



**Facultad  
de  
Ciencias**

**PREDICCIÓN DE PRECIOS DE  
ACTIVOS FINANCIEROS  
EMPLEANDO APRENDIZAJE  
AUTOMÁTICO**

**(FINANCIAL ASSET PRICE PREDICTION USING MACHINE  
LEARNING)**

Trabajo de Fin de Máster  
para acceder al

**MÁSTER INTERUNIVERSITARIO (UC-UIMP) EN  
DATA SCIENCE**

Autor: Samuel Valer Nasta  
Director: Diego García Saiz  
Co-director: Carlos López Gutiérrez  
Junio - 2023

# Índice

<b>1. Introducción</b>	<b>6</b>
1.1. Objetivos e hipótesis . . . . .	6
1.2. Estructura del documento . . . . .	6
<b>2. Estado del arte</b>	<b>7</b>
2.1. Contexto y motivación . . . . .	8
2.2. Técnicas y métodos de inteligencia artificial para la predicción de precios . . . . .	10
<b>3. Metodología</b>	<b>12</b>
3.1. Software empleado . . . . .	13
3.2. Selección de datos . . . . .	13
3.3. Preprocesamiento de los datos . . . . .	15
3.4. Algoritmos de aprendizaje automático empleados . . . . .	15
3.4.1. Regresión lineal . . . . .	15
3.4.2. Máquinas de vector soporte para la regresión . . . . .	16
3.4.3. Redes neuronales RNN (LSTM y GRU) . . . . .	16
3.5. Entrenamiento de modelos . . . . .	18
3.6. Evaluación de los modelos . . . . .	18
<b>4. Trabajo realizado</b>	<b>19</b>
4.1. Análisis exploratorio de los datos . . . . .	19
4.1.1. Histórico de precios . . . . .	20
4.1.2. Índice de volatilidad . . . . .	22
4.2. Datos de entrenamiento y evaluación . . . . .	23
4.3. Proceso de diseño de los modelos . . . . .	23
4.3.1. Regresión Lineal . . . . .	24
4.3.2. Máquinas de vector soporte para la regresión . . . . .	24
4.3.3. Redes neuronales . . . . .	25
4.4. Resultados de la evaluación de los modelos . . . . .	28
4.4.1. Regresión Lineal . . . . .	29
4.4.2. Máquinas de vector soporte para la regresión . . . . .	32
4.4.3. Redes neuronales . . . . .	35
4.5. Comparación de resultados . . . . .	43
4.5.1. Variantes de datos . . . . .	43
4.5.2. Modelos . . . . .	44
4.5.3. Activos . . . . .	45
<b>5. Conclusiones</b>	<b>46</b>

<b>6. Líneas futuras</b>	<b>47</b>
<b>7. Bibliografía</b>	<b>48</b>
7.1. Documentos . . . . .	48

## Imágenes

- [1](#) Ciclo de un proyecto de ciencia de datos: Gráfico obtenido del artículo [\[1\]](#).
- [2](#) Gráfico de líneas: Gráfico de líneas con los precios de diferentes activos financieros creado empleando Python y librerías de representación gráfica.
- [3](#) Gráfico de volatilidad agrupada cada 10 días: Gráfico de líneas con los índices de volatilidad de cada activo financiero agrupados en ventanas de 10 días creado empleando Python y librerías de representación gráfica.
- [4](#) Gráfico con las predicciones del modelo de Regresión Lineal sobre los conjuntos de test: creado empleando Python y librerías de representación gráfica
- [5](#) Gráfico con las predicciones en cadena de los siguientes 10 días usando Regresión Lineal: creado empleando Python y librerías de representación gráfica.
- [6](#) Gráfico con las predicciones del modelo Máquinas de vector soporte para la regresión sobre los conjuntos de test: creado empleando Python y librerías de representación gráfica
- [7](#) Gráfico con las predicciones en cadena de los siguientes 10 días usando Máquinas de vector soporte para la regresión: creado empleando Python y librerías de representación gráfica.
- [8](#) Gráfico con las predicciones del modelo que emplea redes neuronales de tipo LSTM sobre los conjuntos de test: creado empleando Python y librerías de representación gráfica
- [9](#) Gráfico con las predicciones en cadena de los siguientes 10 días usando redes neuronales de tipo LSTM: creado empleando Python y librerías de representación gráfica.
- [10](#) Gráfico con las predicciones del modelo que emplea redes neuronales de tipo GRU sobre los conjuntos de test: creado empleando Python y librerías de representación gráfica
- [11](#) Gráfico con las predicciones en cadena de los siguientes 10 días usando redes neuronales de tipo GRU: creado empleando Python y librerías de representación gráfica.
- [12](#) Gráfico con las predicciones del modelo que emplea redes neuronales de tipo LSTM y GRU sobre los conjuntos de test: creado empleando Python y librerías de representación gráfica
- [13](#) Gráfico con las predicciones en cadena de los siguientes 10 días usando redes neuronales de tipo LSTM y GRU: creado empleando Python y sus librerías.

## Cuadros

- 1 Cuadro con los parámetros óptimos resultantes al aplicar GridSearchCV a los distintos datos de entrenamiento con máquinas de vector soporte para la regresión.
- 2 Cuadro con los parámetros óptimos resultantes al aplicar GridSearchCV a los distintos datos de entrenamiento con redes neuronales de tipo LSTM.
- 3 Cuadro con los parámetros óptimos resultantes al aplicar GridSearchCV a los distintos datos de entrenamiento con redes neuronales de tipo GRU.
- 4 Cuadro con los parámetros óptimos resultantes al aplicar GridSearchCV a los distintos datos de entrenamiento con redes neuronales de tipo LSTM y GRU.
- 5 Cuadro con los resultados de las métricas de evaluación usando regresión lineal sobre el conjunto de test.
- 6 Cuadro con los resultados de las métricas de evaluación usando regresión lineal aplicada la predicción en cadena de los próximos 10 días.
- 7 Cuadro con los resultados de las métricas de evaluación usando máquinas de vector soporte para la regresión sobre el conjunto de test.
- 8 Cuadro con los resultados de las métricas de evaluación usando máquinas de vector soporte para la regresión aplicadas a la predicción en cadena de los próximos 10 días.
- 9 Cuadro con los resultados de las métricas de evaluación usando redes neuronales LSTM sobre el conjunto de test.
- 10 Cuadro con los resultados de las métricas de evaluación usando redes neuronales LSTM aplicadas a la predicción en cadena de los próximos 10 días.
- 11 Cuadro con los resultados de las métricas de evaluación usando redes neuronales GRU sobre el conjunto de test.
- 12 Cuadro con los resultados de las métricas de evaluación usando redes neuronales GRU aplicadas a la predicción en cadena de los próximos 10 días.
- 13 Cuadro con los resultados de las métricas de evaluación usando redes neuronales LSTM y GRU sobre el conjunto de test.
- 14 Cuadro con los resultados de las métricas de evaluación usando redes neuronales LSTM y GRU aplicadas a la predicción en cadena de los próximos 10 días.

## Resumen

En este documento se presenta un estudio sobre la predicción de las tendencias y el precio de diferentes activos financieros empleando modelos de inteligencia artificial. El objetivo principal de este trabajo es comprobar si, en base a los precios diarios de un activo como datos de entrenamiento para un modelo de inteligencia artificial es posible determinar la tendencia de sus precios. Los resultados obtenidos muestran que los modelos de aprendizaje automático son capaces realizar la tarea propuesta con una precisión aceptable, y que algunos algoritmos obtienen un mejor rendimiento con respecto a los demás. Este estudio puede tener implicaciones importantes en la toma de decisiones en los mercados financieros y en la gestión de riesgos de inversión, ya que los modelos entrenados podrían utilizarse como indicadores financieros.

**PALABRAS CLAVE:** inteligencia artificial, predicción de tendencias, aprendizaje automático, mercados financieros, gestión de riesgos, red neuronal, máquina de vector soporte, regresión lineal.

## Abstract

This paper presents a study on trends and prices predictions of different financial assets using artificial intelligence models. The main objective of this document is to check if by using the daily prices of an asset as training data for an artificial intelligence model it is possible to determine the trend of its prices. The results obtained show that machine learning models are able to perform the proposed task with acceptable accuracy, and that some algorithms perform better than others. This study may have important implications for decision making in financial markets and investment risk management, since the trained models could be used as financial indicators.

**KEYWORDS:** artificial intelligence, trend prediction, machine learning, financial markets, risk management, neural network, support vector machine, linear regression.

---

# 1. Introducción

Un ciclo de mercado resulta fácilmente visible en el histórico del precio de un activo [2], no obstante, la identificación del inicio y el final de las fases de estos fenómenos económicos resulta una tarea complicada. Los *traders*<sup>1</sup> más vanguardistas utilizan una amplia variedad de métricas y señales para intentar predecir las tendencias y ciclos de un activo y con ello respaldar sus decisiones financieras para obtener beneficios. En este documento se quiere probar si es posible emplear modelos de inteligencia artificial como indicadores de las tendencias de mercado.

## 1.1. Objetivos e hipótesis

Este trabajo final de máster tiene como objetivo principal determinar qué algoritmos de aprendizaje automático se comportan mejor a la hora de realizar predicciones en torno a los ciclos de mercado de un activo financiero en base solamente al histórico de sus precios de cierre ajustados. Más concretamente, se quiere determinar la dirección del precio de cierre futuro de un activo en las dos semanas siguientes con el fin de poder establecer precios objetivo a corto plazo. Para ello, se empleará una ventana de precios ajustados como variable de entrada, esta, contendrá los precios de los días anteriores.

Como parte del objetivo principal de este trabajo, se intentará determinar si mediante el uso de diferentes modelos de aprendizaje automático es posible predecir el precio de un activo de manera precisa, medir la calidad de estas predicciones y realizar una comparación entre las predicciones de diferentes activos.

Debido a lo anterior, la hipótesis principal de este documento resulta ser: *¿Es posible predecir de manera aproximada el precio futuro de activo y con ello determinar el tipo de tendencia a corto plazo en la que se encuentra mediante el uso de aprendizaje automático?*

## 1.2. Estructura del documento

Este trabajo final de máster se divide en tres bloques generales.

Inicialmente, el documento presenta una breve investigación sobre los avances más recientes realizados en torno a la predicción del precio de activos financieros. Se presentan las diferentes técnicas más utilizadas actualmente junto con las métricas de evaluación más adecuadas para este tipo de tareas. Todo esto se encuentra expuesto en la sección 2.

---

<sup>1</sup>Del inglés, inversor. Dícese de una persona que obtiene rentabilidad al realizar operaciones de compra y venta de activos en los mercados financieros y bursátiles.

---

En segundo lugar, se explica la metodología seguida a la hora de seleccionar y preparar los datos para el entrenamiento y la evaluación de los diferentes modelos. En esta parte también se justifican las diferentes decisiones técnicas tomadas. Esta parte del documento figura en las secciones 3 y 4.

Por último, los resultados obtenidos se presentan y discuten en las secciones 5 y 6. En este bloque se enuncia las conclusiones del trabajo realizado y el potencial trabajo a realizar en el futuro.

Cabe mencionar que todo el código empleado en este documento se encuentra publicado en el siguiente repositorio de carácter público:

<https://github.com/samuelvaler/TFM-PRICE-PREDICTION>

## 2. Estado del arte

Para entender este documento, resulta crucial conocer bien una serie de términos financieros relacionados con el documento, por ello, primero es conveniente aportar una definición clara de estos términos por separado.

**Aprendizaje automático:** cuando hablamos de aprendizaje automático nos referimos a una rama de la inteligencia artificial que aprende al analizar datos y posteriormente genera su propia decisión por medio de algoritmos, es decir, su razonamiento en la resolución de tareas involucra características de la inteligencia humana [3]. Las técnicas de aprendizaje automático emplean sistemas de reconocimiento de patrones que permiten a las computadoras aprender de los errores y predecir resultados.

**Activo financiero:** Un activo financiero es un instrumento financiero que otorga a su comprador el derecho a recibir ingresos futuros por parte del vendedor; es decir, es un derecho sobre los activos reales del emisor y sobre el efectivo que generen [4]. Los activos financieros son emitidos o creados por entidades tales como empresas, gobiernos o instituciones financieras y pueden ser comprados, vendidos o negociados en mercados financieros. Acciones, bonos, opciones, futuros, divisas, entre otros, son algunos ejemplos de activos financieros y cada uno de ellos tiene características específicas y puede tener diferentes niveles de riesgo, rendimiento y liquidez.

**Tendencia de mercado:** Se entiende como tendencia a la trayectoria que sigue el precio de un activo financiero a lo largo de un periodo de tiempo determinado. Las tendencias pueden ser alcistas (el precio del activo aumenta su valor), laterales (el precio se mantiene) o bajistas (el precio del activo disminuye) y a su vez pueden clasificarse en:

- **Primaria:** Es la tendencia principal y la más importante. Suele durar varios meses y están compuestas por varias tendencias secundarias.

- **Secundaria:** Van en dirección contraria a la tendencia primaria y pueden durar de tres semanas a tres meses.
- **Terciaria:** Tienen una dirección contraria a las tendencias secundarias y no llegan a durar ni tres semanas.

**Ciclo de mercado:** Un ciclo de mercado se refiere a las fluctuaciones recurrentes y periódicas que experimenta una economía a lo largo de un periodo de tiempo marcado. Un ciclo de mercado se caracteriza por cuatro fases básicas [5]:

- **Acumulación:** Esta fase se da cuando el mercado ha alcanzado sus niveles más bajos durante la fase bajista y llegan empiezan a llegar compradores.
- **Tendencia alcista o fase de expansión:** Es el estado de consolidación de un mercado. El número de compradores es alto y se ve incrementado diariamente por ello la cima del mercado se da en esta fase.
- **Distribución:** En esta etapa el numero de vendedores es el que incrementa por lo que el sentimiento financiero cambia. Los movimientos económicos y noticias negativas influyen sobre el mercado de manera directa.
- **Fase bajista:** En esta fase hay una gran negatividad y sentimiento de inestabilidad en el mercado por lo que las ventas aumentan aún más llegando el precio a desplomarse en algunos activos.

**Análisis técnico:** Se entiende como el estudio de patrones, tendencias y datos históricos del precio y del volumen de negociación de un activo para predecir su comportamiento futuro. Este tipo de análisis se utiliza principalmente para respaldar la toma de decisiones de compra y venta. Está basado en la premisa de que los precios pasados y los patrones repetitivos pueden brindar información sobre la dirección futura del precio.

En este documento se va a tratar de predecir las direcciones de las tendencias terciarias de varios activos financieros. Esta tarea tiene un alto interés, ya que puede servir para determinar señales de compra o venta con el fin de maximizar beneficios. El objetivo no resulta algo trivial ya que las relaciones entre los precios de un activo no son lineales y muchas veces estos precios dependen de varios factores económicos externos a la hora de determinar su valor.

## 2.1. Contexto y motivación

Desde siempre, los precios de los activos financieros en el mercado de valores se han ligado a una serie de tendencias o patrones por medio el análisis técnico [6]. Estas tendencias se ven afectadas tanto por el contexto histórico económico de la época.

Un claro ejemplo de esto es el confinamiento a causa del *SARS Co-V-2*<sup>2</sup> sufrido el 2020, cuando se declaró el estado de alarma el precio del *IBEX35*<sup>3</sup> se desplomó.

El precio de un activo financiero se mueve en ciclos de mercado. Estas fases de mercado son cíclicas y pueden durar semanas, meses o incluso años y tampoco siguen ningún patrón que facilite su identificación con certeza total [7].

Históricamente se han empleado numerosas técnicas matemáticas para estudiar los ciclos y tendencias de los precios de los activos financieros en el mercado, no obstante, estas no son muy buenas realizando predicciones a futuro [8]. Ciertos estudios han probado que son necesarios modelos capaces de predecir características no lineales para mejorar los resultados a la hora de predecir los precios a futuro [9]. Otra técnica empleada para la predicción de precios es el uso de métodos estocásticos basados en cadenas de Markov para predecir las probabilidades de que se dé un cambio en los precios [10].

Hay estudios que tratan de predecir la volatilidad de un activo mediante el uso de modelos *GARCH*<sup>4</sup> [11]. Este estudio trata de pronosticar la volatilidad diaria de los índices de diferentes mercados de valores. El resultado de este estudio indica que los modelos de volatilidad asimétrica presentan un mejor desempeño que los modelos históricos.

Debido al comportamiento no lineal de las variables económicas, desde los años 90 se han propuesto nuevos métodos basados en redes neuronales artificiales. Estas redes permiten establecer relaciones lineales y no lineales entre las entradas y salidas de un sistema, lo que las hace aplicables en mercados de alta volatilidad y en áreas de la ingeniería y los mercados donde las variables exhiben comportamientos no lineales.

En [12], se presenta una revisión inicial de las aplicaciones exitosas de las redes neuronales en las finanzas, incluyendo análisis de reportes contables, predicción de quiebras, análisis de riesgo, pronóstico de divisas y estrategias de negociación de índices financieros, entre otros. Posteriormente, se realizó una revisión actualizada de las aplicaciones de las redes neuronales en predicciones de mercados de valores, derivados, divisas y crisis financieras, destacando la superioridad de las redes neuronales en términos de rendimiento en comparación con los métodos econométricos y otros modelos lineales [13].

En los últimos años, las redes neuronales han sido utilizadas en combinación con

---

<sup>2</sup>Acrónimo de "Severe Acute Respiratory Syndrome Coronavirus." en inglés, que se traduce al español como "Coronavirus del Síndrome Respiratorio Agudo Grave".

<sup>3</sup>Principal índice bursátil de referencia de la bolsa española elaborado por Bolsas y Mercados Españoles.

<sup>4</sup>Del inglés, Generalized Autorregresive Conditional Heterocedasticity. Modelo autorregresivo con heteroelasticidad condicional.

la lógica difusa y los algoritmos genéticos. En [14] se realiza una comparación del rendimiento de una red neuro-difusa con una red neuronal en la predicción de la dirección del mercado en los índices *NASDAQ*<sup>5</sup> y *NIKKEI*<sup>6</sup>. Se encontró que una estrategia de negociación basada en la combinación de ambos modelos era superior a una estrategia de *comprar y mantener*. Además, el modelo neuro-difuso mostró una mayor precisión en la predicción de la dirección del mercado en comparación con el modelo neuronal.

Se han propuesto modelos que combinan redes neuronales con algoritmos genéticos. Se han propuesto modelos neuro-genéticos [15] para pronosticar el precio de las acciones a corto plazo en la bolsa de valores de Shenzhen, China. Este modelo combinó la capacidad de búsqueda de los algoritmos genéticos para determinar los pesos óptimos de la red neuronal. El modelo propuesto obtuvo resultados muy buenos en la predicción de los precios de las acciones en los siguientes cuatro días no obstante, las predicciones empeoraban cuando se quería predecir en temporalidades semanales.

Actualmente, ya hay varios estudios que comparan diferentes modelos y técnicas para la predicción de los precios de un activo [16], [17] y [18]. En estos documentos podemos ver cómo las redes neuronales artificiales han demostrado su aplicabilidad en la predicción de variables económicas no lineales. La combinación de redes neuronales con diferentes técnicas ha mejorado aún más el rendimiento de los modelos en términos de precisión en el pronóstico. Sin embargo, todavía existen desafíos en la definición de la estructura del modelo y la selección de parámetros óptimos, lo que requiere una investigación adicional en este campo.

## 2.2. Técnicas y métodos de inteligencia artificial para la predicción de precios

La predicción del precio de un activo resulta ser un problema no lineal en el que se emplean series temporales multivariantes [19]. Debido a lo anterior, los modelos de aprendizaje automático empleados deben ser capaces de reconocer patrones basándose en los datos de entrenamiento para poder realizar predicciones sobre nuevos datos.

Los algoritmos de aprendizaje automático pueden clasificarse en dos grupos [20]:

- **Algoritmos de aprendizaje supervisado:** Estos algoritmos se conocen por

---

<sup>5</sup>Del inglés, National Association of Securities Dealers Automated Quotations. Es una bolsa de valores electrónica en la que se negocian acciones de las principales empresas tecnológicas de Estados Unidos.

<sup>6</sup>Del japonés, Nikkei 225, comúnmente denominado índice Nikkei, es el índice bursátil más popular del mercado japonés.

emplear entradas las cuales tienen etiquetas asignadas durante su entrenamiento. El objetivo de este tipo de algoritmos es ser capaces de a partir de una entrada nueva poder predecir una etiqueta de salida.

- **Algoritmos de aprendizaje no supervisado:** Este tipo de algoritmos no emplean etiquetas para los datos de entrenamiento sino que a raíz de los propios datos se intentan encontrar características comunes para clasificarlos.

La propia naturaleza del problema nos dice que a la hora de intentar predecir precios de activos financieros nos estamos enfrentando ante un problema de aprendizaje supervisado ya que tenemos una serie de entradas (los precios anteriores) y una serie de etiquetas para cada una de ellas (los precios del día siguiente).

Algunos de los modelos de aprendizaje supervisado más utilizados son [21]:

- **Regresión lineal:** Se utiliza para predecir una variable numérica continua (variable dependiente) en función de una o más variables explicativas (variables independientes), mediante una ecuación lineal. Las relaciones entre variables que establece son lineales.
- **Gradient Boosting:** Es una técnica de aprendizaje automático que utiliza árboles de decisión para crear un modelo predictivo más robusto. Se basa en la idea de ir ajustando el modelo en cada iteración para corregir los errores del modelo anterior.
- **Máquinas de vector soporte:** es un algoritmo de aprendizaje supervisado que se utiliza para clasificación y regresión. El objetivo del algoritmo es encontrar el hiperplano que mejor separa los datos en diferentes clases o que mejor se ajusta a los datos para la regresión.
- **Redes Neuronales Artificiales:** Es un conjunto de algoritmos y técnicas de aprendizaje automático que se inspiran en la estructura y funcionamiento del cerebro humano para procesar información. Consiste en una red de nodos interconectados, llamados neuronas artificiales, que realizan operaciones matemáticas para procesar la información.

En este documento se utilizarán algunos de estos algoritmos y derivados de los mismos para tratar de predecir el precio futuro de un activo financiero.

---

### 3. Metodología

En esta sección se va a exponer y justificar la metodología seguida a la hora de realizar la selección de datos, los entrenamientos de los modelos y las diferentes evaluaciones de los mismos.

La metodología seguida en este proyecto aparece reflejada en la figura 1 obtenida de [1]. Esta metodología se caracteriza por seguir los pasos básicos de un proyecto de ciencia de datos.



Figura 1: Gráfico con un esquema del proceso de un proyecto de ciencia de datos.

Como podemos ver en la figura anterior, lo primero que se hace es recoger los datos y prepararlos para el entrenamiento y la prueba de los modelos, acto seguido realizan los entrenamientos y la evaluación de los modelos para luego visualizar e interpretar los resultados.

### 3.1. Software empleado

La obtención de los datos, la creación de modelos y la realización del código para este trabajo son tareas que se han llevado a cabo empleando íntegramente el lenguaje de programación Python. Se ha elegido este lenguaje de programación debido a su potencia y sencillez para el tratamiento de datos y la creación de modelos de aprendizaje automático. Junto con Python 3.10.11 se han empleado las siguientes bibliotecas:

- **Yfinance**[22]: *Yahoo Finance* Emplea esta *API*<sup>7</sup> para compartir diferentes datos sobre los precios de los activos de los cuales proporciona seguimiento. Esta herramienta es la fuente de los históricos de los precios de los activos empleados para entrenar los diferentes modelos de aprendizaje automático.
- **Matplotlib**[23] y **Seaborn**[24]: Ambas son bibliotecas destinadas a la representación gráfica. En este trabajo se han empleado para la representación gráfica de los datos y para realizar análisis gráficos.
- **Pandas**[25] y **Numpy**[26]: NumPy es una biblioteca que se utiliza para trabajar con matrices y arreglos multidimensionales, mientras que Pandas, por otro lado, es una biblioteca que se utiliza para manipular y analizar datos estructurados. Ambas bibliotecas se han empleado para la manipulación y el tratamiento previo de los datos.
- **Sklearn**[27]: Esta biblioteca se emplea para tareas de aprendizaje automático. En este trabajo se ha usado para la implementación de los diferentes algoritmos de aprendizaje automático y para el posterior análisis de la calidad de sus predicciones.

### 3.2. Selección de datos

Como ya se ha mencionado previamente, para la obtención de datos se han usado la API de *Yahoo Finance*. Mediante el uso de la función *download* se han cargado los datos de diferentes activos financieros. Cada activo elegido opera en mercados diferentes para así poder evaluar el rendimiento de los modelos en varios mercados y asegurar una baja correlación entre los mismos. Los activos elegidos son los siguientes:

- **Tesla (TSLA)**: Es una empresa estadounidense de vehículos eléctricos y energía limpia que opera en bolsa de valores *NASDAQ*, en el mercado estadounidense.

---

<sup>7</sup>Del inglés, Application Programming Interface que significa interfaz de programación de aplicaciones. Una API es una interfaz que permite que diferentes aplicaciones se comuniquen entre sí y compartan información de manera estandarizada y segura.

- **S&P 500 (GSPC):** Se trata de un índice bursátil estadounidense que representa a las 500 mayores empresas cotizadas en la bolsa de valores de Nueva York y en el NASDAQ.
- **Bitcoin (BTC-USD):** Se caracteriza por ser una moneda digital descentralizada, lo que significa que no está controlada por ningún gobierno o institución financiera centralizada. Debido a lo anterior opera en un mercado descentralizado de criptomonedas, que permite a los usuarios comprar, vender y negociar con distintas criptomonedas. Este mercado funciona las 24 horas del día, los 7 días de la semana.
- **Petróleo (CL=F):** Es un recurso natural no renovable que se utiliza ampliamente como fuente de energía en todo el mundo. Se negocia en varias bolsas de valores en todo el mundo, incluyendo la Bolsa de Nueva York, la Bolsa de Londres y la Bolsa de Tokio.

La API empleada nos proporciona un conjunto de datos con los precios, en dólares, de cada activo en intervalos diarios durante el período de actividad de su sesión correspondiente en la bolsa de valores:

- **Open:** Representa el precio inicial que tenía el activo a la hora de apertura de la sesión. Este precio no tiene por qué coincidir con el precio de cierre del día anterior.
- **High:** Este precio resulta ser el valor máximo alcanzado durante la sesión.
- **Low:** Se conoce como el valor mínimo alcanzado durante la sesión.
- **Close:** Representa el precio final que tenía el activo al cierre de la sesión.
- **Adj Close:** Es el precio de cierre de una acción después de los pagos de dividendos y otras distribuciones de efectivo realizadas por la empresa; en algunos casos, se corresponde con el precio de cierre.
- **Volume:** Es la medida de la cantidad de actividad de negociación que ha tenido una acción en la sesión; mide el volumen tanto de las ventas como de las compras.

De todos los precios diferentes proporcionados, se ha decidido emplear *Adj Close* debido a que este precio es el precio de cierre tras contabilizar las acciones corporativas por lo que se le considera el precio real de la acción. Este precio es el utilizado para estimar los rendimientos históricos y sus análisis. Las acciones corporativas son eventos o decisiones que toma una empresa y que tienen un impacto en la estructura de su capital, la propiedad de la empresa y/o los derechos de los accionistas. Las acciones corporativas pueden incluir desde la emisión de más acciones, el pago de

dividendos, la división de acciones, las fusiones y adquisiciones, e incluso la recompra de acciones [28].

Finalmente cabe mencionar que los precios de todos los activos excepto el de Bitcoin, vienen dados en secuencias de 5 días ya que los mercados no abren los fines de semana.

### 3.3. Preprocesamiento de los datos

Tanto para la predicción de precios como para la evaluación de los modelos se ha decidido emplear todos los datos existentes desde el 1 de enero de 2010 al 2 de mayo del año 2023. En primera instancia se decidió eliminar los datos relativos al año 2020 ya que durante este año el mercado de valores sufrió múltiples bajadas seguidas de recuperaciones debidas a una situación atípica a nivel global causada por el virus SARS Co-V-2 no obstante tras probar a entrenar modelos con y sin los datos de este año se ha comprobado que no hay influencia negativa por lo que los datos de este periodo no han sido considerados valores atípicos.

A la hora de obtener los datos, tan solo ha sido necesario eliminar las columnas que no contienen el precio de cierre ajustado, ya que la API empleada no devuelve ningún valor nulo, debido a que los activos elegidos cotizan en grandes mercados, pero de haberlos, se usaría el precio de cierre del día anterior o el de la media móvil para completar los conjuntos de datos.

El único tratamiento aplicado a los datos ha sido el escalado de los precios para que tomen un valor comprendido entre 0 y 1. Se ha decidido emplear esta técnica debido a que puede ayudar a mejorar la precisión y el rendimiento de los modelos, mejorando así su convergencia de los mismos y reduciendo así los tiempos de entrenamiento.

### 3.4. Algoritmos de aprendizaje automático empleados

En este apartado se van a exponer y justificar los diferentes modelos entrenados para la predicción de precios.

#### 3.4.1. Regresión lineal

La regresión lineal es un modelo estadístico que trata de buscar relaciones lineales entre los datos de entrada y salida. La idea detrás de este tipo de modelo es encontrar la mejor línea recta que se ajuste a los datos observados. Esto se logra estimando los coeficientes de una ecuación lineal y evaluando el modelo utilizando diferentes métricas que indican lo bien que se ajusta al problema [29].

Se trata de un modelo sumamente sencillo de implementar y arroja muy buenos resultados en gran variedad de problemas. A pesar de que las relaciones entre las

variables dependientes e independientes en la predicción de precios de activos no son puramente lineales la regresión lineal resulta un buen modelo de referencia ya que el resto de modelos deberán mejorar su precisión debido a su mayor complejidad. Para entrenar este modelo ni siquiera ha hecho falta el uso de parámetros.

#### 3.4.2. Máquinas de vector soporte para la regresión

Las máquinas de vector soporte para la regresión o SVR se emplean para problemas de regresión y son capaces de determinar tanto relaciones lineales y no lineales entre las variables independientes y las dependientes. Un modelo de SVR busca encontrar una función que se ajuste a los datos de entrenamiento al minimizar el error y al mismo tiempo controlar la complejidad del modelo. Utiliza funciones núcleo para mapear los datos a un espacio de mayor dimensión y se basa en los vector de soporte para establecer límites de error [30].

Este tipo de modelo emplea dos parámetros que permiten controlar la relación sesgo-varianza del modelo y su complejidad. Estos dos parámetros son:

- **C:** Este parámetro controla el margen de error permitido en el modelo. Cuanto menor sea su valor, mayor será el margen permitido. Por el contrario, si su valor es más grande el modelo se ajustará más a los datos de entrenamiento.
- **Gamma:** Define la amplitud de la función de núcleo de la máquina, controlando así la flexibilidad del modelo. Si toma un valor pequeño hará que los puntos lejanos tengan un mayor peso en el cálculo de las predicciones. Por otro lado, un valor grande de gamma hará que los puntos cercanos tengan un mayor peso en el cálculo de las predicciones.

Estos parámetros se emplean junto con diferentes tipos de funciones núcleo para tratar de encontrar relaciones entre los datos de entrada y salida.

#### 3.4.3. Redes neuronales RNN (LSTM y GRU)

Las redes neuronales artificiales son un modelo de aprendizaje automático formado por capas de nodos, que contienen una capa de entrada, una o varias capas ocultas y una capa de salida. Cada nodo, o neurona artificial, se conecta a otro y tiene un peso y un umbral asociados. Si la salida de un nodo individual está por encima del valor de umbral especificado, dicho nodo se activa y envía datos a la siguiente capa de la red. De lo contrario, no se pasan datos a la siguiente capa de la red [31].

Este tipo de modelo se divide en capas de nodo las cuales tienen dos parámetros configurables. Los parámetros de cada capa de una red neuronal son:

- **Units:** Hace referencia al número de neuronas que contiene cada capa. A más neuronas más complejo es el modelo y más tiempo de entrenamiento será

requerido.

- **Activation:** Este parámetro se refiere a la función matemática que se aplica a la salida de un nodo. Permite introducir no linealidad a las salidas de cada nodo.
- **Learning rate:** Determina cuánto se deben actualizar los parámetros de la red en función del error calculado en cada paso del entrenamiento.

Actualmente hay diferentes variantes de redes neuronales pero este documento empleará tan solo dos variantes de redes neuronales recurrentes. