiones de compra o venta de los inversores impactan directamente en los precios de las acciones.

En este contexto, los índices de mercado como el XLK y el S&P 500 son fundamentales para comprender y analizar el comportamiento del mercado. El XLK (Technology Select Sector SPDR Fund) agrupa empresas del sector tecnológico, incluyendo líderes en semiconductores, software, hardware y servicios tecnológicos. Este índice representa el comportamiento del sector tecnológico en el mercado bursátil. Por otro lado, el S&P 500 incluye las 500 empresas más grandes de Estados Unidos, abarcando una variedad de sectores y sirviendo como un barómetro general de la economía estadounidense. Ambos índices se utilizan comúnmente como puntos de referencia para evaluar estrategias de inversión.

En este entorno, la inteligencia artificial ofrece un conjunto de técnicas que pueden capturar estos patrones y tendencias, proporcionando una base más sólida para la toma de decisiones. Sin embargo, predecir precios no solo involucra datos históricos financieros; la percepción del mercado, los sentimientos y reacciones de los inversionistas también juegan un papel importante. Nuestro objetivo es aprovechar estas oportunidades y construir un modelo de predicción que integre ambos tipos de información: los datos de mercado y el análisis de sentimientos, en un modelo que capture estas dinámicas y proporcione predicciones más precisas.

I-B. Motivación

Con el avance del aprendizaje automático y el procesamiento del lenguaje natural (PLN), han surgido nuevas oportunidades para analizar grandes volúmenes de datos financieros y textuales. Las redes neuronales profundas, especialmente las Redes de Memoria a Largo Plazo (LSTM por sus siglas en inglés), han demostrado ser efectivas en la modelación de series temporales. Además, el análisis de sentimientos a partir de noticias financieras y publicaciones en redes sociales puede proporcionar información valiosa sobre las percepciones del mercado, influenciando los movimientos de precios. Aunque este trabajo se enfoca en las acciones del sector tecnológico, los métodos y modelos desarrollados son aplicables a cualquier tipo de activo financiero, siempre que se disponga de datos históricos adecuados. Esto resalta la flexibilidad del enfoque y su potencial para ser utilizado en diversos contextos del mercado.

I-C. Objetivo general del proyecto

Nuestro objetivo principal de este trabajo es desarrollar modelos de predicción de precios de acciones que integren datos financieros históricos y análisis de sentimientos derivados de noticias y publicaciones en redes sociales. Este enfoque aprovecha redes neuronales LSTM y modelos avanzados de procesamiento del lenguaje natural (PLN), como Transformers, especializados en lenguaje financiero.

Además, se busca construir un portafolio optimizado basado en las acciones que conforman el índice XLK y compararlo con los índices XLK y S&P 500. Para ello, se empleará como métrica de evaluación el rendimiento ajustado al riesgo, con el fin de identificar estrategias de inversión que maximicen los beneficios mientras controlan los riesgos asociados.

II. ESTADO DEL ARTE

La predicción de precios de acciones utilizando aprendizaje automático y procesamiento de lenguaje natural (PLN) ha recibido mucha atención en los últimos años. Este trabajo combina técnicas tradicionales y modernas para abordar tres enfoques principales: predicciones basadas únicamente en datos históricos, predicciones que integran análisis de sentimientos mediante herramientas como VADER, y predicciones utilizando modelos avanzados como FinBERT, diseñado específicamente para el lenguaje financiero.

II-A. Predicción de series temporales.

Fischer y Krauss [2] demostraron la eficacia de las LSTM para identificar patrones en datos financieros secuenciales, superando en precisión a modelos tradicionales como ARIMA y GARCH. Este trabajo amplía ese enfoque al integrar análisis de sentimientos.

Además de las LSTM, otras arquitecturas de redes neuronales han sido exploradas en la predicción financiera. Las Redes Neuronales Convolucionales (CNN) han demostrado ser efectivas para extraer patrones locales de los datos financieros, particularmente útiles cuando las series temporales presentan comportamientos no lineales o características espaciales implícitas. Sin embargo, modelos híbridos como el CNN-LSTM han surgido como una solución prometedora. Este enfoque combina la capacidad de las CNN para detectar características locales con la habilidad de las LSTM para capturar relaciones temporales a largo plazo. Lu et al. [11] demostraron que este modelo híbrido supera en precisión a las arquitecturas individuales en la predicción de precios financieros, lo que lo convierte en una herramienta alternativa en estos problemas.

II-B. Análisis de sentimientos en finanzas.

El análisis de sentimientos es una técnica que extrae información subjetiva de textos, permitiendo evaluar emociones y actitudes expresadas. En el contexto financiero, el sentimiento del mercado puede influir significativamente en los precios de las acciones.

II-B1. VADER (Valence Aware Dictionary and sEntiment Reasoner): Es un modelo de análisis de sentimientos basado en léxicos y reglas, diseñado específicamente para captar el sentimiento en textos cortos y coloquiales, como los encontrados en redes sociales. Desarrollado por Hutto y Gilbert [4], VADER asigna puntajes de sentimiento a palabras y frases, teniendo en cuenta aspectos como la intensidad y contexto gramatical.

Características técnicas de VADER:

- Modelo basado en léxico y reglas: Utiliza un diccionario con más de 7,500 palabras y expresiones comunes, cada una con un puntaje de sentimiento preasignado en una escala de -4 (muy negativo) a +4 (muy positivo).
- Manejo de intensificadores y negaciones: Ajusta los puntajes de sentimiento según la presencia de palabras que intensifican o niegan el sentimiento.

- Entradas y salidas: La entrada es un texto preprocesado, y la salida es un diccionario con cuatro puntajes: positivo, negativo, neutral y compuesto. El puntaje compuesto es una métrica normalizada entre -1 y 1 que indica el sentimiento general del texto.
- Validación y rendimiento: VADER fue validado en conjuntos de datos de Twitter, comentarios de películas y reseñas de productos, demostrando una alta correlación con evaluaciones humanas y superando a otros métodos basados en léxicos en textos informales.

II-B2. FinBERT: Es un modelo de lenguaje preentrenado basado en la arquitectura BERT (Bidirectional Encoder Representations from Transformers), adaptado específicamente para el dominio financiero. Desarrollado por Yang et al. [19], FinBERT fue entrenado en grandes cantidades de datos financieros para capturar la terminología y expresiones propias del sector.

Características técnicas de FinBERT:

- Arquitectura Transformer: Basado en el modelo BERT introducido por Devlin et al. [5], utiliza mecanismos de atención para procesar secuencias de texto, capturando relaciones contextuales complejas entre palabras.
- Preentrenamiento en datos financieros: FinBERT se entrenó utilizando un corpus de 4.9 mil millones de tokens extraídos de fuentes específicas del dominio financiero, incluyendo:
 - Informes corporativos (Formularios 10-K y 10-Q).
 - Transcripciones de conferencias de resultados.
 - Reportes de analistas.

Este entrenamiento especializado le permite capturar la terminología y expresiones propias del sector financiero con mayor precisión que los modelos genéricos.

- Entradas y salidas: La entrada es un texto financiero preprocesado, mientras que la salida es una representación vectorial que puede ser utilizada para tareas específicas, como la clasificación de sentimientos (positivo, negativo, neutral) o la extracción de información.
- Resultados y rendimiento: En tareas de clasificación de sentimientos financieros, FinBERT demostró un desempeño superior al de BERT genérico, logrando una precisión superior al 90%. Esto destaca su capacidad para interpretar correctamente matices y contextos específicos del lenguaje financiero.

II-C. Integración del Análisis de Sentimientos en la Predicción Financiera.

La combinación de análisis de sentimientos con modelos de predicción financiera ha demostrado mejorar la precisión de las predicciones al incorporar información contextual del mercado.

Bollen et al. [1] utilizaron datos de Twitter para medir el sentimiento público y encontraron correlaciones significativas entre el estado de ánimo colectivo y los movimientos

del Dow Jones Industrial Average. Su estudio mostró que ciertas dimensiones del sentimiento, como la calma o el optimismo, podían predecir cambios en el mercado con una precisión de hasta el 87 %.

