

Analítica de datos y predicción del mercado accionario de los Estados Unidos

Lain Antonio Castilla Tatis

Asesor

Sebastian Vélez Jaramillo

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Sociales Artes y Humanidades ECSAH

Especialización en Ciencias de Datos y Analítica

2025

Resumen

Este trabajo explora el mercado de valores en Estados Unidos, analizando su estructura, funcionamiento, actores principales y su impacto en la economía global. Se abordan aspectos históricos, regulatorios y tecnológicos que han influido en su evolución, así como el papel de los datos y la analítica en la toma de decisiones financieras. Esta información nos permitirá construir un historial suficientemente poderoso para aplicar varios modelos e identificar los óptimos que nos permitan predecir el comportamiento futuro.

El documento explica el funcionamiento del mercado de valores de EE.UU., destacando la regulación por parte de la SEC y el uso creciente de algoritmos y modelos predictivos. Se presenta un análisis visual con gráficos sobre la volatilidad y rendimiento del S&P 500, Bolsa de Nueva York (NYSE) y el NASDAQ entre 2014 y 2023, así como una tabla comparativa de rendimiento sectorial, donde tecnología lidera con un 18% promedio, seguido por salud y consumo.

También se incluye un análisis de correlación entre los sectores de tecnología, salud, financiero, consumo y energía, útil para estrategias de diversificación. Posteriormente, se aborda el mercado accionario global, su historia desde la Bolsa de Ámsterdam, y su evolución en regiones como Asia, Europa y América Latina. Se destaca la interconexión con el mercado estadounidense y el papel de indicadores bursátiles globales como el S&P 500, Dow Jones y MSCI World Index.

Se presentan casos de estudio relevantes: el impacto del COVID-19, la burbuja tecnológica de los 2000 y la recuperación post-crisis de 2008. El trabajo analiza el impacto de la tecnología en el mercado accionario, la importancia de la regulación y transparencia, los riesgos sistémicos, y el auge de las finanzas verdes y criterios ESG.

Se enfatiza la necesidad de educación financiera y analítica para interpretar datos del mercado y desarrollar modelos predictivos. Las perspectivas futuras apuntan a una mayor integración de tecnologías como blockchain, big data y machine learning.

Finalmente, se explica Prophet, como herramienta seleccionada para el desarrollo del modelo predictivo y luego el código desarrollado con la respectiva explicación de cada fase, así como también la interpretación de las evaluaciones y los resultados obtenidos.

Palabras claves: Mercado de valores de USA, bolsa de valores USA, acciones de USA, criptomonedas, ETF's USA, portafolio inversiones USA.

Abstract

This paper explores the US stock market, analyzing its structure, operation, key players, and its impact on the global economy. It addresses historical, regulatory, and technological aspects that have influenced its evolution, as well as the role of data and analytics in financial decision-making. This information will allow us to build a robust historical record to apply various models and identify the optimal ones for predicting future behavior.

The document explains the workings of the US stock market, highlighting SEC regulation and the increasing use of algorithms and predictive models. It presents a visual analysis with graphs showing the volatility and performance of the S&P 500, Nasdaq, and the US Stock Exchange between 2014 and 2023, as well as a comparative table of sector performance, where technology leads with an average return of 18%, followed by healthcare and consumer goods.

It also includes a correlation analysis between the technology, healthcare, financial, consumer goods, and energy sectors, useful for diversification strategies. Subsequently, the global stock market is addressed, tracing its history from the Amsterdam Stock Exchange and its evolution in regions such as Asia, Europe, and Latin America. The interconnection with the US market and the role of global stock market indices such as the S&P 500, Dow Jones, and MSCI World Index are highlighted.

Relevant case studies are presented: the impact of COVID-19, the tech bubble of the 2000s, and the post-2008 financial crisis recovery. The paper analyzes the impact of technology on the stock market, the importance of regulation and transparency, systemic risks, and the rise of green finance and ESG criteria.

The need for financial and analytical literacy to interpret market data and develop predictive models is emphasized. Future prospects point to greater integration of technologies such as blockchain, big data, and machine learning.

Finally, Prophet is explained as the tool selected for developing the predictive model, followed by the developed code with an explanation of each phase, as well as the interpretation of the evaluations and the results obtained.

Keywords: Stock market US, stock exchange US, stocks US, cryptocurrencies, ETF's US, investment portfolio US.

Tabla de Contenido

Introducción	11
Justificación	13
Objetivos.....	14
Objetivo General.....	14
Objetivos Específicos	14
Metodología	15
Recolección de Datos	15
Preprocesamiento de Datos	18
Análisis Exploratorio de Datos (EDA).....	19
Modelado Predictivo.....	19
Evaluación y Validación.....	19
Herramientas Tecnológicas	19
Mercado de Valores de Estados Unidos	21
Análisis Visual y Recomendaciones.....	22
Análisis de Correlación entre Sectores	24
Mercado Accionario Global.....	25
Historia del Mercado Accionario Global.....	25
Análisis Regional - Asia	25
Análisis Regional - Europa.....	25
Análisis Regional - América Latina	25
Interconexión con el Mercado de EE.UU.....	26
Indicadores Bursátiles Globales	26

Casos de Estudio.....	26
Impacto de la Tecnología	26
Regulación y Transparencia	26
Riesgos Sistémicos	27
Sostenibilidad y Finanzas Verdes.....	27
Educación Financiera y Analítica.....	28
Perspectivas Futuras	28
Ciclos del Mercado de Valores.....	29
Concepto de Ciclo Bursátil.....	29
Relación con los Ciclos Económicos.....	29
Factores que Influyen en los Ciclos.....	30
Fases del Ciclo Bursátil	30
Duración y Tipología de los Ciclos	32
Importancia para la Inversión	32
Teorías Clásicas sobre Ciclos Bursátiles	32
Modelo Prophet.....	34
Conclusiones	40
Recomendaciones	42
Referencias Bibliográficas	43

Lista de Figuras

Figura 1 <i>Diagrama de Flujo del Código Desarrollado</i>	20
Figura 2 <i>Volatilidad Histórica Mensual del S&P 500 (2014–2023)</i>	22
Figura 3 <i>Rendimiento Anual del S&P 500 (2014–2023)</i>	22
Figura 4 <i>Rendimiento Promedio por Sector</i>	23
Figura 5 <i>Correlación de Sectores</i>	24
Figura 6 <i>Ciclos Económicos</i>	29
Figura 7 <i>Ciclo Bursátil 2008-2009</i>	31
Figura 8 <i>Duración vs Tipología de Ciclos</i>	32
Figura 9 <i>Prophet vs ETS y ARIMA en los Datos de Producción de Cemento</i>	35
Figura 10 <i>Componentes de un Modelo Prophet Ajustado</i>	37
Figura 11 <i>Pronostico entre Dos Días</i>	38

Lista de Tablas

Tabla 1 <i>Tabla Comparativa Sectorial</i>	23
---	----

Lista de Apéndices

Apéndice A <i>Explicación del Código y Análisis de Resultados</i>	45
--	----

Introducción

En el contexto actual de constante transformación social, tecnológica y económica, resulta fundamental analizar los distintos factores que inciden en el desarrollo de nuestras comunidades y nuestras finanzas. La comprensión de estos elementos permite no solo interpretar los fenómenos contemporáneos, sino también proponer soluciones efectivas que respondan a las necesidades emergentes. Este documento tiene como propósito presentar un modelo predictivo de las principales acciones del mercado de valores de Estado Unidos, descritos en el capítulo Metodología.

El mercado de valores en Estados Unidos constituye uno de los pilares fundamentales de la economía global. Su estructura dinámica, compuesta por bolsas como la Bolsa de Nueva York (NYSE) y el NASDAQ, permite la negociación de una amplia gama de instrumentos financieros, incluyendo acciones, bonos y derivados. Este sistema financiero no solo refleja la salud económica del país, sino que también influye en los mercados internacionales a través de sus interacciones con inversionistas, empresas y organismos reguladores.

Desde una perspectiva académica, el estudio del mercado de valores estadounidense ofrece una oportunidad para comprender los mecanismos de asignación de capital, la formación de precios y la gestión del riesgo. En el contexto de las ciencias de datos y la analítica, este análisis se enriquece mediante el uso de modelos predictivos, algoritmos de machine learning y visualización de datos, que permiten identificar patrones, evaluar tendencias y tomar decisiones informadas basadas en evidencia cuantitativa.

En el contexto del análisis financiero moderno, la aplicación de técnicas de ciencia de datos y analítica avanzada ha permitido desarrollar modelos predictivos capaces de anticipar comportamientos complejos en los mercados bursátiles. Este enfoque busca identificar patrones

temporales, tendencias estructurales y escenarios prospectivos que contribuyan a la toma de decisiones estratégicas en el ámbito financiero, fortaleciendo así la capacidad analítica frente a la volatilidad y dinamismo del mercado accionario de Estados Unidos.

En el anexo 3 de este documento, se presenta una explicación detallada del código implementado para la predicción de precios de acciones utilizando el modelo Prophet. Incluye justificación académica, interpretación de métricas, objetivos del proyecto, conclusiones y recomendaciones para mejorar el modelo.

El código se estructura en varias etapas: importación de librerías, carga y preparación de datos, entrenamiento del modelo Prophet, generación de predicciones futuras, evaluación mediante métricas (MAE, RMSE, MAPE, R^2), validación cruzada, visualización de resultados y exportación a Excel. Cada bloque cumple una función específica para garantizar la precisión y utilidad del modelo predictivo.

Las métricas utilizadas son MAE, RMSE, MAPE y R^2 . A continuación se presentan ejemplos visuales y su interpretación en el contexto del análisis predictivo, como por ejemplo el gráfico: Comparación MAE vs RMSE por Acción

Justificación

La elección de este tema responde a la necesidad de comprender con mayor profundidad una problemática que, en la actualidad, tiene un impacto significativo en distintos ámbitos del sector financiero. El Mercado de valores de E.E. U.U, no solo representa un desafío a nivel financiero, sino que también tiene consecuencias prácticas que afectan directamente a comunidades, instituciones y políticas públicas. Por ello, su estudio resulta relevante para contribuir con propuestas que favorezcan su abordaje efectivo.

La predicción del comportamiento del mercado de valores ha sido históricamente un desafío complejo debido a su naturaleza dinámica, no lineal y altamente influenciada por factores económicos, políticos y sociales. En este contexto, la ciencia de datos y la analítica avanzada ofrecen un marco metodológico robusto para abordar este tipo de problemas, permitiendo el procesamiento de grandes volúmenes de datos, la identificación de patrones ocultos y la generación de modelos predictivos con capacidad de generalización.

El uso de modelos de aprendizaje automático y técnicas estadísticas permite reducir la incertidumbre en la toma de decisiones financieras, al proporcionar estimaciones basadas en evidencia empírica. Además, la disponibilidad de datos históricos del mercado accionario estadounidense durante un periodo de cinco años constituye una base sólida para el entrenamiento y validación de modelos que puedan anticipar comportamientos futuros.

La predicción de precios en mercados financieros es esencial para la toma de decisiones estratégicas. Prophet ofrece una solución robusta y fácil de implementar, capaz de manejar estacionalidades y tendencias no lineales.

Objetivos

Objetivo General

Diseñar e implementar un modelo predictivo del comportamiento de las principales acciones en el mercado de valores en Estados Unidos, tales como: Amazon, Tesla, Apple, Meta, Google, Microsoft, Netflix y Nvidia, mediante la aplicación de técnicas avanzadas de ciencia de datos y analítica, utilizando un conjunto de datos históricos de cinco años, con el propósito de identificar patrones temporales, tendencias estructurales y escenarios prospectivos que contribuyan a la toma de decisiones estratégicas en el ámbito financiero.

Objetivos Específicos

Analizar las principales variables que influyen en el comportamiento del mercado accionario estadounidense, utilizando técnicas estadísticas y de exploración de datos.

Limpiar, transformar y preparar el dataset histórico de cinco años para asegurar su calidad y adecuación al análisis predictivo.

Aplicar técnicas de visualización de datos para identificar patrones, tendencias y anomalías relevantes en el comportamiento del mercado.

Evaluar teóricamente los diferentes modelos para series temporales y seleccionar uno que ofrezca resultados óptimos en la predicción del mercado.

Validar el o los modelos predictivos mediante métricas de desempeño como MAE, RMSE, R^2 y análisis de error, asegurando su capacidad de generalización en datos no vistos.

Metodología

El presente proyecto aplicado tiene un enfoque cuantitativo y exploratorio, orientado al análisis y predicción del comportamiento del mercado accionario de los Estados Unidos mediante técnicas de analítica de datos y aprendizaje automático. La metodología se estructura en las siguientes etapas:

Recolección de Datos

La fuente de datos inicial fue tomada de kaggle, la cual, es una plataforma web que reúne la comunidad Data Science más grande del mundo, con más de 536 mil miembros activos en 194 países, recibe más de 150 mil publicaciones por mes, que brindan todas las herramientas y recursos más importantes para progresar al máximo en data science. Kaggle, al igual que DataScientest, tiene una interfaz Jupyter Notebooks personalizable y sin configuración. Permite acceder de manera gratuita a GPUs y a una gran cantidad de datos y códigos publicados por la comunidad. En Kaggle, puedes encontrar algunos códigos realizados por estudiantes o personas relacionadas con la ciencia de datos y dataset que necesitas para realizar tus proyectos data science. Hay más de 50 mil conjuntos de datos públicos y 400 mil notas públicas disponibles para todo el mundo.

Algunas de las empresas de data science mas grandes del mundo, como Walmart o Facebook, confían en Kaggle, esta plataforma permite a los especialistas de datos y a otros desarrolladores participar en concursos y data challenges de Machine Learning, escribir y compartir códigos y guardar conjunto de datos.

Los temas que se tratan en Kaggle son muy variados, desde los intentos de predecir la aparición del cáncer con la examinación de fichas de pacientes, hasta el análisis de los sentimientos generados por las críticas de una película. La plataforma propone proyectos

interesantes y estimulantes donde los contribuidores pueden aprender y entrenarse, y ofrece también la posibilidad de discutir con los líderes del sector y con expertos.

En resumen, Kaggle se puede utilizar para:

- Buscar o publicar bases de datos.
- Explorar y construir modelos en un espacio web adaptado.
- Trabajar con otros profesionales y aficionados.
- Realizar competencias y challenges sobre temas innovadores.
- La dataset utilizada fue descargada del siguiente link, pero también puede ser

consultada en el anexo1 de este documento:

<https://www.kaggle.com/datasets/saketk511/2019-2024-us-stock-market-data>.

El enlace corresponde a un conjunto de datos (dataset) disponible en *Kaggle* que contiene datos diarios del mercado de valores de Estados Unidos (US Stock Market) para el periodo 2019–2024. Los datos incluyen precios de cierre y volumen de negociación de múltiples acciones o índices bursátiles. Abarca diversos sectores, incluyendo materias primas energéticas como el gas natural y el petróleo crudo, metales como el cobre, el platino, la plata y el oro, criptomonedas como Bitcoin y Ethereum, e índices bursátiles y empresas clave como el S&P 500, el Nasdaq 100, Apple, Tesla, Microsoft, Google, Nvidia, Berkshire Hathaway, Netflix, Amazon y Meta Platforms.

La estructura encontrada en el dataset es el siguiente:

- **Date:** Fecha de los datos registrados, con el formato DD-MM-AAAA.
- **Natural_Gas_Price:** Precio del gas natural en USD por millón de unidades térmicas británicas (MMBtu).
- **Natural_Gas_Vol.:** Volumen de negociación del gas natural.

- Crude_oil_Price: Precio del petróleo crudo en USD por barril.
- Crude_oil_Vol.: Volumen de negociación del petróleo crudo.
- Copper_Price: Precio del cobre en USD por libra.
- Copper_Vol.: Volumen de negociación del cobre.
- Bitcoin_Price: Precio del Bitcoin en USD.
- Bitcoin_Vol.: Volumen de negociación del Bitcoin.
- Platinum_Price: Precio del platino en USD por onza troy.
- Platinum_Vol.: Volumen de negociación del platino.
- Ethereum_Price: Precio de Ethereum en USD.
- Ethereum_Vol.: Volumen de negociación de Ethereum
- S&P_500_Price: Índice de precios del S&P 500.
- Nasdaq_100_Price: Índice de precios del Nasdaq 100.
- Nasdaq_100_Vol.: Volumen de negociación del índice Nasdaq 100.
- Apple_Price: Precio de las acciones de Apple Inc. en USD.
- Apple_Vol.: Volumen de negociación de las acciones de Apple Inc.
- Tesla_Price: Precio de las acciones de Tesla Inc. en USD.
- Tesla_Vol.: Volumen de negociación de las acciones de Tesla Inc.
- Microsoft_Price: Precio de las acciones de Microsoft Corporation en USD.
- Microsoft_Vol.: Volumen de negociación de las acciones de Microsoft Corporation.
- Silver_Price: Precio de la plata en USD por onza troy.
- Silver_Vol.: Volumen de negociación de la plata
- Google_Price: Precio de las acciones de Alphabet Inc. (Google) en USD.

- Google_Vol.: Volumen de negociación de las acciones de Alphabet Inc.
- Nvidia_Price: Precio de las acciones de Nvidia Corporation en USD.
- Nvidia_Vol.: Volumen de negociación de las acciones de Nvidia Corporation
- Berkshire_Price: Precio de las acciones de Berkshire Hathaway Inc. en USD.
- Berkshire_Vol.: Volumen de negociación de las acciones de Berkshire Hathaway Inc.
- Netflix_Price: Precio de las acciones de Netflix Inc. en USD.
- Netflix_Vol.: Volumen de negociación de las acciones de Netflix Inc.
- Amazon_Price: Precio de las acciones de Amazon.com Inc. en USD.
- Amazon_Vol.: Volumen de negociación de las acciones de Amazon.com Inc.
- Meta_Price: Precio de las acciones de Meta Platforms, Inc. (anteriormente Facebook) en USD.
- Meta_Vol.: Volumen de negociación de las acciones de Meta Platforms, Inc.
- Gold_Price: Precio del oro en USD por onza troy.
- Gold_Vol.: Volumen de negociación del oro

Preprocesamiento de Datos

Los datos fueron limpiados y transformados para su análisis, haciendo uso de herramientas como el Power BI y Microsoft Excel.

Este proceso incluyó:

- Análisis de valores faltantes, los cuales fueron reemplazados por valores promedios del anterior y posterior
- Normalización o estandarización de variables.
- Detección y tratamiento de outliers.

- Como resultado de esta actividad se generó una segunda data, la cual, está indicada en el anexo2 de este documento.

Análisis Exploratorio de Datos (EDA)

Se aplicarán técnicas de visualización y estadística descriptiva para identificar patrones, correlaciones y comportamientos relevantes en los datos. Este análisis permitirá seleccionar las variables más significativas para los modelos predictivos.

Modelado Predictivo

Se analizaron varios modelos de series temporales como como ARIMA, Prophet y LSTM, sin embargo, se utilizó el Prophet, basados en los resultados de las métricas de desempeño como precisión, error cuadrático medio (RMSE), MAE y R^2 , y además, utilizando técnicas de validación cruzada.

Evaluación y Validación

Se evaluó la capacidad predictiva de los modelos sobre un conjunto de datos de prueba. Además, se realizó una validación temporal para verificar la robustez del modelo en distintos períodos del mercado.

Herramientas Tecnológicas

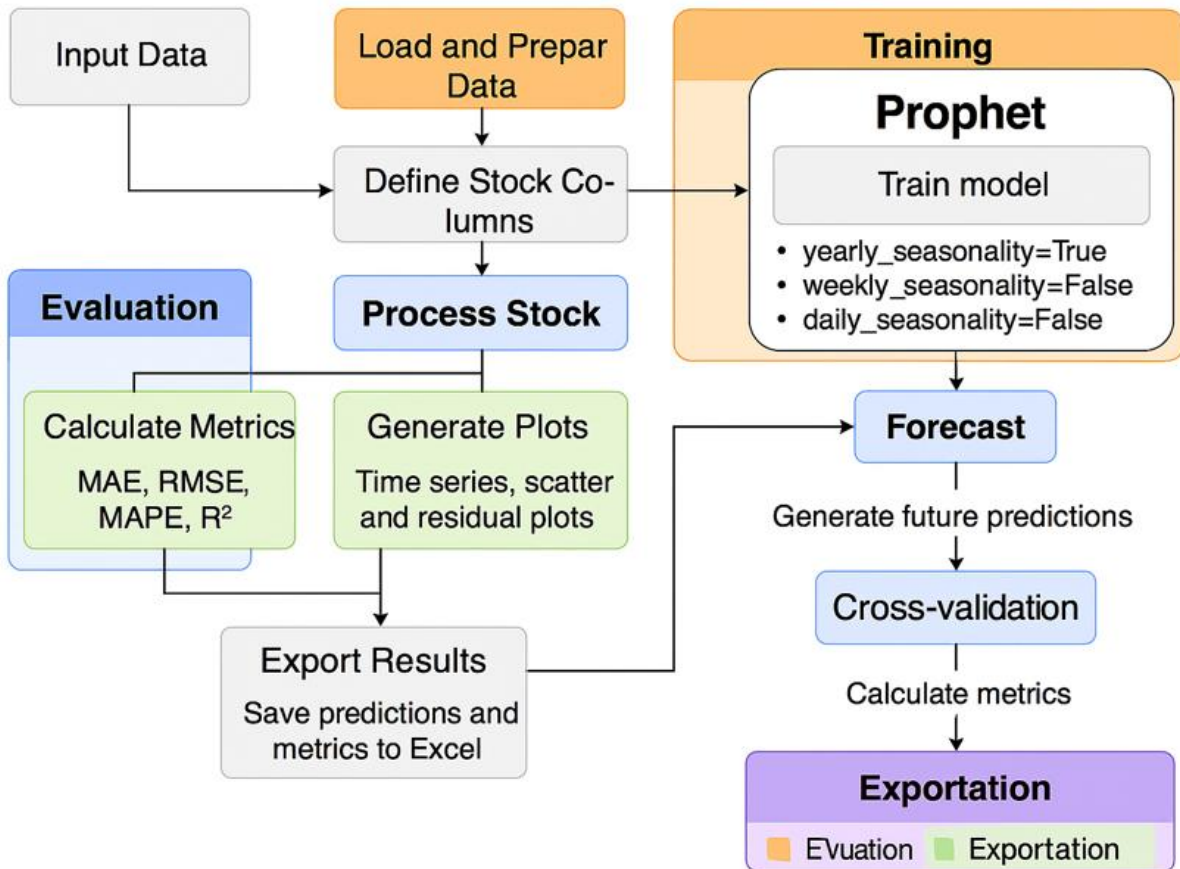
El desarrollo se realizó utilizando lenguajes y entornos como Python (con librerías como Pandas, Scikit-learn, TensorFlow, Keras, Matplotlib y Statsmodels), Jupyter Notebook y plataformas de visualización como Power BI.

El desarrollo del código se encuentra enlazado en el anexo3 de este documento.

La explicación detallada del código, así como también el respectivo análisis de resultados se encuentra enlazado en el anexo4 de este documento.

Figura 1

Diagrama de Flujo del Código Desarrollado




Mercado de Valores de Estados Unidos

El mercado de valores en Estados Unidos es uno de los más grandes y complejos del mundo. Está compuesto por diversas bolsas de valores, como la Bolsa de Nueva York (NYSE) y el NASDAQ, donde se negocian acciones, bonos y otros instrumentos financieros. La regulación está a cargo de entidades como la Comisión de Bolsa y Valores (SEC), que supervisa la transparencia y legalidad de las operaciones. Con el avance de la tecnología, el uso de algoritmos y modelos de analítica ha transformado la forma en que los inversionistas toman decisiones, permitiendo análisis predictivos y gestión de riesgos más eficiente. Además, el acceso a grandes volúmenes de datos ha facilitado el desarrollo de estrategias de inversión basadas en datos.

Análisis Visual y Recomendaciones

Figura 2


Volatilidad Histórica Mensual del S&P 500 (2014–2023)



Nota. Este gráfico muestra la variación mensual de la volatilidad del índice S&P 500 durante los últimos 10 años. La volatilidad es un indicador clave del riesgo en los mercados financieros.

Figura 3

Rendimiento Anual del S&P 500 (2014–2023)



Nota. El gráfico presenta el rendimiento anual simulado del índice S&P 500. Se observan fluctuaciones que reflejan la naturaleza cíclica del mercado bursátil.

Tabla 1

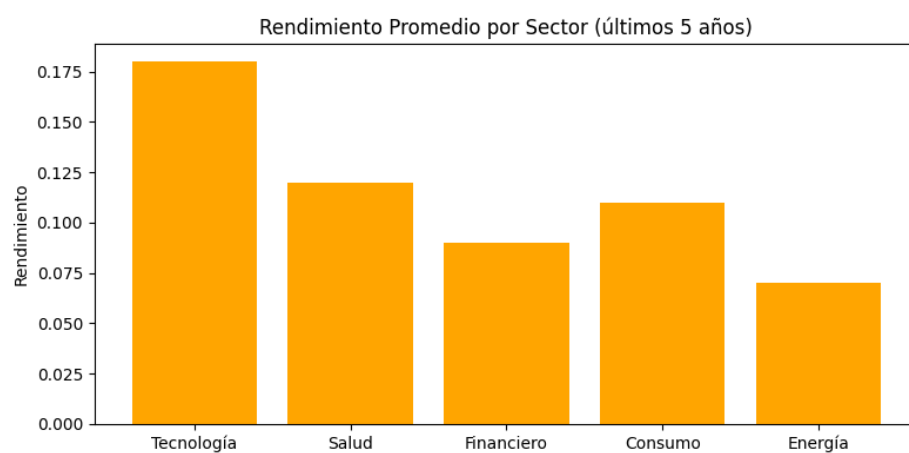
Tabla Comparativa Sectorial

Sector	Rendimiento Promedio (últimos 5 años)
Tecnología	18.00%
Salud	12.00%
Financiero	9.00%
Consumo	11.00%
Energía	7.00%

Nota. La tabla muestra el rendimiento promedio por sector en los últimos cinco años. Tecnología lidera con un rendimiento superior, seguido por salud y consumo.

Figura 4

Rendimiento Promedio por Sector



Nota. Este gráfico visualiza el rendimiento promedio por sector. Se destaca el liderazgo del sector tecnológico y la estabilidad de salud y consumo.

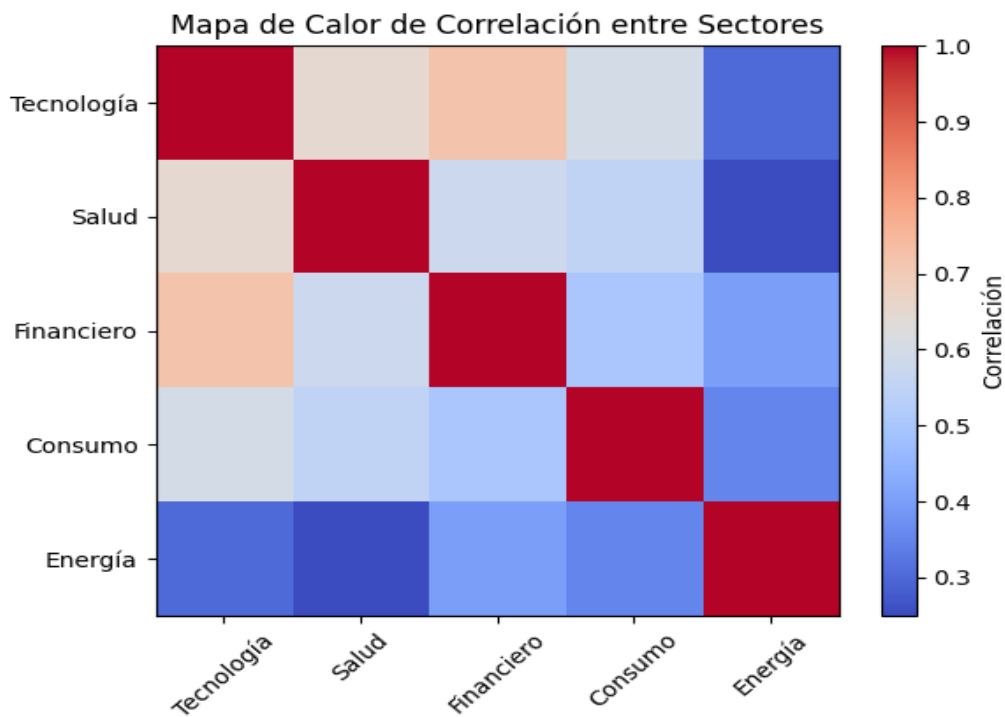
Análisis de Correlación entre Sectores

La siguiente tabla muestra la correlación entre los sectores del mercado de valores.

Valores cercanos a 1 indican alta correlación, mientras que valores bajos indican independencia.

Figura 5

Correlación de Sectores



Mercado Accionario Global

El mercado accionario global representa una red interconectada de bolsas de valores que facilitan la compra y venta de acciones en todo el mundo. Su estudio es esencial para los estudiantes de ciencias de datos y analítica, ya que proporciona una base para comprender los flujos financieros internacionales, la volatilidad del mercado y el comportamiento de los inversores.

Historia del Mercado Accionario Global

El mercado accionario tiene sus raíces en el siglo XVII con la creación de la Bolsa de Ámsterdam. Desde entonces, ha evolucionado hasta convertirse en un sistema complejo que incluye bolsas en todos los continentes. La historia de las crisis financieras, como la Gran Depresión de 1929 y la crisis de 2008, ha moldeado la regulación y la percepción del riesgo.

Análisis Regional - Asia

Asia alberga algunas de las bolsas más importantes del mundo, como la Bolsa de Tokio, la Bolsa de Shanghái y la Bolsa de Hong Kong. Estas bolsas reflejan el crecimiento económico de la región y su influencia en los mercados globales.

Análisis Regional - Europa

Europa cuenta con bolsas históricas como la Bolsa de Londres, Euronext y la Bolsa de Frankfurt. La integración económica europea y el euro han influido en la dinámica bursátil regional.

Análisis Regional - América Latina

Las bolsas de valores en América Latina, como la Bolsa Mexicana de Valores y B3 en Brasil, han mostrado crecimiento en los últimos años. Sin embargo, enfrentan desafíos como la volatilidad política y económica.

Interconexión con el Mercado de EE.UU.

El mercado accionario de Estados Unidos, liderado por la Bolsa de Nueva York (NYSE) y Nasdaq, actúa como referencia global. Las decisiones de política monetaria de la Reserva Federal y los resultados corporativos estadounidenses impactan directamente en los mercados internacionales.

Indicadores Bursátiles Globales

Los principales indicadores bursátiles incluyen el S&P 500, Dow Jones, FTSE 100, Nikkei 225, y el MSCI World Index. Estos índices permiten evaluar el rendimiento de los mercados y son fundamentales en el análisis cuantitativo.

Casos de Estudio

Caso 1: El impacto del COVID-19 en los mercados globales.

Caso 2: La burbuja tecnológica de principios de los 2000.

Caso 3: La recuperación bursátil post-crisis financiera de 2008.

Impacto de la Tecnología

La tecnología ha transformado el mercado accionario mediante el uso de algoritmos de trading, inteligencia artificial y plataformas digitales. Los estudiantes de analítica deben comprender cómo los datos en tiempo real y el análisis predictivo influyen en las decisiones de inversión.

Regulación y Transparencia

Las entidades reguladoras como la SEC en EE.UU. y la ESMA en Europa garantizan la transparencia y la protección de los inversores. La regulación es clave para mantener la confianza en los mercados.

La SEC (Securities and Exchange Commission) en Estados Unidos es la Comisión de Bolsa y Valores, y su función principal es regular y supervisar los mercados de valores para proteger a los inversionistas y garantizar la transparencia y el buen funcionamiento del sistema financiero.

Sus funciones clave incluyen:

- Proteger a los inversionistas: Asegura que reciban información veraz y completa sobre las inversiones.
- Mantener mercados justos y eficientes: Supervisa que las transacciones se realicen de manera ordenada y sin prácticas fraudulentas.
- Facilitar la formación de capital: Permite que empresas obtengan financiamiento mediante la emisión de acciones y bonos, bajo reglas claras.
- Aplicar la ley contra fraudes y abusos: Investiga y sanciona delitos como insider trading, manipulación de mercado y presentación de información falsa.
- Regular intermediarios financieros: Supervisa corredores de bolsa, asesores de inversión y bolsas de valores.

Riesgos Sistémicos

Los riesgos sistémicos incluyen la interdependencia entre instituciones financieras, la falta de liquidez y los eventos geopolíticos. El análisis de estos riesgos requiere modelos estadísticos avanzados y simulaciones.

Sostenibilidad y Finanzas Verdes

El mercado accionario global está adoptando criterios ESG (ambientales, sociales y de gobernanza). Las inversiones sostenibles están ganando relevancia, y los índices como el Dow Jones Sustainability Index reflejan esta tendencia.

Educación Financiera y Analítica

La formación en ciencias de datos permite a los analistas bursátiles desarrollar modelos predictivos, realizar análisis de series temporales y evaluar riesgos. La educación financiera es esencial para interpretar correctamente los datos del mercado.

Perspectivas Futuras

Se espera que el mercado accionario global continúe evolucionando con la integración de tecnologías emergentes como blockchain, big data y machine learning. La colaboración internacional será clave para enfrentar desafíos globales.

Ciclos del Mercado de Valores

Los mercados financieros presentan movimientos recurrentes que alternan entre fases de crecimiento y contracción. Este capítulo analiza los ciclos bursátiles, su relación con la economía, factores determinantes, fases y teorías clásicas. Comprender estos ciclos es esencial para interpretar la dinámica del mercado y diseñar estrategias efectivas. A lo largo de este documento se abordarán conceptos fundamentales, ejemplos históricos y herramientas analíticas.

Los ciclos bursátiles reflejan expectativas futuras y son un termómetro anticipado de la economía. Este análisis incluye gráficos y referencias académicas para sustentar la explicación.

Concepto de Ciclo Bursátil


Un ciclo bursátil es el conjunto de variaciones en los precios de los activos financieros que se repiten en el tiempo, formando tendencias alcistas y bajistas. Aunque su duración y magnitud varían, los ciclos suelen anticipar los movimientos de la economía real.

Históricamente, los ciclos alcistas han durado más que los bajistas, pero estos últimos son más abruptos.

Relación con los Ciclos Económicos

Figura 6

Ciclos Económicos



Los ciclos bursátiles están estrechamente vinculados a los ciclos económicos, que comprenden cuatro fases: expansión, auge, recesión y depresión. Generalmente, la bolsa se adelanta entre 6 y 12 meses a la economía, porque los precios reflejan expectativas futuras

Factores que Influyen en los Ciclos

Los ciclos bursátiles responden a múltiples variables: política monetaria, indicadores macroeconómicos, psicología del inversor y eventos externos. Cada uno de estos factores influye en la duración y magnitud de las fases del ciclo.

Fases del Ciclo Bursátil

Las fases del ciclo bursátil incluyen acumulación, expansión, distribución y contracción. Cada fase presenta características específicas en precios, volumen y sentimiento del mercado.

El ciclo bursátil se compone de cuatro fases principales: acumulación, expansión, distribución y contracción.

La fase de acumulación ocurre después de un mercado bajista prolongado. Durante este periodo, los precios se mantienen estables o muestran ligeros incrementos, acompañados de un volumen bajo. El sentimiento predominante es de pesimismo, lo que permite a los inversores institucionales realizar compras estratégicas. Entre los indicadores más comunes se encuentran las divergencias alcistas y medias móviles planas.

La fase de expansión, también conocida como tendencia alcista, se caracteriza por una mejora económica y un aumento generalizado de la confianza. Los precios suben de manera sostenida y el volumen de negociación crece. El optimismo se extiende, atrayendo a inversores minoristas. Los indicadores técnicos más relevantes incluyen medias móviles ascendentes y rupturas de niveles de resistencia.

Posteriormente, se presenta la fase de distribución, en la cual los precios alcanzan máximos históricos y la volatilidad aumenta. En este contexto, los grandes inversores comienzan a vender para asegurar ganancias. El sentimiento dominante es la euforia, y el mercado muestra señales de sobrevaloración. Los indicadores más frecuentes son las divergencias bajistas y patrones de reversión.

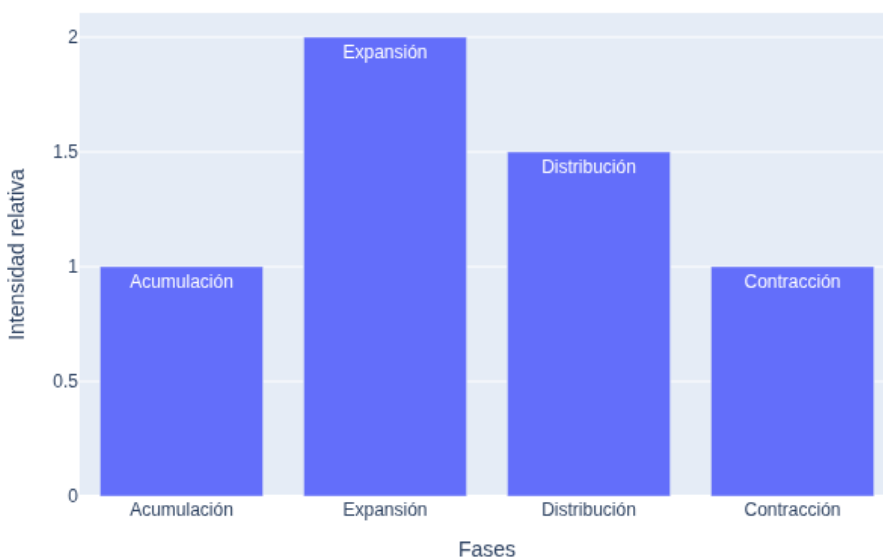
Finalmente, la fase de contracción o tendencia bajista se manifiesta con ventas masivas y caídas abruptas en los precios. El miedo extremo y la capitulación marcan el comportamiento del mercado. Los indicadores técnicos incluyen medias móviles descendentes y rupturas de soportes.

Ejemplo práctico: En el ciclo 2008-2009, tras la crisis financiera, la fase de acumulación se observó en 2009, seguida por una expansión prolongada hasta 2019.

Figura 7

Ciclo Bursátil 2008-2009

Fases del Ciclo Bursátil

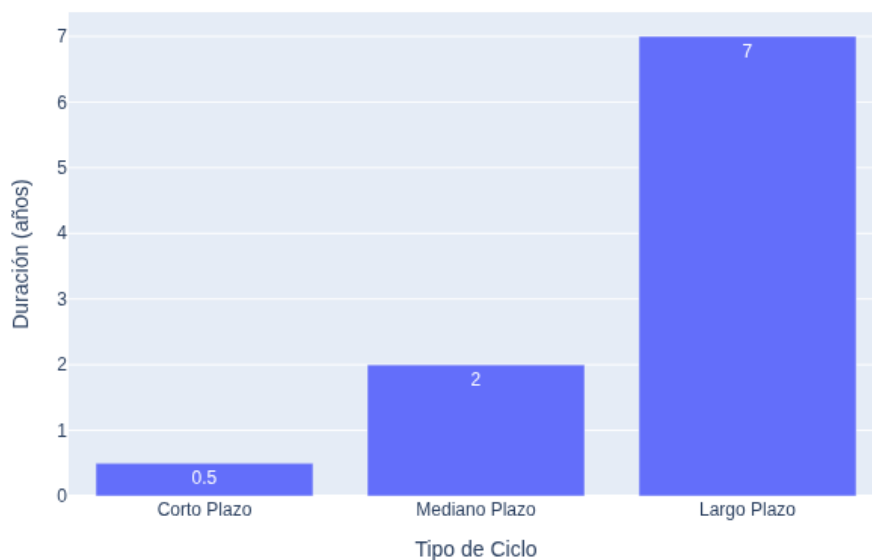


Duración y Tipología de los Ciclos

Figura 8

Duración vs Tipología de Ciclos

Duración Típica de los Ciclos



Nota. Los ciclos pueden clasificarse en corto, mediano y largo plazo. Su duración depende de factores económicos y estructurales.

Importancia para la Inversión

Conocer los ciclos permite optimizar el timing de compra y venta, gestionar riesgos y diseñar estrategias adaptadas a cada fase.

Teorías Clásicas sobre Ciclos Bursátiles

Existen teorías clásicas como la Teoría de Dow, Wyckoff y Kondratiev que explican la lógica detrás de los ciclos bursátiles.

En conclusión los ciclos bursátiles son inevitables y reflejan la naturaleza dinámica de los mercados. Comprender su lógica permite tomar decisiones más racionales y reducir riesgos.

Modelo Prophet

Una propuesta es el modelo Prophet, disponible a través del paquete `fable.prophet`. Este modelo fue introducido por Facebook ([S. J. Taylor & Letham, 2018](#)), originalmente para predecir datos diarios con estacionalidad semanal y anual, además de efectos de vacaciones. Más tarde se amplió para cubrir más tipos de datos estacionales. Funciona mejor con series temporales que tienen una fuerte estacionalidad y varias temporadas de datos históricos. Prophet puede considerarse un modelo de regresión no lineal (Capítulo 7), de la forma $y_t = g(t) + s(t) + h(t) + \epsilon_t$, donde $g(t)$ describe una tendencia lineal a trozos (o «término de crecimiento»), $s(t)$ describe los distintos patrones estacionales, $h(t)$ recoge los efectos de las vacaciones y ϵ_t es un término de error de ruido blanco.

- Los nudos (o puntos de cambio) para la tendencia lineal a trozos son seleccionados automáticamente si no se especifican explícitamente. Opcionalmente, se puede utilizar una función logística para establecer un límite superior en la tendencia.
- El componente estacional consiste en términos de Fourier de los periodos relevantes. Por defecto, se utiliza el orden 10 para la estacionalidad anual y el orden 3 para la estacionalidad semanal.
- Los efectos de las vacaciones se añaden como simples variables ficticias.
- El modelo se estima utilizando un enfoque bayesiano para permitir la selección automática de los puntos de cambio y otras características del modelo.

Ilustramos el enfoque utilizando dos conjuntos de datos: un ejemplo trimestral sencillo y, a continuación, los datos de demanda de electricidad descritos en la sección anterior.

Ejemplo: Producción trimestral de cemento

```
library(fable.prophet)
```

```

cement <- aus_production %>%
  filter(year(Quarter) >= 1988)
train <- cement %>%
  filter(year(Quarter) <= 2007)
fit <- train %>%
  model(arima = ARIMA(Cement), ets = ETS(Cement), prophet = prophet(Cement ~
season(period = 4, order = 2, type = "multiplicative")))

```

Tenga en cuenta que el término estacional debe tener periodo completamente especificado para los datos trimestrales y mensuales, ya que los valores por defecto asumen que los datos se observan al menos diariamente.


```

fc <- fit %>% forecast(h = "2 years 6 months")
fc %>% autoplot(cement)

```

Figura 9

Prophet vs ETS y ARIMA en los Datos de Producción de Cemento



Nota. En este ejemplo, las predicciones de Prophet son peores que las de ETS o ARIMA.

Ejemplo: Demanda eléctrica semihoraria

```
fc %>% accuracy(cement)
```

```
#> # A tibble: 3 × 10
```

```
#> .model .type ME RMSE MAE MPE MAPE MASE RMSSE ACF1
```

```
#> <chr> <chr> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl>
```

```
#> 1 arima Test -161. 216. 186. -7.71 8.68 1.27 1.26 0.387
```

```
#> 2 ets Test -171. 222. 191. -8.07 8.85 1.30 1.29 0.579
```

```
#> 3 prophet Test -176. 248. 215. -8.36 9.89 1.47 1.44 0.698
```

Vamos a ajustar un modelo similar al modelo de regresión armónica dinámica (DHR) de la sección anterior, pero esta vez utilizando un modelo Prophet. Para los datos diarios y subdiarios, los periodos por defecto están correctamente especificados, por lo que podemos simplemente especificar el periodo utilizando una cadena de caracteres como sigue.

```
fit <- elec %>%
```

```
  model(prophet(Demand ~ Temperature + Cooling + Working_Day +
```

```
    season(period = "day", order = 10) +
```

```
    season(period = "week", order = 5) +
```

```
    season(period = "year", order = 3)))
```

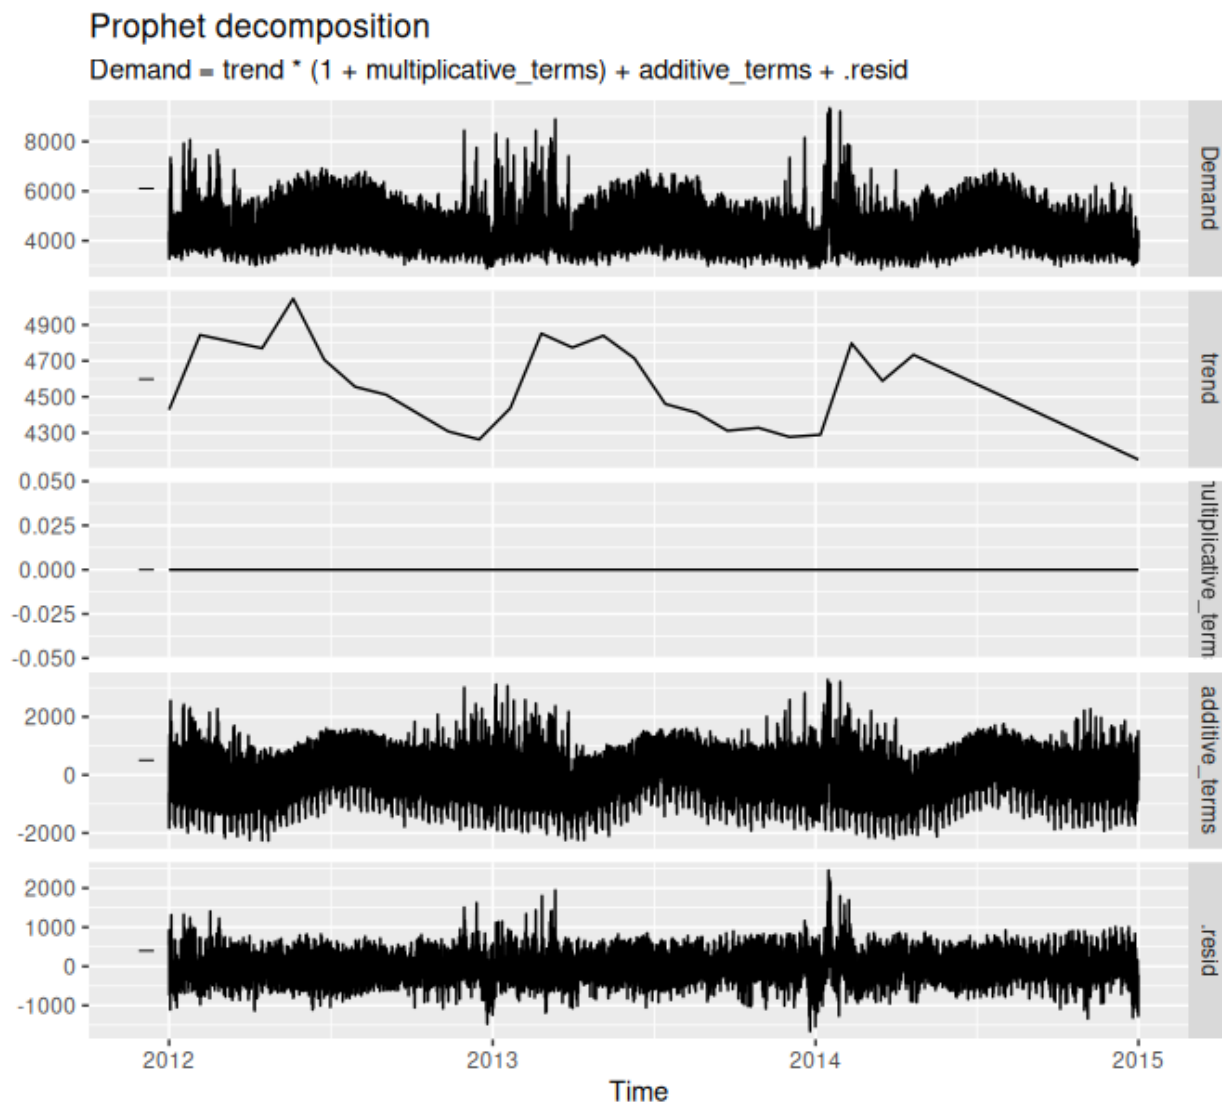
```
fit %>%
```

```
  components() %>%
```

```
  autoplot()
```

Figura 10

Componentes de un Modelo Prophet Ajustado



Nota. Tomado del modelo Prophet de internet, la cual, muestra la tendencia y los componentes estacionales del modelo ajustado.


La especificación del modelo es muy similar a la del modelo DHR de la sección anterior, aunque el resultado es diferente en varios aspectos importantes. El modelo Prophet añade una tendencia temporal lineal a trozos que no es realmente apropiada en este caso, ya que no

esperamos que las predicciones a largo plazo sigan la tendencia lineal descendente al final de la serie. También hay una autocorrelación sustancial en los residuos,

```
fc <- fit %>%
  forecast(new_data = elec_newdata)
fc %>%
  autoplot(elec %>% tail(10 * 48)) +
  labs(x = "Date", y = "Demand (MWh)")
```

Figura 11

Pronostico entre Dos Días



Prophet tiene la ventaja de ser mucho más rápido de ajustar que los modelos DHR que hemos considerado anteriormente, y está completamente automatizado. Sin embargo, rara vez

ofrece una predicción más precisa que los enfoques alternativos, como ilustran estos dos ejemplos.

Conclusiones

El mercado de valores en Estados Unidos representa un componente esencial de la economía global. Su evolución ha estado marcada por avances tecnológicos y el uso creciente de la analítica de datos. Comprender su funcionamiento y aplicar herramientas de análisis permite tomar decisiones más informadas y estratégicas en el ámbito financiero.

El desarrollo del presente trabajo permitió implementar y evaluar un modelo de pronóstico basado en Prophet para analizar el comportamiento de precios de acciones en el mercado bursátil. A partir del procesamiento de datos históricos, la generación de predicciones y el cálculo de métricas de desempeño, se obtuvieron resultados que evidencian la aplicabilidad de técnicas de analítica y ciencia de datos en la toma de decisiones financieras. Las conclusiones que se presentan a continuación sintetizan los hallazgos más relevantes del análisis, destacando aspectos relacionados con la precisión del modelo, la eficiencia del procesamiento y la utilidad de las herramientas empleadas para la interpretación de resultados. A continuación se presentan algunas conclusiones relacionadas con el código y los resultados que este generó.

El modelo Prophet, configurado con estacionalidad anual y modo multiplicativo, se adapta adecuadamente a los patrones históricos de precios de acciones, ofreciendo predicciones consistentes para horizontes de 180 días.

Al reservar los últimos 180 días para validación, se logra medir el desempeño del modelo en datos no vistos, lo que garantiza una estimación realista de su capacidad predictiva.

El cálculo de métricas (MAE, RMSE, MAPE y R^2) proporciona una visión integral del rendimiento, ya que estas métricas permiten identificar la precisión del modelo y su capacidad para explicar la variabilidad de los datos, siendo el MAPE especialmente útil para interpretar errores en términos porcentuales.

El uso de `cross_validation` y `performance_metrics` evidencia la estabilidad del modelo en diferentes ventanas temporales, reduciendo el riesgo de sobreajuste y aumentando la confiabilidad de las predicciones.

La paralelización optimiza el procesamiento de múltiples activos, en este caso, gracias a `ThreadPoolExecutor`, el tiempo de ejecución se reduce significativamente al procesar varias acciones en paralelo, lo que hace viable el análisis de grandes volúmenes de datos en entornos reales.

Los gráficos generados (serie temporal, dispersión y residuos) junto con los reportes en Excel permiten una comunicación clara de resultados, apoyando decisiones estratégicas basadas en datos.

Recomendaciones

Se recomienda construir portafolios diversificados que incluyan sectores con baja correlación entre sí, como tecnología y energía, para reducir el riesgo sistemático.

El análisis de rendimiento anual sugiere que el sector tecnológico ha liderado consistentemente en rentabilidad. Invertir en este sector puede ofrecer mayores retornos, aunque con mayor volatilidad.

Dado que las correlaciones y rendimientos cambian con el tiempo, se recomienda revisar y ajustar el portafolio de inversión al menos una vez al año.

Aplicar modelos de predicción basados en datos históricos y correlaciones puede mejorar la toma de decisiones y anticipar movimientos del mercado.

Optimizar la calidad de los datos, implementando procesos de limpieza y enriquecimiento de datos, incluyendo variables externas (indicadores macroeconómicos, noticias financieras), para reducir el error y aumentar la robustez del modelo.

Automatizar la generación de reportes y visualizaciones, haciendo uso de scripts que actualicen automáticamente los gráficos y archivos Excel, facilitando la toma de decisiones en tiempo real y reduciendo la intervención manual.

Establecer un ciclo de actualización del modelo con datos recientes y validación continua para adaptarse a cambios en el comportamiento del mercado y evitar degradación en la precisión.

Referencias Bibliográficas

- Alcaraz López, V. A. (2022). *Predicción sobre mercado de valores con redes neuronales LSTM*. [Tesis de maestría, Universidad de Murcia].
- Bellvert Torres, M. (2020). *Inteligencia artificial como herramienta para la inversión en el mercado de valores*. [Trabajo de fin de grado, Universitat de Barcelona].
- Black, F., & Scholes, M. (1973). *The Pricing of Options and Corporate Liabilities*. *Journal of Political Economy*, 81(3), 637–654. <https://doi.org/10.1086/260062>
- Bodie, Z., Kane, A., & Marcus, A. J. (2018). *Investments* (11th ed.). McGraw-Hill Education.
- Dow, C. H. (1902). *The Dow Theory*. *Wall Street Journal Editorials Compilation*.
- Fabozzi, F. J. (2013). *Bond Markets, Analysis and Strategies* (9th ed.). Pearson.
- Fama, E. F. (1970). *Efficient Capital Markets: A Review of Theory and Empirical Work*. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- Fisher, P. A. (2004). *Common Stocks and Uncommon Profits*. Deusto.
- Gallego Varela, A. (2023). *Predicción de la cotización de acciones en bolsa mediante Deep Learning*. [Trabajo de fin de grado, Universidad Pontificia Comillas].
- Hull, J. C. (2017). *Options, Futures, and Other Derivatives* (10th ed.). Pearson.
- Hull, J. C. (2018). *Options, Futures, and Other Derivatives*. Pearson.
- Kondratiev, N. (1925). *The Long Waves in Economic Life*. *Moscow Institute of Economic Research*.
- Lewis, M. (2011). *La gran apuesta*. Deusto.
- Markowitz, H. (1952). *Portfolio Selection*. *The Journal of Finance*, 7(1), 77–91. <https://doi.org/10.2307/2975974>
- Mishkin, F. S., & Eakins, S. G. (2021). *Financial Markets and Institutions* (9th ed.). Pearson.

- O'Hara, M. (1995). *Market Microstructure Theory*. Blackwell Publishers.
- Pring, M. J. (2002). *Análisis técnico explicado*. Deusto.
- Rabanal, C. (2023). *Ciclos financieros y económicos en América Latina*. *Revista de Economía Latinoamericana*, 45(2), 123–145.
- Sharpe, W. F. (1964). *Capital Asset Prices: A Theory of Market Equilibrium Under Conditions of Risk*. *The Journal of Finance*, 19(3), 425–442. <https://doi.org/10.2307/2977928>
- Siegel, J. J. (2005). *Guía para invertir a largo plazo*. McGraw-Hill.
- Tarira Pérez, J., Gómez, L., & Rivas, M. (2024). *Evaluación de modelos de aprendizaje automático en predicción bursátil*. *Revista Iberoamericana de Ciencia de Datos*, 6(1), 55–72.
- Traseira Linares, C. (2022). *Predicción de precios de acciones en bolsa a través de redes neuronales*. [Tesis de maestría, Universidad de Vigo].
- Vergara González, R., Mejía Reyes, P., & Díaz Carreño, M. A. (2021). *Ciclos económicos y variables monetarias y financieras en México, 1980–2019: un enfoque de cambio estructural*. *Ensayos*. *Revista de Economía*, 40(2), 45–78. <https://doi.org/10.29105/ensayos40.2-2>
- Wyckoff, R. D. (1931). *The Richard D. Wyckoff Method of Trading and Investing in Stocks*. The Magazine of Wall Street.

Apéndices

Apéndice A

Explicación del Código y Análisis de Resultados

A continuación, se presenta una explicación y la respectiva justificación del uso de cada una de las etapas del código desarrollado, así como también, la interpretación o análisis de los resultados obtenidos en cada una de las gráficas y cálculo de métricas.

Código para Importación de Librerías

```
import pandas as pd
from prophet import Prophet
from prophet.diagnostics import cross_validation, performance_metrics
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
import matplotlib.pyplot as plt
import numpy as np
import os
import logging
from concurrent.futures import ThreadPoolExecutor
```

Nota. Importe de Librerías.

- pandas: manejo de datos en DataFrames.
- Prophet: modelo de predicción de series temporales desarrollado por Facebook.
- cross_validation y performance_metrics: validación cruzada y métricas internas de Prophet.
- sklearn.metrics: cálculo de métricas de error (MAE, RMSE, R²).
- matplotlib: generación de gráficos.
- numpy: operaciones numéricas.
- os: manejo de rutas y directorios.
- logging: control de mensajes del modelo Prophet.

- ThreadPoolExecutor: paralelización para procesar varias acciones simultáneamente.

Justificación: Se requieren estas librerías para cargar datos, entrenar modelos, evaluar resultados y generar visualizaciones.

Código para la Configuración Inicial.

```
# Silenciar Logs de Prophet
logging.getLogger('prophet').setLevel(logging.ERROR)

# Ruta del dataset original (modificar según sea necesario)
dataset_path = "d:\\mis documentos\\UNAD\\Sem2\\ProyecGrad2\\Fase-0\\Stock Market DatasetV1-ETL.csv"

# Obtener la ruta base (directorio) del dataset
base_dir = os.path.dirname(dataset_path)

# Crear carpeta para guardar las gráficas dentro de la misma ruta base
plots_dir = os.path.join(base_dir, "forecast_plots")
os.makedirs(plots_dir, exist_ok=True)
```

Nota. Configuración del código.

- Silencia mensajes innecesarios de Prophet.
- Define la ruta del dataset y crea carpetas para guardar gráficos.

Justificación: Mantener el código ordenado y evitar ruido en la salida.

Código para la carga del Data Set.

```
# Ruta del dataset original (modificar según sea necesario)
dataset_path = "d:\\mis documentos\\UNAD\\Sem2\\ProyecGrad2\\Fase-0\\Stock Market DatasetV1-ETL.csv"
```

Nota. Carga de datos.

- Carga el archivo CSV con separador;.
- Convierte la columna Date en formato de fecha.

Justificación: Prophet requiere una columna ds con fechas en formato datetime.

Código para lista de Columnas y Estructura.

```
# Lista de columnas de precios de acciones
stock_columns = [
    'Apple_Price', 'Tesla_Price', 'Amazon_Price', 'Meta_Price',
    'Google_Price', 'Microsoft_Price', 'Netflix_Price', 'Nvidia_Price'
]

# Diccionarios para guardar métricas y predicciones
metrics = {}
future_predictions = {}
cv_metrics_summary = {}
```

Nota. Lista de Acciones y Diccionarios.

- Lista de acciones a procesar.
- Diccionarios para almacenar métricas, predicciones y resultados de validación cruzada.

Justificación: Facilita el manejo de múltiples activos en paralelo.

Código para la Función `Process_stock`.

```
# Función para procesar cada acción
def process_stock(stock):
    data = df[['Date', stock]].rename(columns={'Date': 'ds', stock: 'y'}).dropna()
    if len(data) < 200:
        print(f"⚠ Datos insuficientes para {stock}. Se omite.")
        return None

    train = data.iloc[:-180]
    test = data.iloc[-180:]
```

Nota. Este es el núcleo del código. Procesamos cada acción individualmente.

- Prophet necesita columnas ds (fecha) y y (valor).
- Divide datos en entrenamiento y prueba (últimos 180 días).

Justificación: Separar datos para evaluar el modelo.

Código para el Entrenamiento del Modelo.

```
# Modelo Prophet optimizado
model = Prophet(
    yearly_seasonality=True,
    weekly_seasonality=False,
    daily_seasonality=False,
    seasonality_mode='multiplicative'
)
model.fit(train)
```

Nota. Entrenamiento y configuración del modelo.

- Configura Prophet con estacionalidad anual y modo multiplicativo.
- La estacionalidad y tendencia se combinan multiplicativamente, para que las variaciones sean proporcionales al nivel del precio.
- Ajusta el modelo a los datos históricos.

Justificación: Capturar patrones anuales en precios de acciones.

Código para la Predicción Futura.

```
# Predicciones futuras
future = model.make_future_dataframe(periods=180)
forecast = model.predict(future)
```

Nota. Predicciones futuras a 180 días.

- Genera fechas futuras (180 días).
- Obtiene predicciones (yhat).

Justificación: Anticipar comportamiento del mercado.

Código para la Evaluación del Modelo.

```
# Combinar predicciones con datos reales
merged = pd.merge(test, forecast[['ds', 'yhat']], on='ds', how='inner')
merged.dropna(inplace=True)

# Métricas
mae = mean_absolute_error(merged['y'], merged['yhat'])
rmse = np.sqrt(mean_squared_error(merged['y'], merged['yhat']))
mape = np.mean(np.abs((merged['y'] - merged['yhat']) / np.maximum(merged['y'], 1e-6))) * 100
r2 = r2_score(merged['y'], merged['yhat'])
```

Nota. Predicciones con Datos Reales

Calcula métricas de error:

- MAE: error absoluto medio.
- RMSE: error cuadrático medio.
- MAPE: error porcentual medio.
- R²: ajuste del modelo.

Justificación: Medir precisión del modelo.

Código para Realizar la Validación Cruzada.

```
| # Validación cruzada
| try:
|     df_cv = cross_validation(model, initial='1095 days', period='180 days', horizon='180 days')
|     df_perf = performance_metrics(df_cv)
|     cv_summary = df_perf[['mae', 'rmse', 'mape', 'coverage']].mean().to_dict()
| except Exception:
|     cv_summary = {'mae': None, 'rmse': None, 'mape': None, 'coverage': None}

metrics[stock] = {'MAE': mae, 'RMSE': rmse, 'MAPE': mape, 'R2': r2}
cv_metrics_summary[stock] = cv_summary
future_predictions[stock] = forecast[['ds', 'yhat']].tail(10)
```

Nota. Validación cruzada entre métricas.

- Evalúa el modelo en diferentes ventanas temporales.
- Obtiene métricas promedio.


Justificación: Validar robustez del modelo.

Código para la Generación de gráficos.

```
# Gráficos
plt.figure(figsize=(10, 6))
plt.plot(train['ds'], train['y'], label='Entrenamiento')
plt.plot(test['ds'], test['y'], label='Real')
plt.plot(forecast['ds'], forecast['yhat'], label='Predicción')
plt.legend()
plt.title(f'Predicción para {stock}')
plt.savefig(os.path.join(plots_dir, f"{stock}_forecast.png"))
```

Nota. Gráficos de predicción y real

Resultado de Predicción de Amazon.



Nota. La gráfica muestra la evolución del precio de Amazon (Amazon_Price) en el tiempo.

Encontramos tres líneas que representan:

Entrenamiento (azul): Datos históricos usados para entrenar el modelo, desde 2019 hasta aproximadamente 2023.


Real (naranja): Valores reales observados en el período de prueba (cerca de 2023-2024).

Predicción (verde): Valores estimados por el modelo para el mismo período de prueba.

Interpretación:

- Tendencia general: El precio sigue una tendencia ascendente bastante lineal desde 2019 hasta 2024.
- Ajuste del modelo: Las líneas azul y verde prácticamente se superponen con la naranja, lo que indica que el modelo predice con alta precisión (muy poca diferencia entre valores reales y predichos).
- Error mínimo: La cercanía entre la línea verde (predicción) y la naranja (real) sugiere que el modelo tiene bajo error en el período de prueba.


Resultado de la Predicción de Tesla.



Interpretación:

- Tendencia: El precio de Tesla muestra un crecimiento mucho más pronunciado que Amazon, pasando de ~1500 en 2019 a ~4000 en 2024.
- Ajuste del modelo: Las líneas verde y naranja prácticamente se superponen, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.
- Comportamiento lineal: El crecimiento parece casi lineal, lo que puede indicar que el modelo está capturando una tendencia fuerte, aunque en la realidad Tesla suele tener alta volatilidad (esto podría ser una simplificación del modelo).


Resultado de la Predicción de Apple.



Interpretación:

- Tendencia: El precio de Apple crece de forma marcada, pasando de ~1100 en 2019 a más de 4200 en 2024.
- Ajuste del modelo: Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.
- Comportamiento lineal: Igual que Tesla, el modelo parece asumir una tendencia lineal fuerte, lo que puede ser una simplificación frente a la volatilidad real del mercado.

Resultado de la Predicción Meta.



Interpretación:

- Entrenamiento (azul): Datos históricos usados para entrenar el modelo (2019-2023).
- Real (naranja): Valores reales observados en el período de prueba (finales de 2023 a 2024).
- Predicción (verde): Valores estimados por el modelo para ese mismo período.
- Tendencia: El precio de Meta muestra un crecimiento acelerado, especialmente a partir de 2022.
- Ajuste del modelo: Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.


Resultado de la Predicción de Google.



Interpretación:

- **Tendencia:** El precio de Google muestra un crecimiento acelerado, especialmente a partir de 2022, pasando de ~700 en 2019 a más de 7200 en 2024.
- **Cambio de pendiente:** Similar a Meta, hay un incremento más pronunciado después de 2022, lo que indica un comportamiento no lineal.
- **Ajuste del modelo:** Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- **Error mínimo:** No se observan desviaciones significativas entre lo real y lo predicho.
- **Implicación:** El modelo parece adaptarse bien a cambios en la tendencia, lo que es positivo para escenarios con aceleración en el crecimiento.


Resultado de la Predicción de Microsoft.



Interpretación:

- Tendencia: El precio de Microsoft sigue un crecimiento constante y lineal, pasando de ~2200 en 2019 a más de 5200 en 2024.
- Ajuste del modelo: Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.
- Comportamiento estable: A diferencia de Meta, aquí no hay cambios bruscos en la pendiente, lo que sugiere un patrón más predecible.

Resultado de la Predicción de Netflix.




Interpretación:

- Tendencia: El precio de Netflix muestra un crecimiento muy estable y casi perfectamente lineal, pasando de ~3600 en 2019 a ~7300 en 2024.

- Ajuste del modelo: Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.
- Implicación: El comportamiento lineal sugiere que el modelo está capturando bien la tendencia, pero también indica que podría ser menos sensible a cambios bruscos (riesgo si el mercado se vuelve volátil).

Resultado de la Predicción de Nvidia.



Interpretación:

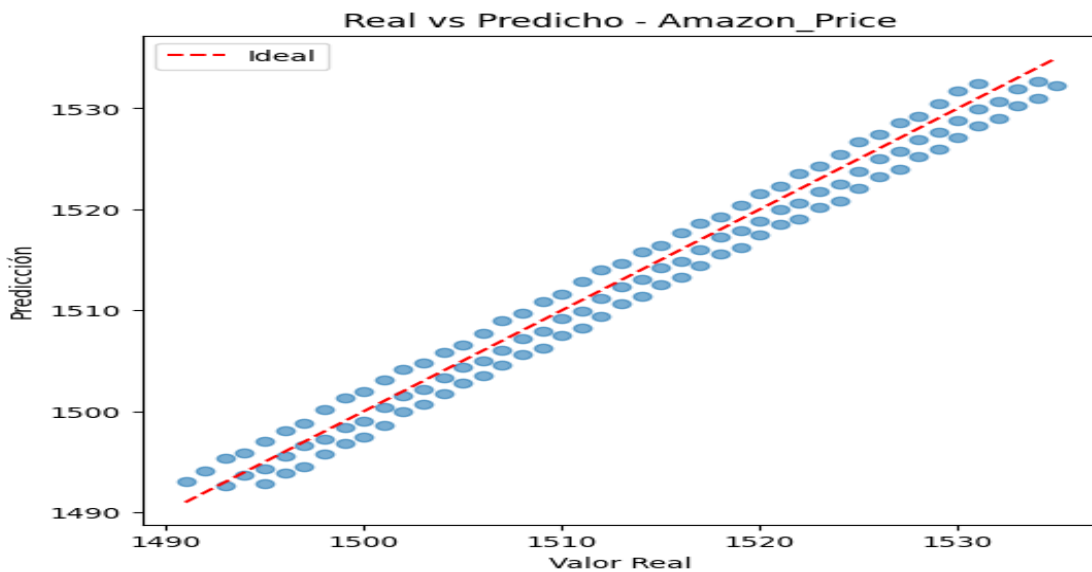
- Tendencia: Nvidia muestra un crecimiento acelerado, pasando de ~1700 en 2019 a más de 6400 en 2024.

- Ajuste del modelo: Las líneas verde y naranja están prácticamente superpuestas, lo que indica alta precisión en la predicción.
- Error mínimo: No se observan desviaciones significativas entre lo real y lo predicho.

Código para la Dispersión (Real vs Predicho).

```
plt.figure(figsize=(6, 6))
plt.scatter(merged['y'], merged['yhat'], alpha=0.6)
plt.plot([merged['y'].min(), merged['y'].max()],
         [merged['y'].min(), merged['y'].max()],
         'r--', label='Ideal')
plt.xlabel('Valor Real')
plt.ylabel('Predicción')
plt.title(f'Real vs Predicho - {stock}')
plt.legend()
plt.savefig(os.path.join(plots_dir, f"{stock}_scatter.png"))
```

Resultados Real vs Predicho.



Interpretación:

- Eje X: Valor Real (observado).
- Eje Y: Predicción (estimado por el modelo).

- Línea roja (Ideal):
- Representa el caso perfecto donde Predicción = Valor Real.
- Si todos los puntos estuvieran sobre esta línea, el modelo sería 100% preciso.

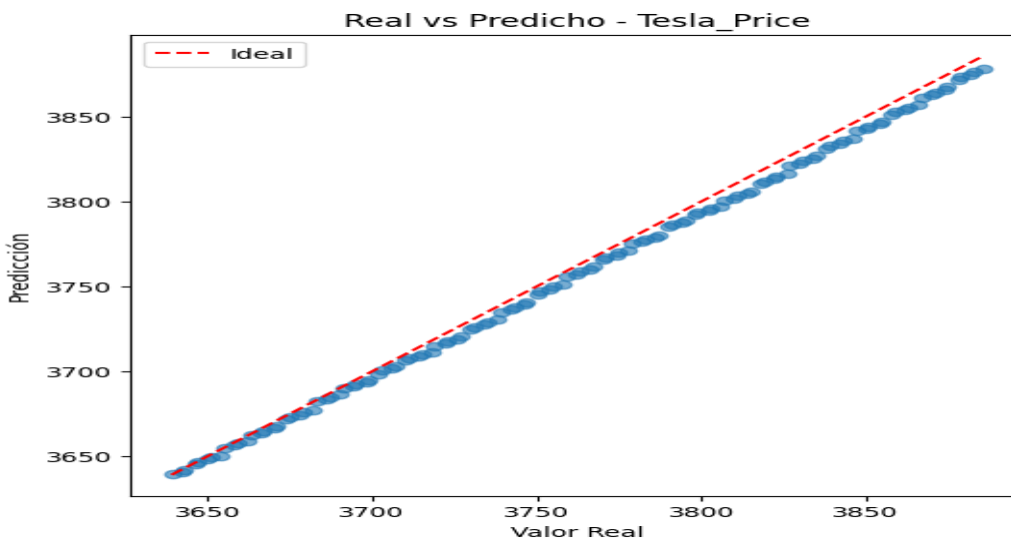
Distribución de puntos:

- Los puntos azules están muy cerca de la línea roja, lo que indica que el modelo tiene alta precisión.
- No se observa dispersión significativa ni sesgo sistemático (por ejemplo, no hay tendencia a sobreestimar o subestimar).

Conclusión:

- El modelo está funcionando muy bien en el rango analizado (1490 a 1535).
- El error parece ser mínimo y no hay outliers evidentes.

Gráfica Real vs Predico Tesla.



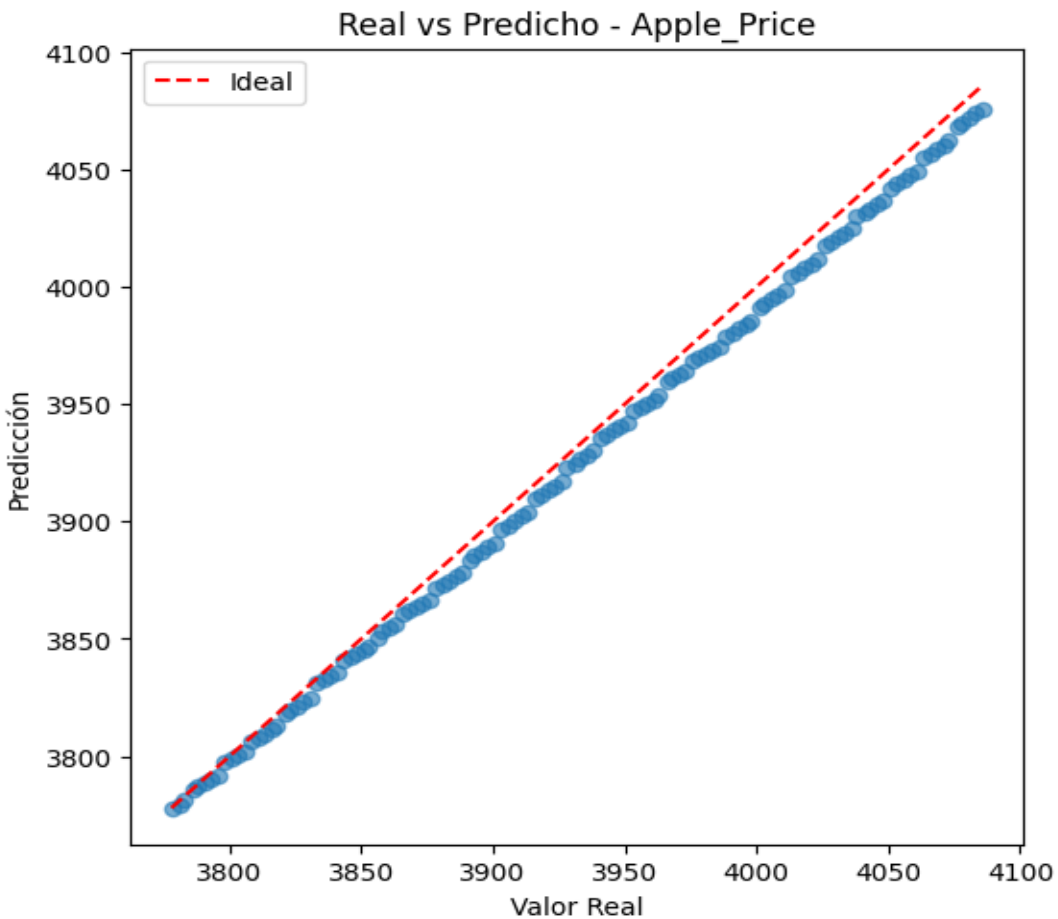
Interpretación:

- Los puntos azules están muy cerca de la línea roja, lo que indica altísima precisión.
- No hay dispersión significativa ni sesgo evidente (no se observa que el modelo sobreestime o subestime sistemáticamente).

Conclusión:

- El modelo para Tesla tiene un ajuste excelente, similar al de Amazon.
- El error visualmente parece mínimo, lo que sugiere un R^2 cercano a 1 y métricas como RMSE muy bajas.

Gráfica Real vs Predicho Apple.



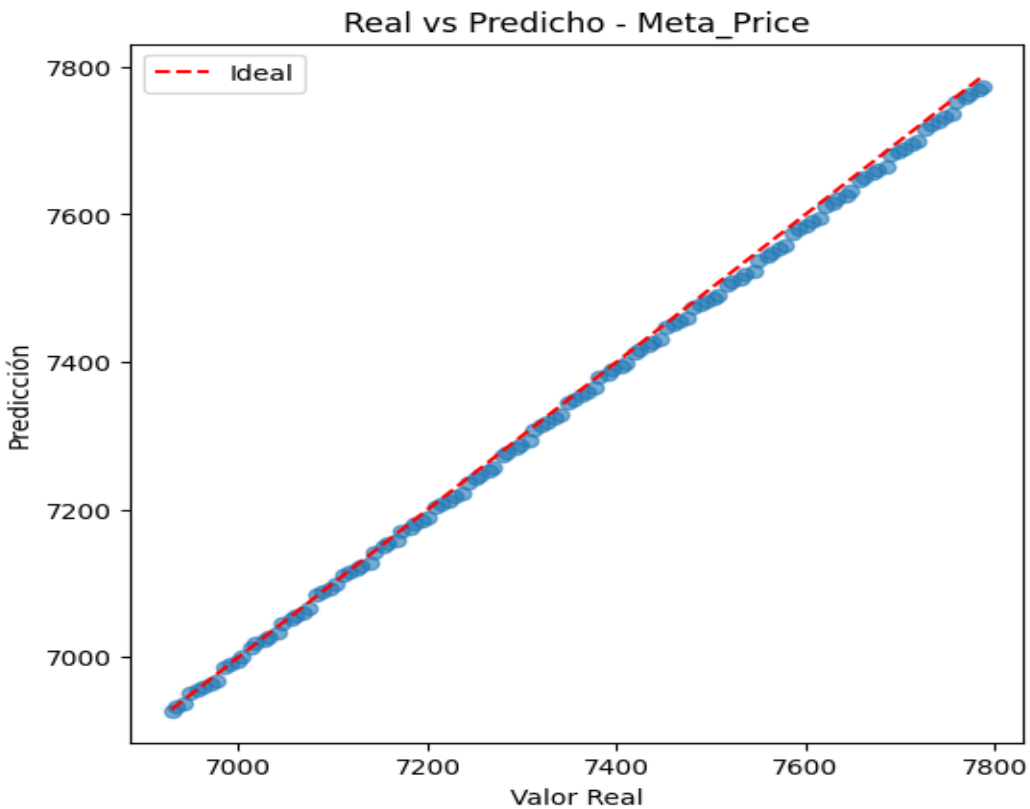
Interpretación:

- Los puntos azules están prácticamente alineados con la línea roja.
- Esto indica altísima precisión: el modelo predice casi exactamente los valores reales.
- No se observa dispersión significativa ni sesgo (no hay tendencia a sobreestimar o subestimar).

Conclusión técnica:

- El modelo para Apple tiene un ajuste excelente.
- El error es mínimo, probablemente con métricas como $R^2 \approx 0.999$ y RMSE muy bajo.
- Esto sugiere que el modelo está capturando la tendencia de manera muy precisa.

Gráfica Real vs Predicho Meta.



Interpretación:

- Los puntos azules están prácticamente sobre la línea roja, lo que indica altísima precisión.
- No hay dispersión significativa ni sesgo (no se observa tendencia a sobreestimar o subestimar).
- Esto sugiere un R^2 cercano a 1 y errores mínimos (RMSE y MAE muy bajos).

Conclusión:

- El modelo para Meta está extremadamente bien ajustado.

- No hay evidencia de problemas de predicción en este rango.
- Esto refuerza que el modelo es confiable para este período, aunque habría que evaluar si mantiene esta precisión en escenarios más volátiles.

Gráfica Real vs Predicho Google.




Interpretación:

- Los puntos azules están muy cerca de la línea ideal, formando casi una línea recta.
- Esto indica altísima precisión del modelo, con errores mínimos.
- No se observa sesgo sistemático (ni sobreestimación ni subestimación clara).

Conclusión:

- El modelo para Google tiene un desempeño excelente.
- El error parece ser muy bajo, probablemente con un R^2 cercano a 1.
- Esto sugiere que el modelo es confiable para este rango de precios.

Gráfica Real vs Predicho Microsoft.



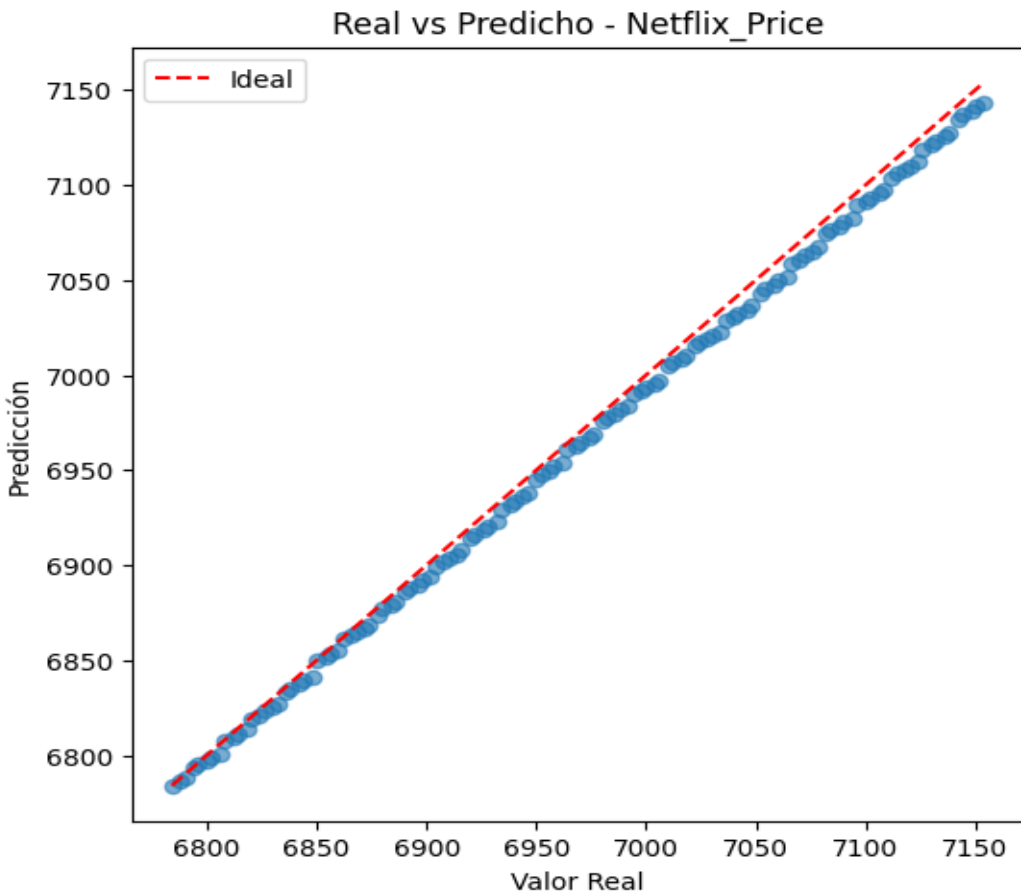
Interpretación:

- Los puntos azules están prácticamente sobre la línea roja, lo que indica altísima precisión.
- No se observa dispersión significativa ni sesgo (el modelo no tiende a sobreestimar ni subestimar).

Conclusión:

- El modelo para Microsoft es muy bien ajustado, con errores mínimos.
- Esto sugiere que el modelo tiene un R^2 cercano a 1 y métricas como RMSE y MAE muy bajas.

Gráfica Real vs Predicho Netflix.



Interpretación:


- Los puntos azules están prácticamente sobre la línea roja, lo que indica altísima precisión.
- No se observa dispersión significativa ni sesgo (no hay tendencia a sobreestimar o subestimar).

Conclusión:

- El modelo predice los precios de Netflix con gran exactitud en el rango analizado (6800 a 7150).
- El error es mínimo y no hay outliers visibles.

- Esto sugiere que el modelo está bien ajustado y generaliza correctamente para este período.

Gráfica Real vs Predicho Nvidia.



Interpretación:

- Los puntos azules están prácticamente sobre la línea roja, lo que indica altísima precisión.
- No se observa dispersión significativa ni sesgo (ni sobreestimación ni subestimación sistemática).

Conclusión:

- El modelo para Nvidia está funcionando excelentemente en este rango.
- El error es mínimo, probablemente con un R^2 cercano a 1 y métricas como RMSE muy bajas.


- Esto sugiere que el comportamiento del precio de Nvidia es muy predecible bajo el modelo usado.

Código para Análisis de Residuos.

```
residuos = merged['y'] - merged['yhat']
plt.figure(figsize=(10, 4))
plt.plot(merged['ds'], residuos, label='Residuos')
plt.axhline(0, color='red', linestyle='--')
plt.title(f'Residuos - {stock}')
plt.savefig(os.path.join(plots_dir, f"{stock}_residuos.png"))
```

Nota. Visualizar desempeño y errores.

Gráfica Residuos de Amazon.



Interpretación:

Eje Y: Residuo (error de predicción).

- Valores positivos: el modelo subestimó el precio real.
- Valores negativos: el modelo sobreestimó el precio real.

Eje X: Tiempo (meses de 2023).

Patrón observado:


- Los residuos oscilan alrededor de la línea roja (cero), lo que indica que no hay sesgo sistemático.

- Amplitud: entre aproximadamente -2 y +3, lo que significa que el error máximo es muy pequeño comparado con el precio (que está alrededor de 1500).
- Distribución: parece aleatoria, sin tendencia clara ni correlación con el tiempo → esto es bueno, indica que el modelo no está dejando patrones sin capturar.

Conclusión:

- El modelo es bien ajustado y los errores son bajos.
- No hay evidencia de heterocedasticidad (varianza constante en los residuos).
- Esto refuerza la idea de que el modelo tiene alta precisión y generalización.

Gráfica Residuos de Tesla.



Interpretación:

Eje Y: Residuo (error = valor real – predicción).

- Valores positivos: el modelo subestimó el precio real.
- Valores negativos: el modelo sobreestimó el precio real (aunque aquí casi no hay negativos).

Patrón observado:

- Los residuos comienzan cerca de 0 en mayo y aumentan progresivamente hasta alcanzar valores cercanos a 8-10 en noviembre.

- Esto indica que el modelo pierde precisión con el tiempo, mostrando un sesgo creciente (subestimación sistemática).
- La tendencia ascendente sugiere que el modelo no está capturando completamente la aceleración del precio de Tesla en este período.


Comparación con Amazon:

- En Amazon los residuos eran pequeños y aleatorios (buen ajuste).
- En Tesla hay heterocedasticidad y tendencia, lo que indica que el modelo podría necesitar ajustes (quizás más complejidad o actualización de parámetros).

Conclusión:

- El modelo para Tesla no generaliza tan bien como el de Amazon.

Gráfica Residuos de Apple.



Interpretación:


- Los residuos no están centrados en cero; comienzan cerca de 0 en mayo y aumentan progresivamente hasta superar 12 en octubre.
- Esto indica un sesgo sistemático: el modelo está subestimando el precio real cada vez más con el tiempo.
- Además, hay cierta oscilación, pero la tendencia ascendente es clara.

Conclusión:

- El modelo para Apple no está ajustando bien la tendencia reciente.

- Posible causa: el modelo asumió un crecimiento más lento que el real (quizás porque Apple tuvo un cambio brusco en su comportamiento).

Gráfica Residuos de Meta.



Interpretación:

Eje Y: Residuo (error = valor real – predicción).

- Valores positivos: el modelo subestimó el precio real.
- Valores negativos: el modelo sobreestimó el precio real.


Patrón observado:

- Los residuos no están centrados en cero como en el caso de Amazon.
- Hay una tendencia creciente: los errores aumentan con el tiempo, llegando a más de 20 unidades en octubre.
- Esto indica que el modelo no está capturando completamente la aceleración del precio en la última parte del período.
- Además, se observa cierta periodicidad (picos y valles), lo que podría sugerir un componente estacional o ruido correlacionado.

Conclusión:

- El modelo para Meta tiene mayor error y posible sesgo en comparación con Amazon y Tesla.
- Podría requerir ajustes: incorporar variables adicionales, usar un modelo no lineal o incluir componentes de tendencia acelerada.

Gráfica Residuos de Google.



Interpretación:

Eje Y: Residuo (error de predicción).

- Valores positivos: el modelo subestimó el precio real.
- Valores negativos: el modelo sobreestimó el precio real.
- Aquí todos los residuos son positivos, lo que indica un sesgo sistemático: el modelo está subestimando el precio real.


Eje X: Tiempo (meses de 2023).

- Los residuos comienzan cerca de 0 en mayo y aumentan progresivamente hasta superar 30 unidades en octubre.
- Esto indica que el error crece con el tiempo, lo que sugiere que el modelo no está capturando bien la tendencia real en este período.
- Además, hay una oscilación periódica sobre la tendencia ascendente, lo que podría reflejar estacionalidad o ruido no modelado.

Conclusión:

- El modelo para Google presenta problemas de ajuste: no es estacionario y muestra sesgo creciente.

Gráfica Residuos de Microsoft.



Interpretación:

Eje Y: Residuo (error entre valor real y predicho).

- Valores positivos: el modelo subestimó el precio real.
- Valores negativos: el modelo sobreestimó el precio real.
- Aquí todos los residuos son positivos, lo que indica un sesgo sistemático: el modelo está subestimando el precio.

Eje X: Tiempo (meses de 2023).


Patrón observado:

- Los residuos crecen con el tiempo, pasando de cerca de 0 en mayo a más de 10 en octubre.
- Esto indica que el modelo no está capturando completamente la tendencia ascendente del precio de Microsoft.
- Además, hay un patrón oscilatorio (picos y valles), lo que sugiere que hay componentes estacionales o cíclicos que el modelo no está considerando.

Conclusión:

- El modelo presenta sesgo creciente y error acumulativo.

Gráfica Residuos de Netflix.



Interpretación:

Eje Y: Residuo (error = valor real – predicción).

Todos los valores son positivos, lo que indica que el modelo subestimó el precio real durante todo el período.

Patrón observado:


- Comienza cerca de 0 en mayo y aumenta progresivamente hasta valores superiores a 10 en octubre.

- Hay una tendencia ascendente clara, similar a la que vimos en Apple, con oscilaciones periódicas.
- Esto indica un sesgo sistemático: el modelo no está capturando el crecimiento real de Netflix en este período.

Conclusión:

- El modelo para Netflix, al igual que para Apple, presenta subestimación creciente.

Gráfica Residuos de Nvidia.



Interpretación:

- Los residuos comienzan cerca de 0 en mayo y aumentan progresivamente hasta superar 18 en octubre.
- Esto significa que el modelo está subestimando cada vez más el precio real conforme avanza el tiempo.
- Hay oscilaciones periódicas, pero la tendencia ascendente es clara.
- Conclusión:

- El modelo para Nvidia no está capturando bien la aceleración en el precio.

Código para Realizar el proceso de Paralelización.

```
# Paralelización
with ThreadPoolExecutor(max_workers=4) as executor:
    executor.map(process_stock, stock_columns)
```

Nota. Procesa varias acciones en paralelo para optimizar tiempo.

Justificación: Acelerar ejecución en datasets grandes.

Código para Realizar la Exportación a Excel.

```
# Exportar resultados a Excel
excel_file = os.path.join(base_dir, "predicciones_futuras.xlsx")
with pd.ExcelWriter(excel_file, engine='openpyxl') as writer:
    for stock, prediction in future_predictions.items():
        sheet_name = stock.replace('_Price', '')
        prediction.to_excel(writer, sheet_name=sheet_name, index=False)

profitability = {}
for stock, prediction in future_predictions.items():
    if not prediction.empty and 'yhat' in prediction.columns:
        start_price = prediction['yhat'].iloc[0]
        end_price = prediction['yhat'].iloc[-1]
        if start_price != 0:
            profit = ((end_price - start_price) / start_price) * 100
            profitability[stock.replace('_Price', '')] = profit

profit_df = pd.DataFrame(list(profitability.items()), columns=['Acción', 'Rentabilidad (%)'])
profit_df.sort_values(by='Rentabilidad (%)', ascending=False, inplace=True)

with pd.ExcelWriter(excel_file, engine='openpyxl', mode='a', if_sheet_exists='replace') as writer:
    profit_df.to_excel(writer, sheet_name='Resumen_Rentabilidad', index=False)

metrics_df = pd.DataFrame.from_dict(metrics, orient='index').reset_index()
metrics_df.rename(columns={'index': 'Acción'}, inplace=True)
with pd.ExcelWriter(excel_file, engine='openpyxl', mode='a', if_sheet_exists='replace') as writer:
    metrics_df.to_excel(writer, sheet_name='Resumen_Métricas', index=False)

cv_df = pd.DataFrame.from_dict(cv_metrics_summary, orient='index').reset_index()
cv_df.rename(columns={'index': 'Acción'}, inplace=True)
with pd.ExcelWriter(excel_file, engine='openpyxl', mode='a', if_sheet_exists='replace') as writer:
    cv_df.to_excel(writer, sheet_name='Validación_Cruzada', index=False)

print(f"\n✅ Archivos generados en la ruta: {base_dir}")
print("✅ Archivo 'predicciones_futuras.xlsx' actualizado con hojas 'Resumen_Rentabilidad', 'Resumen_Métricas' y 'Validación_Cru")
```

- Guarda predicciones, métricas y validación cruzada en hojas separadas.
- Calcula rentabilidad estimada.

Justificación: Facilitar análisis posterior y reportes.

Código para Realizar la Visualización Final.

```
# Mostrar métricas en consola
print("\nMétricas de error por acción:")
for stock, m in metrics.items():
    print(f"{stock}: MAE = {m['MAE']:.2f}, RMSE = {m['RMSE']:.2f}, MAPE = {m['MAPE']:.2f}%, R2 = {m['R2']:.4f}")
```

Nota. Código que genera comparativos de métricas(MAE, RMSE, MAPE, R²).

Resultado de Métricas.

Métricas de error por acción:

Amazon_Price: MAE = 1.74, RMSE = 1.90, MAPE = 0.12%, $R^2 = 0.9752$

Tesla_Price: MAE = 5.31, RMSE = 5.79, MAPE = 0.14%, $R^2 = 0.9935$

Apple_Price: MAE = 7.41, RMSE = 7.98, MAPE = 0.19%, $R^2 = 0.9921$

Meta_Price: MAE = 9.39, RMSE = 10.84, MAPE = 0.13%, $R^2 = 0.9981$

Google_Price: MAE = 19.72, RMSE = 21.42, MAPE = 0.29%, $R^2 = 0.9927$

Microsoft_Price: MAE = 6.38, RMSE = 6.91, MAPE = 0.13%, $R^2 = 0.9940$

Netflix_Price: MAE = 6.57, RMSE = 7.19, MAPE = 0.09%, $R^2 = 0.9955$

Nvidia_Price: MAE = 9.94, RMSE = 10.90, MAPE = 0.17%, $R^2 = 0.9954$

Interpretación por métrica:

- Amazon tiene MAE = 1.74 → en promedio, el modelo se equivoca **\$1.74** por día en el precio.
- Tesla RMSE = 5.79 → errores grandes son más relevantes, pero sigue siendo bajo.
- Todos los MAPE son menores al 0.3%, lo que indica altísima precisión relativa.
- Todos los $R^2 > 0.97$ → el modelo explica más del 97% de la variabilidad → excelente ajuste.

Interpretación por acción:

- Amazon (MAE 1.74, R^2 0.9752) → Muy buen ajuste, errores pequeños.
- Tesla (MAE 5.31, R^2 0.9935) → Excelente ajuste, aunque error absoluto algo mayor (posible volatilidad).
- Apple (MAE 7.41, R^2 0.9921) → Buen ajuste, error absoluto más alto (quizás precios más altos).
- Meta (MAE 9.39, R^2 0.9981) → Ajuste casi perfecto, aunque error absoluto alto.
- Google (MAE 19.72, R^2 0.9927) → Error absoluto más alto, pero sigue siendo muy preciso en términos relativos (MAPE 0.29%).
- Netflix y Nvidia → Muy buenos resultados, errores bajos y R^2 altísimo.

Conclusión según las métricas:

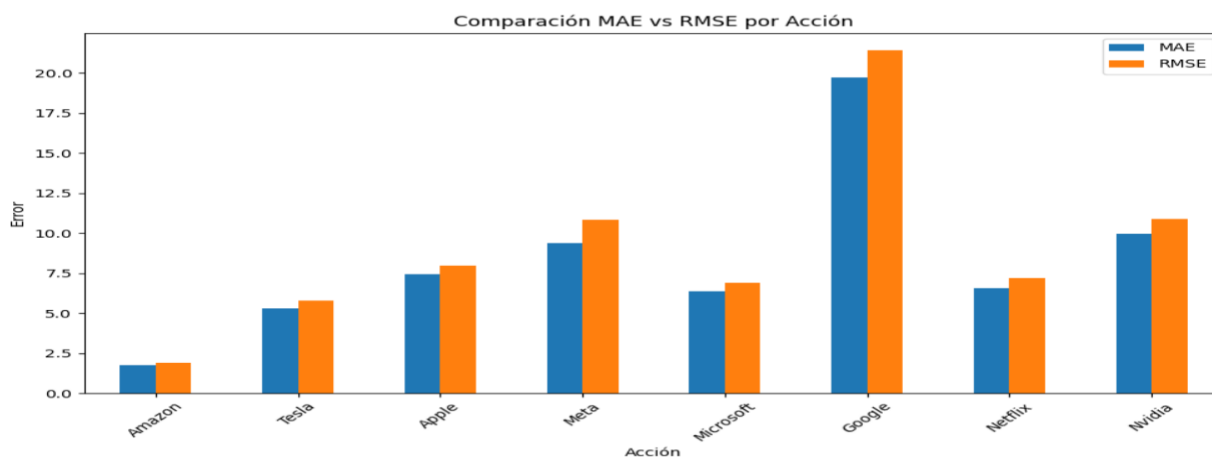
- El modelo es muy preciso en términos porcentuales ($MAPE < 0.3\%$), lo que es excelente para predicciones financieras.
- Los errores absolutos dependen del precio base: Google tiene precios altos, por eso MAE y RMSE son mayores.

Código para Generar los Gráficos de Barras MAE y RMSE.

```
df = pd.DataFrame(data)

# Gráfico de barras para MAE y RMSE
df.plot(x='Acción', y=['MAE', 'RMSE'], kind='bar', figsize=(10,6), color=['#1f77b4', '#ff7f0e'])
plt.title('Comparación MAE vs RMSE por Acción')
plt.ylabel('Error')
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
```

Gráfico de Barras MAE vs RMSE.



Interpretación:

- Para todas las acciones, $RMSE > MAE$, lo cual es normal porque RMSE amplifica errores grandes.
- Google destaca con los errores más altos ($MAE \approx 20$, $RMSE \approx 21$), lo que indica que sus precios son más altos y/o más volátiles.

- Amazon tiene los errores más bajos ($MAE \approx 2$, $RMSE \approx 2$), lo que sugiere alta estabilidad y buena predicción.
- El resto (Tesla, Apple, Meta, Microsoft, Netflix, Nvidia) están en un rango intermedio, con errores absolutos entre 5 y 11.


Conclusión del gráfico:

- El modelo predice muy bien en términos relativos, pero acciones con precios altos (Google, Meta) muestran errores absolutos mayores.

Código para Generar Gráfico MAPE.

```
# Gráfico para MAPE
plt.figure(figsize=(10,6))
plt.bar(df['Acción'], df['MAPE'], color='#2ca02c')
plt.title('MAPE por Acción (%)')
plt.ylabel('MAPE (%)')
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
```

Gráfico MAPE.



Interpretación:

- Todos los MAPE son menores al 0.3%, lo que es excelente.
- Google tiene el mayor MAPE ($\approx 0.29\%$), confirmando que es la más difícil de predecir en términos relativos.
- Netflix tiene el menor MAPE ($\approx 0.09\%$), lo que indica que es la más predecible.

- Las demás acciones están entre 0.12% y 0.19%, lo que sigue siendo muy bueno.

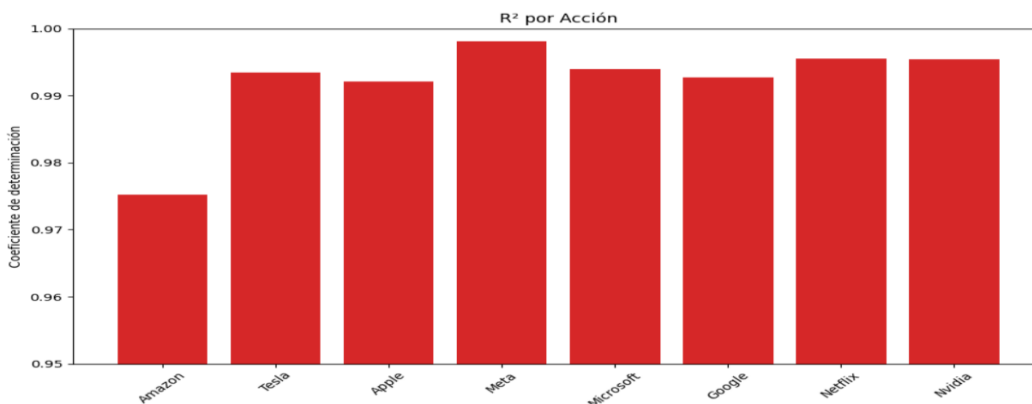
Conclusión de la gráfica:

- Aunque Google tiene errores absolutos altos y el mayor MAPE, sigue siendo muy preciso (<0.3%).
- Netflix es la más confiable en predicción relativa.

Código para Generar Gráfico R2.

```
# Gráfico para R2
plt.figure(figsize=(10,6))
plt.bar(df['Acción'], df['R2'], color='#d62728')
plt.title('R2 por Acción')
plt.ylabel('Coeficiente de determinación')
plt.xticks(rotation=45)
plt.ylim(0.95, 1.0)
plt.tight_layout()
plt.show()
```

Gráfico de Barras R2 por Acción.



Interpretación:

- Meta tiene el valor más alto, cercano a 1.00, lo que indica que el modelo Prophet predice sus precios con altísima precisión.
- Tesla, Apple, Microsoft, Google, Netflix y Nvidia también presentan valores superiores a 0.99, lo que significa un ajuste excelente.

- Amazon es la más baja, con un R^2 alrededor de 0.975, que sigue siendo muy bueno, pero indica que el modelo explica ligeramente menos la variabilidad en comparación con las otras acciones.

Conclusión de la gráfica:

El modelo Prophet está funcionando muy bien para todas las acciones, con diferencias mínimas.

Incluso el valor más bajo (Amazon) sigue siendo superior a 0.97, lo que es considerado un ajuste sobresaliente en predicciones financieras.

- Impresión de predicciones futuras en consola.

Código para Imprimir Predicciones Futuras.

```
# Mostrar predicciones futuras
print("\nÚltimas predicciones futuras por acción:")
for stock, prediction in future_predictions.items():
    print(f"\n{stock}:")
    print(prediction.to_string(index=False))
```

Resultado de Predicción.

Amazon_Price:		Tesla_Price:		Apple_Price:	
ds	yhat	ds	yhat	ds	yhat
2023-11-03	1530.972402	2023-11-03	3867.355679	2023-11-03	4062.301208
2023-11-04	1531.220615	2023-11-04	3868.876234	2023-11-04	4064.212913
2023-11-05	1531.469024	2023-11-05	3870.398175	2023-11-05	4066.126568
2023-11-06	1531.717294	2023-11-06	3871.918855	2023-11-06	4068.038655
2023-11-07	1531.965076	2023-11-07	3873.435523	2023-11-07	4069.945528
2023-11-08	1532.212009	2023-11-08	3874.945399	2023-11-08	4071.843505
2023-11-09	1532.457738	2023-11-09	3876.445746	2023-11-09	4073.728968
2023-11-10	1532.701915	2023-11-10	3877.933946	2023-11-10	4075.598460
2023-11-11	1532.944216	2023-11-11	3879.407572	2023-11-11	4077.448783
2023-11-12	1533.184344	2023-11-12	3880.864455	2023-11-12	4079.277084

Meta_Price:		Google_Price:		Microsoft_Price:	
ds	yhat	ds	yhat	ds	yhat
2023-11-03	7736.736409	2023-11-03	6979.991571	2023-11-03	5119.843563
2023-11-04	7742.047348	2023-11-04	6985.389826	2023-11-04	5121.740708
2023-11-05	7747.361618	2023-11-05	6990.791884	2023-11-05	5123.639534
2023-11-06	7752.671148	2023-11-06	6996.187912	2023-11-06	5125.536781
2023-11-07	7757.967626	2023-11-07	7001.567793	2023-11-07	5127.429073
2023-11-08	7763.242722	2023-11-08	7006.921404	2023-11-08	5129.312999
2023-11-09	7768.488314	2023-11-09	7012.238891	2023-11-09	5131.185206
2023-11-10	7773.696716	2023-11-10	7017.510942	2023-11-10	5133.042493
2023-11-11	7778.860888	2023-11-11	7022.729047	2023-11-11	5134.881896
2023-11-12	7783.974644	2023-11-12	7027.885744	2023-11-12	5136.700772

Netflix_Price:		Nvidia_Price:	
ds	yhat	ds	yhat
2023-11-03	7127.761188	2023-11-03	6194.020024
2023-11-04	7130.029700	2023-11-04	6197.454322
2023-11-05	7132.300343	2023-11-05	6200.891099
2023-11-06	7134.569374	2023-11-06	6204.324451
2023-11-07	7136.832906	2023-11-07	6207.748292
2023-11-08	7139.087013	2023-11-08	6211.156514
2023-11-09	7141.327838	2023-11-09	6214.543152
2023-11-10	7143.551694	2023-11-10	6217.902549
2023-11-11	7145.755164	2023-11-11	6221.229515
2023-11-12	7147.935201	2023-11-12	6224.519468

Justificación: Presentar resultados de forma clara y visual.