Gu et al. [3] desarrollaron un enfoque que integra FinBERT. En su trabajo, emplearon noticias financieras extraídas de la plataforma Benzinga para analizar el sentimiento asociado con empresas del índice NASDAQ-100, transformando los artículos en puntajes de sentimiento. Estos puntajes se incorporaron como características adicionales junto con datos históricos de precios para entrenar el modelo LSTM. La evaluación del modelo utilizó métricas como el Error Absoluto Medio (MAE) y el Error Porcentual Absoluto Medio (MAPE), mostrando que la inclusión del análisis de sentimientos a través de FinBERT mejoró significativamente la precisión de las predicciones en comparación con modelos basados únicamente en datos históricos. Este enfoque destaca cómo el análisis de noticias financieras puede enriquecer los modelos de predicción al capturar dinámicas subjetivas del mercado que no son evidentes en los datos cuantitativos.

Swathi et al. [16] utilizaron VADER para analizar el sentimiento en Twitter y alimentaron estos datos en un modelo LSTM optimizado para la predicción de precios de acciones. Su enfoque demostró que el análisis de sentimientos basado en redes sociales puede complementar los datos financieros tradicionales, proporcionando señales tempranas de cambios en el mercado.

II-D. Optimización de portafolios.

La teoría moderna de portafolios de Markowitz [12] establece que la diversificación permite maximizar el rendimiento esperado para un nivel dado de riesgo. El Ratio de Sharpe [15] es una medida clave que evalúa el rendimiento ajustado al riesgo de un portafolio.

En el contexto del aprendizaje automático, Zhang et al. [20] exploraron el uso de modelos de deep learning para la optimización de portafolios. Combinando predicciones basadas en series temporales con técnicas de optimización cuadrática, buscaron maximizar el Ratio de Sharpe. Su enfoque permitió adaptar la composición del portafolio en función de las predicciones del modelo, mejorando el rendimiento ajustado al riesgo.

Ledoit y Wolf [10] propusieron mejoras en la estimación de la matriz de covarianza de los retornos, lo que es crucial en la optimización de portafolios. Su método de “shrinkage” reduce el error de estimación y mejora la estabilidad del portafolio optimizado.

II-E. Diferenciación del trabajo.

Este estudio no solo busca predecir precios de acciones, sino también construir un portafolio optimizado basado en las acciones del índice XLK y compararlo con los índices XLK y S&P 500. Además, se evalúa el impacto de tres enfoques distintos: (1) datos financieros históricos, (2)

análisis de sentimientos mediante VADER y (3) análisis de sentimientos utilizando Transformers como FinBERT. Este enfoque integral, que combina técnicas avanzadas de PLN y métricas financieras tradicionales, representa una contribución novedosa al campo de la inteligencia artificial aplicada a finanzas.

III. METODOLOGÍA

Pipeline para la predicción de precios y optimización del portafolio

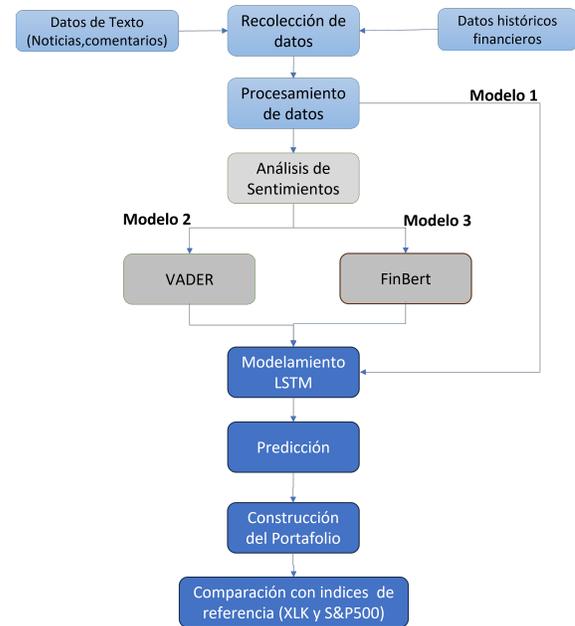


Figura 1. Diagrama de bloques del pipeline para la predicción de precios y optimización de portafolio

En la figura 1, se presenta el diagrama de bloques del pipeline utilizado en nuestro trabajo, que muestra las etapas clave en la construcción del modelo de predicción de precios de acciones y la optimización del portafolio. Cada bloque representa una etapa importante del proceso, detallada en las subsecciones posteriores.

III-A. Recolección de datos financieros.

Recopilamos datos históricos de precios ajustados de cierre y medias móviles para las acciones que componen el índice XLK, abarcando un periodo de cinco años (2019-2023). Estos datos fueron obtenidos a través de la API de Yahoo Finance y sirvieron como base para el análisis y modelado.

Si bien el presente trabajo se enfoca en las acciones del índice XLK, el proceso de recolección y análisis de datos financieros es adaptable a cualquier tipo de activo o índice bursátil. Esto incluye acciones de otros sectores, índices regionales, o incluso datos macroeconómicos relacionados, siempre que se disponga de información histórica de calidad.

La Figura 2 muestra el gráfico de comportamiento histórico de 5 acciones relevantes del sector tecnológico, que son

parte del índice XLK, en los últimos 5 años, donde podemos observar patrones de tendencia y volatilidad en cada acción para identificar periodos de alta o baja volatilidad, lo que resulta útil para ajustar el modelo de predicción y mejorar su precisión en periodos de comportamiento atípico del mercado.



Figura 2. Gráfico del comportamiento de datos históricos

III-B. Extracción de datos textuales.

Además de los datos financieros, para el análisis de sentimientos, recopilamos datos textuales de dos fuentes principales: publicaciones en el subreddit WallStreetBets de Reddit y noticias financieras extraídas mediante APIs de proveedores como Google News y Yahoo Finance. Estas fuentes son complementarias, ya que las publicaciones en Reddit reflejan el sentir de inversionistas minoristas, mientras que las noticias financieras ofrecen análisis más estructurados y respaldados por expertos.

Entre los datos recolectados, se incluyeron titulares, descripciones y contenido relevante relacionado con las empresas que componen el índice XLK. Estos textos formaron la base para el análisis de sentimientos, el cual integramos como una variable adicional en el modelo predictivo.

III-C. Preprocesamiento de datos financieros.

Normalizamos los datos financieros utilizando el método de *min-max scaling*, que transforma cada variable para que esté dentro del rango $[0, 1]$, lo cual facilita el modelado al mejorar la estabilidad de las series temporales y asegura que todas las características tengan el mismo rango de valores. Adicionalmente, generamos indicadores de tendencia, como medias móviles simples (SMA) de 10, 30 y 60 días, que proporcionan una representación suavizada de los movimientos de precios, mejorando la capacidad del modelo para identificar patrones relevantes en las series temporales.

III-D. Preprocesamiento de datos textuales.

Antes de analizar el sentimiento, procesamos los datos textuales siguiendo los pasos descritos a continuación, garantizando su consistencia y adecuación:

- Limpieza del texto: Eliminamos caracteres especiales, URLs, menciones y hashtags presentes en las publicaciones de Reddit, así como palabras irrelevantes.

- Tokenización: Dividimos los textos en palabras individuales o “tokens”. Por ejemplo, el texto “nvda stock up today” se convirtió en [“nvda”, “stock”, “up”, “today”].

- Lematización: Convertimos las palabras a su forma base para unificar términos similares. Por ejemplo, “stocks” se lematizó como “stock”.

- Eliminación de palabras de parada: Excluimos palabras comunes como “the”, “and” y “of”, que no aportan información relevante al análisis.

III-E. Análisis de sentimientos con VADER.

Como se mencionó en la sección anterior, VADER fue utilizado para evaluar el sentimiento general en publicaciones de Reddit y titulares de noticias financieras. Los textos fueron preprocesados mediante limpieza, tokenización y eliminación de palabras irrelevantes. Posteriormente, VADER asignó un puntaje compuesto $([-1, 1])$ a cada texto, ajustando la puntuación según intensificadores y negaciones presentes en el contenido.

Por ejemplo, una publicación de Reddit como “Tesla to the moon!!!” se procesó como [“Tesla”, “moon”] y recibió un puntaje positivo de $+0.7$, reflejando una percepción optimista. De manera similar, un titular financiero como “Apple stocks rise after earnings report” fue calificado con un puntaje positivo de $+0.8$ debido a términos asociados con crecimiento. Los puntajes individuales fueron agregados en promedios diarios para cada fuente (Reddit y noticias).

III-F. Análisis de sentimientos con Transformers (FinBERT).

Para el análisis de noticias financieras, empleamos FinBERT, un modelo Transformer preentrenado en lenguaje financiero, que es particularmente efectivo para capturar matices específicos del dominio.

FinBERT se aplicó para realizar un análisis más detallado y matizado de los mismos textos, clasificándolos en categorías de sentimiento positivo, negativo o neutral. Los textos preprocesados fueron ingresados al modelo, que utilizó su mecanismo de atención para identificar palabras clave relevantes. Esto permitió obtener una representación más precisa del impacto emocional y contextual de las publicaciones.

Por ejemplo, un comentario de Reddit como “Intel is going down, bad news everywher” fue clasificado como negativo debido a frases como “going down” y “bad news”. Asimismo, un titular financiero como “NVIDIA announces record revenue growth” fue clasificado como positivo, reflejando un impacto favorable para la empresa. A partir de estas clasificaciones, se calcularon porcentajes diarios para cada categoría en ambas fuentes.

III-G. Integración de datos en el modelo.

Los puntajes de sentimiento derivados de VADER y FinBERT se integraron con los datos financieros históricos en una matriz de características. Esta matriz incluyó:

- Precios de cierre de las acciones.
- Indicadores técnicos (medias móviles).
- Sentimiento promedio diario obtenido con VADER.
- Porcentajes diarios de noticias positivas, negativas y neutrales derivados de FinBERT.

Por ejemplo, para el día 15 de enero de 2024, las entradas del modelo incluyeron: un precio de cierre ajustado de \$200 para una acción específica, un valor de 0.65 como sentimiento promedio diario (VADER), y un 70% de noticias positivas (FinBERT). Estas variables se utilizaron para capturar tanto las tendencias históricas como el impacto del sentimiento del mercado en los precios.

III-H. Entrenamiento del modelo LSTM.

Entrenamos tres modelos LSTM con distintas configuraciones de entrada: uno con datos financieros históricos, otro que incluye análisis de sentimientos de VADER, y un tercero que utiliza análisis de sentimientos de FinBERT. Las LSTM (Long Short-Term Memory) al ser un tipo de red neuronal recurrente diseñada específicamente para modelar secuencias temporales, la hace ideal para analizar datos financieros, donde los valores actuales están influenciados por tendencias pasadas.

III-H1. Descripción de la Arquitectura LSTM: El modelo LSTM consta de una capa recurrente con 100 unidades ocultas, diseñada para capturar dependencias temporales en secuencias de datos de 60 días consecutivos. La capa LSTM procesa los datos de entrada en formato secuencial y genera una representación interna que resume las tendencias observadas. La salida final de la capa LSTM se conecta a una capa densa que transforma esta representación en un único valor escalar: el precio ajustado predicho para el día siguiente.

El conjunto de datos de entrada incluye cuatro características principales en el modelo base (*Adjusted Close*, medias móviles simples de 10, 30 y 60 días). En los modelos extendidos, se añade una quinta característica correspondiente al sentimiento promedio diario derivado de análisis textuales. Los datos se normalizan en el rango $[0, 1]$ utilizando `MinMaxScaler`, lo que asegura que todas las características tengan el mismo rango y mejora la estabilidad del modelo.

La configuración del modelo incluye la función de pérdida de Error Cuadrático Medio (MSE) y el optimizador Adam con una tasa de aprendizaje de 0,001. El entrenamiento se realizó utilizando un tamaño de lote de 32 durante un máximo de 20 épocas, número seleccionado tras observar en pruebas preliminares que la función de pérdida se estabilizaba rápidamente, alcanzando convergencia antes de este límite. Esta configuración permite un entrenamiento eficiente sin comprometer el rendimiento del modelo.

Finalmente, los tres modelos se evaluaron utilizando métricas estándar como MSE, MAE y R^2 , y se compararon los valores predichos con los valores reales en el conjunto de validación. Estas evaluaciones confirmaron la capacidad del modelo para capturar patrones históricos y el impacto positivo de la inclusión del análisis de sentimientos en la mejora de la precisión.

III-I. Construcción del Portafolio

Con base en las predicciones del modelo más preciso (Modelo 3, con FinBERT), se construyó un portafolio de inversión optimizado mediante la maximización del Ratio de Sharpe, que mide el rendimiento ajustado al riesgo. Este proceso considera tres componentes principales: criterios de selección de acciones, formulación matemática del problema de optimización y criterios de actualización. Estos elementos se diseñaron para maximizar el rendimiento ajustado al riesgo del portafolio.

III-I1. Criterio de Selección de Acciones: El universo de inversión está compuesto por las acciones del índice XLK, el cual agrupa empresas líderes del sector tecnológico. Este índice fue seleccionado debido a su alta volatilidad, liquidez y relevancia en los mercados financieros, además de ser un subconjunto del S&P 500. Esto permite realizar una comparación directa entre el desempeño del portafolio optimizado y ambos índices como referencias del sector tecnológico y del mercado en general.

Se decidió incluir todas las acciones del índice XLK para evaluar integralmente cómo las predicciones generadas por los modelos LSTM, junto con el análisis de sentimientos, pueden optimizar la asignación de pesos en el portafolio. Este enfoque asegura una diversificación inicial y permite medir el valor agregado de la estrategia optimizada frente a estrategias pasivas basadas en la replicación del índice.

III-I2. Formulación Matemática del Problema de Optimización: La asignación de pesos entre las acciones seleccionadas se realizó mediante un modelo de optimización diseñado para maximizar el Ratio de Sharpe del portafolio.

El Ratio de Sharpe S_p se define como:

$$S_p = \frac{E[R_p] - R_f}{\sigma_p} \quad (1)$$

Donde:

- $E[R_p]$: Rendimiento esperado del portafolio.
- R_f : Tasa libre de riesgo (asumida como 0 en este trabajo).
- σ_p : Desviación estándar (volatilidad) del rendimiento del portafolio.

El objetivo es determinar los pesos w_i asignados a cada acción i para maximizar S_p , sujeto a las siguientes restricciones:

$$\sum_{i=1}^N w_i = 1 \quad (2)$$

$$w_i \geq 0, \quad \forall i = 1, 2, \dots, N \quad (3)$$

Donde:

- N : Número total de acciones seleccionadas.
- w_i : Peso asignado a la acción i en el portafolio.

El rendimiento esperado del portafolio $E[R_p]$ se calcula como:

$$E[R_p] = \sum_{i=1}^N w_i E[R_i] \quad (4)$$

Donde $E[R_i]$ es el rendimiento esperado de la acción i , obtenido de las predicciones del modelo LSTM.

La volatilidad del portafolio σ_p se calcula utilizando la matriz de covarianza Σ :

$$\sigma_p = \sqrt{w^T \Sigma w} \quad (5)$$

Donde:

- w : Vector de pesos $w = [w_1, w_2, \dots, w_N]^T$.
- Σ : Matriz de covarianza $N \times N$ de los rendimientos de las acciones seleccionadas.

Para simplificar la resolución, el problema de optimización se transforma utilizando la optimización media-varianza de Markowitz, introduciendo un parámetro de aversión al riesgo λ :

$$\begin{aligned} & \underset{w}{\text{Maximizar}} && E[R_p] - \lambda \sigma_p^2 \\ & \text{Sujeto a} && \sum_{i=1}^N w_i = 1 \\ & && w_i \geq 0, \quad \forall i \end{aligned} \quad (6)$$

Al ajustar λ , se puede controlar el equilibrio entre el rendimiento esperado y la volatilidad del portafolio, buscando maximizar el Ratio de Sharpe.

III-I3. Implementación y Solución del Problema de Optimización: El proceso de optimización se realizó siguiendo estos pasos:

1. **Cálculo de rendimientos esperados:** Utilizando las predicciones del modelo LSTM, calculamos el rendimiento esperado diario $E[R_i]$ para cada acción seleccionada.
2. **Estimación de la volatilidad y matriz de covarianza:** Estimamos la volatilidad de cada activo y construimos la matriz de covarianza Σ utilizando los rendimientos históricos diarios de las acciones.

3. **Definición del problema de optimización:** Planteamos el problema utilizando la ecuación (6) como función objetivo, con las restricciones (2) y (3).
4. **Resolución del problema:** Empleamos métodos de optimización convexa, específicamente la programación cuadrática, utilizando herramientas como `cvxpy` en Python.
5. **Obtención de los pesos óptimos:** Tras resolver el problema, obtuvimos los pesos óptimos w_i^* para cada acción, que maximizan el rendimiento ajustado al riesgo del portafolio.
6. **Validación y análisis del portafolio:** Calculamos las métricas clave del portafolio optimizado, como el rendimiento esperado $E[R_p]$, la volatilidad σ_p y el Ratio de Sharpe S_p , para evaluar su desempeño en comparación con los índices de referencia.

III-I4. Criterios de Actualización del Portafolio:

Nuestro modelo genera predicciones diarias para capturar las dinámicas de corto plazo en el mercado, lo que permite una alta versatilidad en la frecuencia de actualización del portafolio. Sin embargo, la elección de esta frecuencia debe ajustarse a las necesidades del usuario y las condiciones específicas del mercado, considerando los siguientes aspectos:

- **Actualización diaria:** Esta frecuencia es ideal para estrategias más activas, donde el objetivo es maximizar las oportunidades de corto plazo capturadas por el modelo. No obstante, puede no ser adecuada para todos los casos debido a los costos asociados, como comisiones, spreads y mayor exposición al ruido del mercado. Esta opción es recomendable en mercados con costos de transacción bajos o para usuarios con estrategias enfocadas en alta rotación de activos.
- **Actualización mensual:** Este enfoque equilibra la estabilidad operativa con la capacidad predictiva del modelo. Al actualizar mensualmente, se minimizan costos operativos y se reduce la exposición a fluctuaciones transitorias, permitiendo decisiones basadas en tendencias de mediano plazo. Es una opción más conservadora y adecuada para usuarios que priorizan la eficiencia y consistencia a largo plazo.

La versatilidad del modelo permite que pueda adaptarse a diferentes frecuencias de actualización según las necesidades específicas del usuario. Desde una perspectiva financiera, recomendamos evaluar el balance entre costos operativos y el potencial de capturar oportunidades de mercado antes de definir la frecuencia de actualización. Este enfoque flexible asegura que el modelo pueda ser aplicado tanto en escenarios de alta frecuencia como en estrategias más estables y a largo plazo.

III-I5. Evaluación del Portafolio: La evaluación del portafolio optimizado se diseñó para medir su desempeño utilizando métricas estándar en finanzas y compararlo con índices de referencia, como el XLK y el S&P 500. Este proceso se estructuró en dos etapas principales: cálculo de métricas clave y comparación con *benchmarks*.

1. Métricas clave para la evaluación: La evaluación del portafolio se basó en el cálculo de métricas fundamentales que reflejan el rendimiento ajustado al riesgo, la volatilidad y la estabilidad del portafolio:

- **Rendimiento promedio diario** ($E[R_p]$): Representa la media aritmética de los rendimientos diarios obtenidos por el portafolio durante el periodo de análisis. Este indicador se calcula como:

$$E[R_p] = \frac{1}{T} \sum_{t=1}^T R_{p,t}$$

donde $R_{p,t}$ es el rendimiento del portafolio en el día t y T el número total de días evaluados.

- **Volatilidad diaria** (σ_p): Mide la desviación estándar de los rendimientos diarios, proporcionando una indicación del riesgo asociado al portafolio. Se calcula mediante:

$$\sigma_p = \sqrt{\frac{1}{T-1} \sum_{t=1}^T (R_{p,t} - E[R_p])^2}$$

- **Máximo Drawdown** (MDD): Evalúa la pérdida máxima acumulada desde un pico hasta un valle durante el periodo analizado. Este indicador se implementó mediante la identificación del punto máximo y el punto mínimo subsecuente en la curva acumulativa de rendimientos del portafolio:

$$MDD = \min_{t \in T} \frac{C_t - P_t}{C_t}$$

donde C_t es el valor máximo alcanzado hasta el tiempo t , y P_t es el valor mínimo subsecuente.

- **Ratio de Sharpe** (S_p): Se utilizó para evaluar el rendimiento ajustado al riesgo. Este indicador compara el exceso de rendimiento sobre la tasa libre de riesgo con la volatilidad del portafolio:

$$S_p = \frac{E[R_p] - R_f}{\sigma_p}$$

donde R_f es la tasa libre de riesgo, asumida como cero para simplificar los cálculos.

2. Implementación de la comparación con benchmarks: Para evaluar el desempeño del portafolio, se compararon sus métricas clave con las obtenidas por índices de referencia relevantes en el periodo de análisis:

- **Índice XLK:** Se seleccionó este índice debido a su enfoque en el sector tecnológico, alineado con las acciones incluidas en el portafolio. Los datos históricos del XLK se procesaron de manera similar a las acciones del portafolio para garantizar comparabilidad.
- **Índice S&P 500:** Se utilizó como un indicador general del mercado, representando una estrategia de inversión más diversificada. Los datos del S&P 500 se normalizaron para coincidir con el horizonte temporal y los valores iniciales del portafolio.

3. Herramientas y entorno de implementación: El cálculo de métricas y la comparación se implementaron utilizando Python, empleando las librerías `numpy`, `pandas` y `matplotlib`. Se realizaron cálculos diarios durante el periodo de análisis para garantizar la consistencia de las métricas, evaluando tanto la configuración inicial del portafolio como las actualizaciones mensuales para analizar su estabilidad a lo largo del tiempo.

IV. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados obtenidos de los tres modelos desarrollados para la predicción de precios de acciones: (1) utilizando solo datos históricos financieros, (2) incorporando análisis de sentimientos con VADER, y (3) integrando análisis de sentimientos mediante Transformers (FinBERT). Aunque el conjunto completo de acciones incluye las que forman parte del índice XLK (65 en total), los resultados tabulados se muestran para una selección representativa de cinco acciones. Estas acciones fueron elegidas debido a su relevancia en el índice XLK y su representación de diferentes sectores tecnológicos (retail, servicios en la nube, semiconductores, hardware y entretenimiento). Este enfoque permite observar el comportamiento del modelo en un subconjunto diverso antes de generalizar los resultados al resto del portafolio.

IV-A. Modelo 1: Datos Históricos Financieros.



Figura 3. Predicción acciones de NVIDIA con datos históricos

Cuadro I
MODELO 1: SOLO DATOS HISTÓRICOS FINANCIEROS.

Ticker	MSE Norm.	R^2
AMZN	0.000586	0.966930
GOOGL	0.000872	0.944334
NVDA	0.091816	0.454067
AAPL	0.004449	0.436502
NFLX	0.000977	0.969849

El primer modelo utiliza únicamente datos históricos financieros para predecir los precios de las acciones. Los resultados muestran que, en general, se alcanzan buenos valores de R^2 , lo que indica que el modelo captura una gran parte de la variabilidad en los datos. Los errores cuadráticos medios normalizados (MSE) varían según el ticker, aumentando considerablemente para NVDA y AAPL, que presentan errores más altos.

IV-B. Modelo 2: Inclusión de Datos de Sentimientos usando VADER.

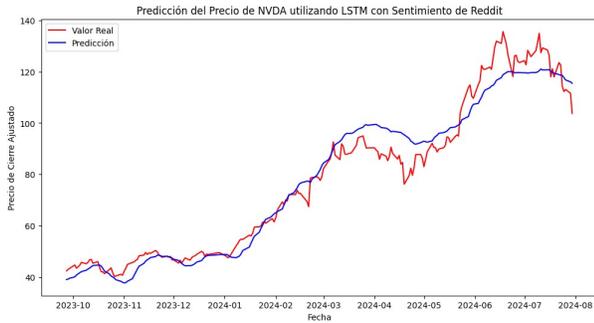


Figura 4. Predicción acciones de NVIDIA con datos de sentimientos con VADER

Cuadro II
MODELO 2: INCLUSIÓN DE DATOS DE SENTIMIENTOS (VADER).

Ticker	MSE	R^2
AMZN	0.000516	0.968278
GOOGL	0.001682	0.885265
NVDA	0.027108	0.803820
AAPL	0.000717	0.908220
NFLX	0.000985	0.966338

En el segundo modelo, se incorpora el análisis de sentimientos utilizando VADER. Se observa una mejora en la precisión para algunos tickers, como NVDA y AAPL, que muestran una reducción en el MSE. Sin embargo, para otros tickers como GOOGL, el modelo presenta una disminución en el R^2 , lo que sugiere que el análisis de sentimientos basado en VADER no es consistente en todos los casos y su impacto puede ser variable según la acción.

IV-C. Modelo 3: Inclusión de datos de sentimientos usando Transformers.

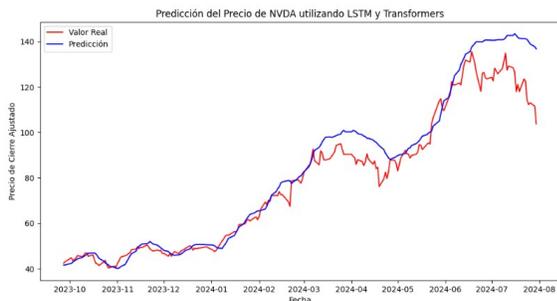


Figura 5. Predicción acciones de NVIDIA con datos de sentimientos

Cuadro III
MODELO 3: INCLUSIÓN DE DATOS DE SENTIMIENTOS CON TRANSFORMERS (FINBERT)

Ticker	MSE	R^2
AMZN	0.000492	0.969720
GOOGL	0.000994	0.932198
NVDA	0.023191	0.832167
AAPL	0.000953	0.877907
NFLX	0.000921	0.968539

El tercer modelo, que incluye análisis de sentimientos utilizando Transformers (FinBERT), muestra una mejora significativa en la precisión y consistencia de las predicciones en comparación con los dos modelos anteriores. Además, se observa un alto R^2 en promedio, lo cual confirma la efectividad del uso de Transformers en la captura de matices en el lenguaje financiero y su impacto positivo en la predicción de precios de acciones.

En resumen, los resultados sugieren que la integración de análisis de sentimientos, y en particular el uso de Transformers, mejora la precisión del modelo de predicción de acciones. FinBERT, en este contexto, demuestra ser superior a VADER, ya que proporciona predicciones más precisas y consistentes en comparación con el análisis de sentimientos basado en léxicos, lo que sugiere que los Transformers son más efectivos para capturar el contexto financiero en comparación con métodos de análisis de sentimientos tradicionales.

IV-D. Portafolio.

El portafolio optimizado, basado en predicciones con Transformers (FinBERT), utiliza las acciones del índice XLK para construir una estrategia de inversión. A continuación, se presentan los resultados clave organizados en tres aspectos

IV-D1. Rendimientos esperados diarios: Los rendimientos esperados diarios de las acciones destacan la diversidad dentro del índice XLK. Las acciones con los mayores rendimientos esperados son:

- **NVDA:** 0.006003
- **AVGO:** 0.004162
- **GDDY:** 0.003103

Por otro lado, algunas acciones presentan rendimientos más bajos, como:

- **ANSS:** 0.000179
- **CSGP:** 0.000013
- **CTSH:** 0.000360

Estos valores reflejan una heterogeneidad que permite aplicar estrategias mixtas de concentración y diversificación. Los rendimientos completos para todas las acciones consideradas se encuentran en el Anexo C.

IV-D2. Distribución de Pesos en el Portafolio: La asignación de pesos en el portafolio se enfoca estratégicamente en acciones con altos rendimientos esperados:

- **NVDA: 30 %.** Este peso predominante destaca el rendimiento y la relevancia estratégica de NVIDIA dentro del sector tecnológico.
- **AVGO: 19 %.** Broadcom también recibió una asignación significativa debido a su balance entre retorno y estabilidad.
- **Resto de las acciones: 51 %.** Todas las demás acciones recibieron un peso uniforme de 1 %, asegurando diversificación mínima y mitigando riesgos.

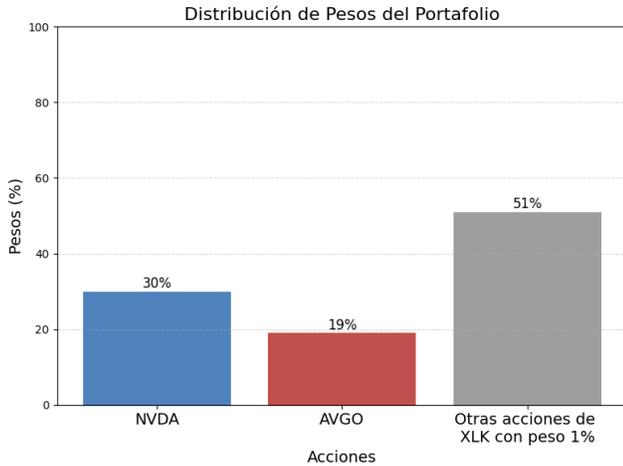


Figura 6. Portafolio óptimo según rendimientos y ratio de sharpe

Esta configuración combina una alta concentración en activos clave con diversificación mínima para equilibrar el riesgo general.

Cuadro IV
MÉTRICAS DEL PORTAFOLIO OPTIMIZADO

Métrica	Valor
Rendimiento esperado diario	0.0037
Volatilidad diaria	0.0074
Sharpe Ratio	0.4959

IV-D3. Desempeño del Portafolio: El desempeño del portafolio optimizado se resume en la Tabla IV, que presenta las métricas clave: rendimiento esperado diario, volatilidad diaria y Ratio de Sharpe. Estas métricas destacan el potencial del portafolio para generar retornos positivos (0.37% diarios en promedio) con una volatilidad moderada (0.74%). El Ratio de Sharpe de 0.4959 refleja un equilibrio positivo entre retorno y riesgo, indicando que el portafolio está bien optimizado para maximizar el rendimiento ajustado al riesgo.

La Figura 6 muestra la distribución de pesos en el portafolio optimizado, destacando las asignaciones predominantes en NVDA y AVGO, junto con la diversificación mínima en las demás acciones.

IV-D4. Interpretación General: El portafolio asigna el 49% de su peso a NVDA y AVGO, identificadas como las más prometedoras por su rendimiento esperado. Sin embargo, esta concentración incrementa la sensibilidad del portafolio a eventos específicos relacionados con estas empresas. Las demás acciones, con un peso uniforme del 1%, aseguran una diversificación básica, aunque su impacto en el rendimiento general es limitado. Finalmente, el Ratio de Sharpe negativo destaca un desequilibrio temporal entre retornos y riesgo, que podría ajustarse al incorporar factores adicionales en la optimización.

IV-E. Comparación con los Índices de Referencia

Para evaluar el desempeño del portafolio optimizado, se compararon métricas clave con los índices XLK y S&P 500. La Tabla V presenta un resumen de las métricas principales.

Cuadro V
MÉTRICAS COMPARATIVAS DEL PORTAFOLIO OPTIMIZADO Y LOS ÍNDICES DE REFERENCIA

Métrica	Portafolio	XLK	S&P 500
Rendimiento Diario	0.0037	0.0013	0.0014
Volatilidad	0.0074	0.0120	0.0070
Máximo Drawdown	-0.0908	-0.1213	-0.0557
Sharpe Ratio	0.4959	0.1097	0.1942

IV-E1. Rendimiento Promedio Diario: El portafolio optimizado superó ampliamente a los índices de referencia, con un rendimiento promedio diario de 0.37%, en comparación con 0.13% del XLK y 0.14% del S&P 500. Este resultado destaca la capacidad del modelo para capturar dinámicas del mercado y maximizar retornos.

IV-E2. Volatilidad Diaria: El portafolio presentó una volatilidad diaria de 0.74%, significativamente menor que la del XLK (1.20%) y comparable con la del S&P 500 (0.70%). Esto refleja un buen equilibrio entre riesgo y retorno, especialmente en comparación con el índice XLK, que es más volátil por naturaleza.

IV-E3. Máximo Drawdown (MDD): El MDD es una métrica que evalúa el mayor descenso acumulado desde un pico hasta un valle durante el período analizado. En este caso, el MDD del portafolio es del -9.08%, lo que indica que la mayor pérdida relativa del portafolio fue moderada en comparación con índices como el XLK (-12.13%). Este valor resalta la capacidad del portafolio para limitar pérdidas extremas en mercados volátiles, aunque no alcanza la estabilidad del S&P 500, cuyo MDD fue de -5.57%. La menor sensibilidad del portafolio optimizado frente a eventos negativos importantes demuestra una mayor resiliencia, atribuible a la estrategia de diversificación parcial y asignación estratégica de activos clave.

IV-E4. Sharpe Ratio: El Sharpe Ratio del portafolio optimizado fue 0.4959, significativamente mayor que el del XLK (0.1097) y el S&P 500 (0.1942), lo que indica un rendimiento ajustado al riesgo superior.

IV-E5. Visualización de Retornos Diarios: La Figura 7 y la Figura 8 presentan las comparaciones de los retornos diarios del portafolio frente al XLK y el S&P 500, respectivamente.

Estas visualizaciones resaltan que el portafolio optimizado tiene retornos más consistentes y menos fluctuaciones extremas que el XLK, mientras que supera en rendimiento al S&P 500, incluso con una volatilidad similar.

IV-E6. Análisis de Eventos Clave: Durante el período de evaluación, se identificaron eventos específicos que impactaron significativamente en el mercado. Por ejemplo, el anuncio de ganancias de NVIDIA en mayo de 2024 generó un aumento notable en su precio, lo que contribuyó al rendimiento del portafolio optimizado. Comparativamente, el

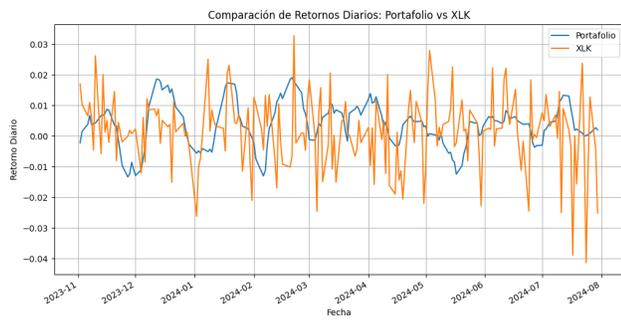


Figura 7. Comparación de Retornos Diarios: Portafolio vs. XLK

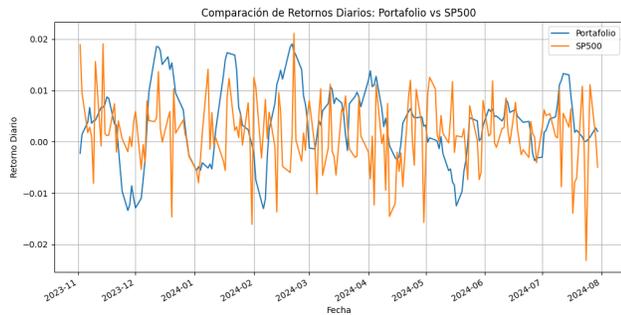


Figura 8. Comparación de Retornos Diarios: Portafolio vs. S&P 500

XLK presentó una mayor volatilidad en este período debido a su exposición a otras acciones que no se comportaron tan positivamente.

Otro evento importante fue la incertidumbre regulatoria en el sector tecnológico en marzo de 2024, donde el portafolio optimizado mostró una menor pérdida relativa frente al XLK, atribuido a su enfoque más selectivo en acciones con menor sensibilidad a estos riesgos.

IV-E7. Limitaciones y Oportunidades de Mejora: Aunque el portafolio optimizado logró superar a los benchmarks en términos de rendimiento ajustado al riesgo, la alta concentración en activos como NVDA y AVGO introduce un riesgo significativo relacionado con eventos específicos. Una mejora futura podría incluir restricciones adicionales en la asignación de pesos para aumentar la diversificación y mitigar este riesgo.

IV-E8. Interpretación General: Los resultados confirman que la integración de análisis de sentimientos avanzados y modelos de optimización permite construir portafolios más resilientes y con mejor desempeño ajustado al riesgo en comparación con estrategias basadas únicamente en datos históricos. Sin embargo, los hallazgos también resaltan la importancia de considerar mecanismos que equilibren concentración y diversificación para maximizar la estabilidad a largo plazo.

V. CONCLUSIONES

El desarrollo de este trabajo de tesis nos permitió demostrar que la integración de datos financieros históricos y análisis de sentimientos es una estrategia efectiva para mejorar la precisión en la predicción de precios de acciones. En

particular, el uso de modelos avanzados de Procesamiento del Lenguaje Natural, como Transformers especializados en lenguaje financiero (FinBERT), mostró resultados superiores frente a enfoques más tradicionales como VADER y modelos basados exclusivamente en datos históricos.

En cuanto al desempeño de los modelos, observamos que el análisis de sentimientos basado en FinBERT no solo mejoró las métricas de error cuadrático medio (MSE) y R^2 , sino que también ofreció predicciones más consistentes y robustas. En comparación, el modelo basado en VADER presentó mejoras parciales, pero su impacto fue menos uniforme, lo que sugiere que los métodos basados en léxicos no son suficientes para capturar la complejidad del lenguaje financiero. Estos resultados resaltan la importancia de utilizar herramientas específicas para el dominio financiero, especialmente en escenarios donde los matices lingüísticos son críticos.

El portafolio optimizado, construido a partir de las predicciones del modelo FinBERT, logró superar significativamente los índices de referencia XLK y S&P 500 en términos de rendimiento ajustado al riesgo. Este resultado evidencia el valor práctico de incorporar modelos de inteligencia artificial en la construcción de estrategias de inversión. Sin embargo, se identificaron desafíos relacionados con la concentración de activos clave, como NVDA y AVGO, lo que incrementa la sensibilidad del desempeño general a eventos específicos. Esto sugiere la necesidad de incorporar mecanismos de diversificación adicionales y restricciones en la asignación de pesos para lograr un balance más estable entre riesgo y retorno.

A pesar de los avances logrados, el trabajo también dejó en evidencia algunos desafíos. El Ratio de Sharpe negativo en ciertas configuraciones iniciales refleja la necesidad de refinar la metodología de optimización y de considerar restricciones adicionales que mitiguen riesgos específicos asociados a la concentración de activos.

Los resultados obtenidos no solo destacan el impacto positivo de estas herramientas, sino también su aplicabilidad en la construcción de estrategias de inversión robustas y adaptadas a entornos dinámicos. Sin embargo, el éxito de estas aplicaciones dependerá de la calidad y diversidad de los datos utilizados, la incorporación de estrategias de diversificación más sofisticadas y la capacidad de los modelos para adaptarse a las condiciones volátiles del mercado.

Finalmente, este trabajo ofrece un enfoque bien estructurado para explorar la aplicación de la inteligencia artificial en finanzas. Las técnicas presentadas pueden ampliarse mediante la integración de datos macroeconómicos, configuraciones más avanzadas de modelos, y análisis de portafolios en horizontes de inversión más largos, permitiendo desarrollar herramientas más precisas y eficaces para la gestión financiera. Además, aunque el estudio se centra en el sector tecnológico, la metodología y los modelos implementados son fácilmente adaptables a otros

tipos de activos financieros, sectores económicos o índices, demostrando su flexibilidad y aplicabilidad en diferentes contextos financieros.

VI. APÉNDICES

APÉNDICE A

GRÁFICOS DE ALGUNAS ACCIONES RELEVANTES CON CADA MODELO

A-A. AMAZON

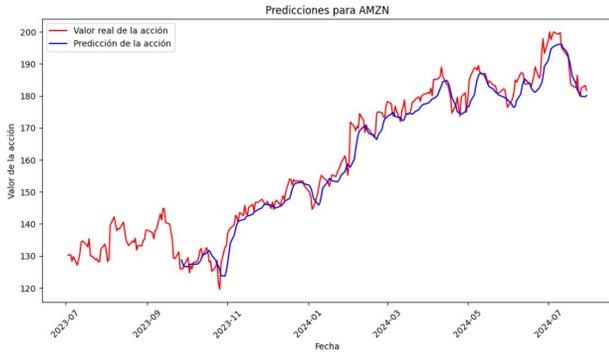


Figura 9. Predicción acciones de AMAZON con datos históricos

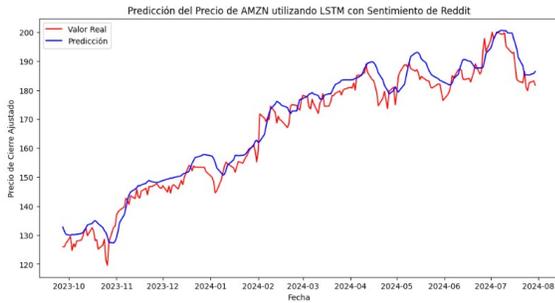


Figura 10. Predicción acciones de AMAZON incluyendo análisis de sentimientos

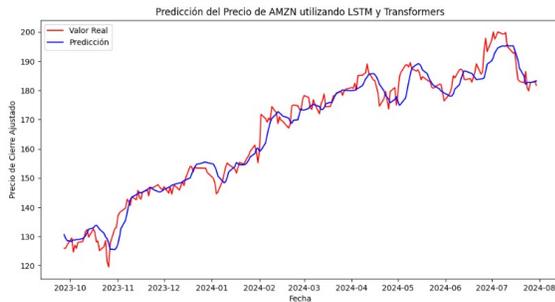


Figura 11. Predicción acciones de AMAZON incluyendo análisis de sentimientos con Transformers

A-B. GOOGLE

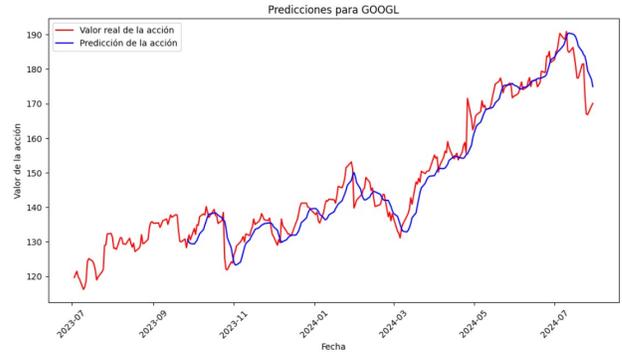


Figura 12. Predicción acciones de GOOGLE con datos históricos

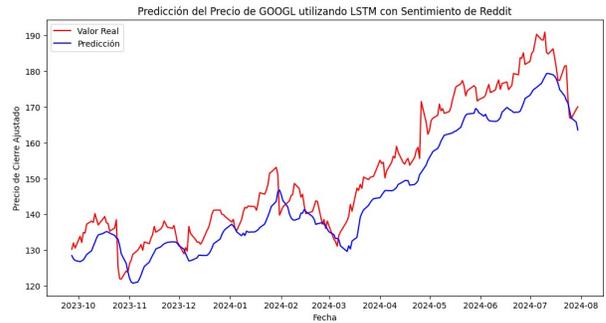


Figura 13. Predicción acciones de GOOGLE incluyendo análisis de sentimientos

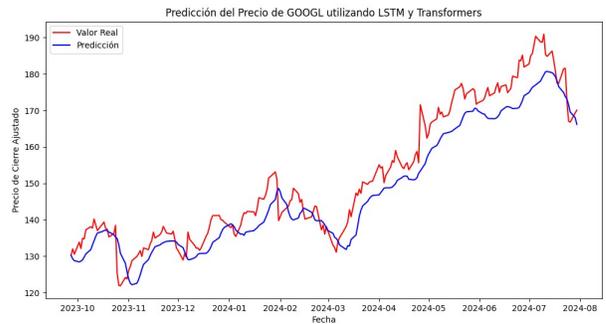


Figura 14. Predicción acciones de GOOGLE incluyendo análisis de sentimientos con Transformers

A-C. NVIDIA

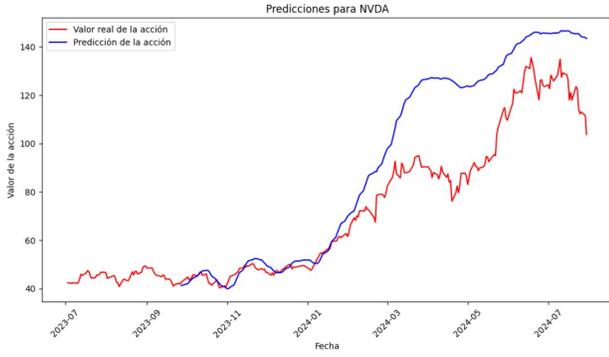


Figura 15. Predicción acciones de NVIDIA con datos históricos

A-D. APPLE



Figura 18. Predicción acciones de APPLE con datos históricos

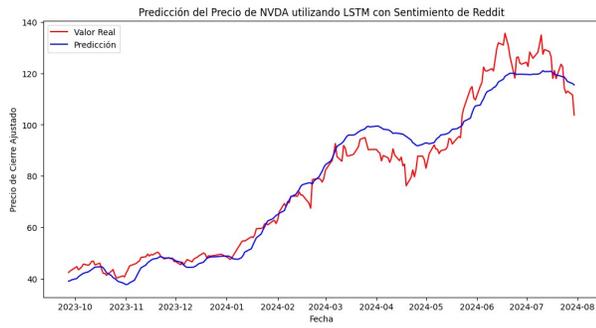


Figura 16. Predicción acciones de NVIDIA incluyendo análisis de sentimientos

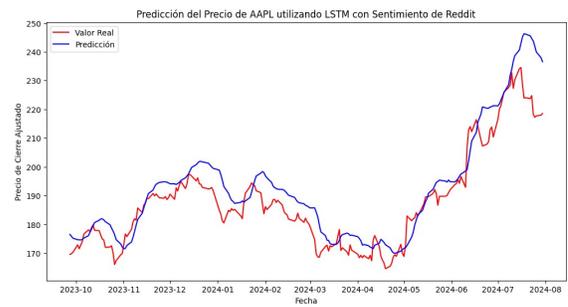


Figura 19. Predicción acciones de APPLE incluyendo análisis de sentimientos

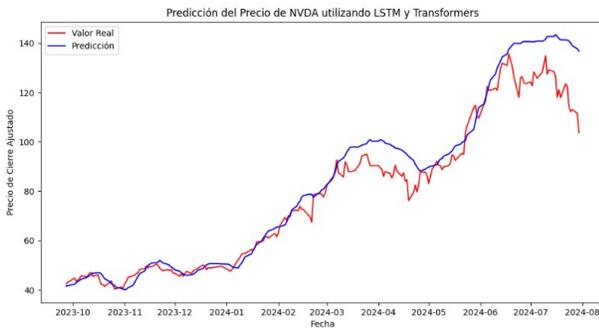


Figura 17. Predicción acciones de NVIDIA incluyendo análisis de sentimientos con Transformers

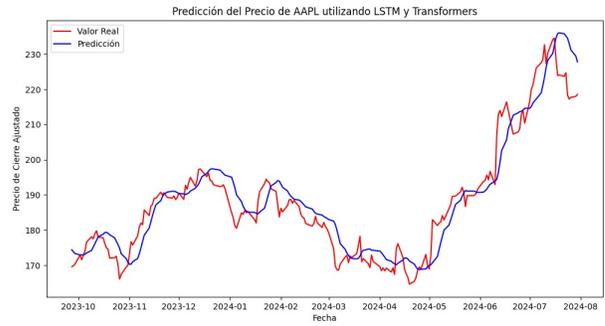


Figura 20. Predicción acciones de APPLE incluyendo análisis de sentimientos con Transformers

A-E. NETFLIX

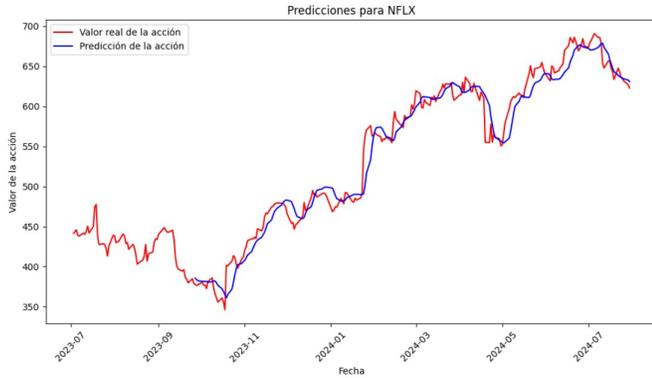


Figura 21. Predicción acciones de NETFLIX con datos históricos

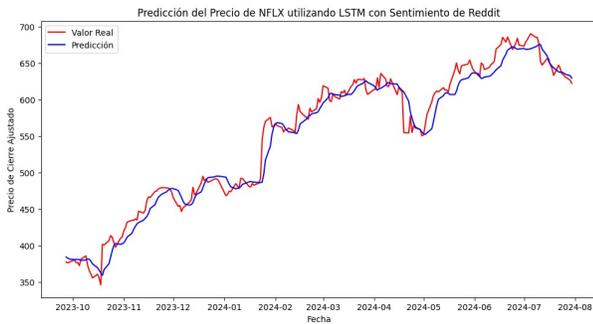


Figura 22. Predicción acciones de NETFLIX incluyendo análisis de sentimientos

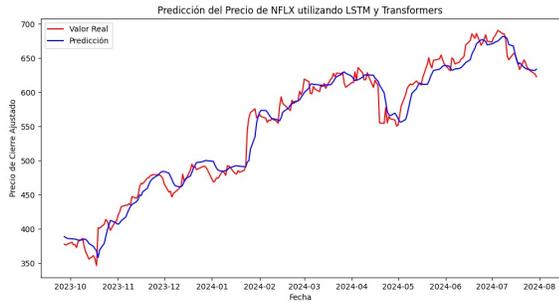


Figura 23. Predicción acciones de NETFLIX incluyendo análisis de sentimientos con Transformers

APÉNDICE B
RENDIMIENTOS DE CADA ACCIÓN DEL PORTAFOLIO

Cuadro VI
RENDIMIENTOS ESPERADOS DIARIOS DE LAS ACCIONES DEL ÍNDICE XLK

Acción	Rendimiento	Acción	Rendimiento
AAPL	0.001129	GLW	0.001587
MSFT	0.001492	HPQ	0.001634
NVDA	0.006003	IT	0.001251
AVGO	0.004162	LDOS	0.002455
CRM	0.001078	NTAP	0.002563
ORCL	0.001355	FFIV	0.000463
AMD	0.001688	JNPR	0.001347
ACN	0.000357	CSGP	0.000013
ADBE	0.000269	TRMB	0.000450
TXN	0.001089	GRMN	0.002426
IBM	0.001400	ZBRA	0.001563
QCOM	0.002430	BR	0.000575
INTU	0.000932	PTC	0.000989
AMAT	0.001880	CTSH	0.000360
MU	0.002319	HPE	0.000766
LRCX	0.001990	MSI	0.001583
NOW	0.001733	WDC	0.002107
PANW	0.002238	STX	0.002379
SNPS	0.001346	ANET	0.003892
CDNS	0.000624	KLAC	0.003661
ANET	0.003892	APH	0.001938
KLAC	0.003661	TEL	0.001058
APH	0.001938	MCHP	0.000587
TEL	0.001058	NXPI	0.001579
MCHP	0.000587	MPWR	0.002557
NXPI	0.001579	ADI	0.001230
MPWR	0.002557	KEYS	0.000250
ADI	0.001230	CDW	0.000514
KEYS	0.000250	ANSS	0.000179
CDW	0.000514	GDDY	0.003103
ANSS	0.000179	TYL	0.001851
GDDY	0.003103	SSNC	0.001291
TYL	0.001851	JKHY	0.000654
SSNC	0.001291		

APÉNDICE C
CONFIGURACIÓN EXPERIMENTAL

- Hiperparámetros fijos:
 - Número de épocas: 20
 - Tamaño del lote: 32
 - Función de pérdida: Error cuadrático medio (MSE)
 - Optimizador: Adam con tasa de aprendizaje de 0.001
- Hiperparámetros variables (optimizados):
 - Número de capas LSTM: 1
 - Tamaño de la capa oculta de la LSTM: 100
- División de datos:
 - Datos de entrenamiento: Junio 2019 - Junio 2023
 - Datos de validación: Julio 2023 - Julio 2023
 - Se mantuvo una división temporal para respetar la naturaleza secuencial de los datos.
- Framework y hardware utilizados
 - Framework de ML: PyTorch 1.8
 - Librerías de PLN: NLTK para VADER, Transformers para FinBERT

- Hardware: Los experimentos se llevaron a cabo en una laptop con las siguientes especificaciones:
 - Procesador: Intel(R) Core(TM) i5-8300H CPU @ 2.30GHz
 - RAM instalada: 8GB
 - Tarjeta gráfica: NVIDIA GeForce GTX 1050
 - Sistema operativo: Windows 10 Pro, Sistema operativo de 64 bits, procesador basado en x64
- Link al repositorio de GitHub: El código y los recursos necesarios para reproducir los experimentos están disponibles en el repositorio: <https://github.com/grecalde17gh/Tesis-IA—Portafolio-de-inversiones>

REFERENCIAS

- [1] J. Bollen, H. Mao, and X. Zeng, “Twitter mood predicts the stock market,” *Journal of Computational Science*, vol. 2, no. 1, pp. 1-8, 2011. [Online]. Available: <https://doi.org/10.1016/j.jocs.2010.12.007>
- [2] T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” *European Journal of Operational Research*, vol. 270, no. 2, pp. 654-669, 2018. [Online]. Available: <https://doi.org/10.1016/j.ejor.2017.11.054>
- [3] W. Gu et al., “Predicting Stock Prices with FinBERT-LSTM: Integrating News Sentiment Analysis,” arXiv preprint arXiv:2407.16150, 2024. [Online]. Available: <https://arxiv.org/abs/2407.16150>
- [4] C. J. Hutto and E. Gilbert, “VADER: A parsimonious rule-based model for sentiment analysis of social media text,” in *Proceedings of the Eighth International AAAI Conference on Weblogs and Social Media (ICWSM-14)*, Ann Arbor, MI, USA, 2014, pp. 216–225.
- [5] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of deep bidirectional transformers for language understanding,” in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, Minneapolis, MN, USA, 2019, pp. 4171–4186.
- [6] S. Halder, “FinBERT-LSTM: Deep Learning Based Stock Price Prediction Using News Sentiment Analysis,” arXiv preprint arXiv:2211.07392, 2022. [Online]. Available: <https://arxiv.org/abs/2211.07392>
- [7] Z. Jiang and J. Liang, “Applications of Deep Learning in Stock Market Prediction: Recent Progress,” *Expert Systems with Applications*, vol. 184, p. 115537, 2021. [Online]. Available: <https://doi.org/10.1016/j.eswa.2021.115537>
- [8] Z. Jin, Y. Yang, and Y. Liu, “Stock Closing Price Prediction Based on Sentiment Analysis and LSTM,” *Neural Computing and Applications*, vol. 32, pp. 9713-9729, 2020. [Online]. Available: <https://doi.org/10.1007/s00521-019-04504-2>
- [9] H. Kaeley, Y. Qiao, and N. Bagherzadeh, “Support for Stock Trend Prediction Using Transformers and Sentiment Analysis,” 2023. [Online]. Available: <https://arxiv.org/abs/2305.14368>
- [10] O. Ledoit and M. Wolf, “Improved Estimation of the Covariance Matrix of Stock Returns With an Application to Portfolio Selection,” *Journal of Empirical Finance*, vol. 10, no. 5, pp. 603-621, 2003. [Online]. Available: [https://doi.org/10.1016/S0927-5398\(03\)00007-0](https://doi.org/10.1016/S0927-5398(03)00007-0)
- [11] W. Lu, J. Li, Y. Li, A. Sun, y J. Wang, “A CNN-LSTM-Based Model to Forecast Stock Prices,” *Complexity*, vol. 2020, Art. no. 6622927, 2020. Available: <https://doi.org/10.1155/2020/6622927>
- [12] H. Markowitz, “Portfolio Selection,” *The Journal of Finance*, vol. 7, no. 1, pp. 77-91, 1952. [Online]. Available: <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- [13] S. Mehtab, J. Sen, and A. Dutta, “Stock Price Prediction Using Machine Learning and LSTM-Based Deep Learning Models,” in *Machine Learning and Metaheuristics Algorithms, and Applications*, Springer, 2021, pp. 88-106. [Online]. Available: https://doi.org/10.1007/978-981-16-0419-5_8
- [14] J. Qiu, B. Wang, and C. Zhou, “Forecasting Stock Prices with Long-Short Term Memory Neural Network Based on Attention Mechanism,” *PLOS ONE*, vol. 15, no. 1, 2020. [Online]. Available: <https://doi.org/10.1371/journal.pone.0227222>
- [15] W. F. Sharpe, “Mutual Fund Performance,” *The Journal of Business*, vol. 39, no. 1, pp. 119-138, 1966. [Online]. Available: <https://doi.org/10.1086/294846>
- [16] T. Swathi, N. Kasiviswanath, and A. Ananda Rao, “An Optimal Deep Learning-Based LSTM for Stock Price Prediction Using Twitter Sentiment Analysis,” *Applied Intelligence*, vol. 52, pp. 13675-13688, 2022. [Online]. Available: <https://doi.org/10.1007/s10489-022-03175-2>
- [17] A. Vaswani et al., “Attention Is All You Need,” in *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017, pp. 6000-6010. [Online]. Available: <https://doi.org/10.5555/3295222.3295349>
- [18] Y. Xu and Y. Cohen, “Stock Movement Prediction from Tweets and Historical Prices,” in *Proceedings of the 2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, Barcelona, Spain, 2018, pp. 579-586. [Online]. Available: <https://doi.org/10.18653/v1/P18-1183>
- [19] Y. Yang, M. C. S. Uy, and A. Huang, “FinBERT: A Pretrained Language Model for Financial Communications,” 2020. [Online]. Available: <https://arxiv.org/abs/2006.08097>
- [20] Z. Zhang, S. Zohren, and S. Roberts, “Deep Learning for Portfolio Optimization,” arXiv preprint arXiv:2005.13665, 2020. [Online]. Available: <https://arxiv.org/abs/2005.13665>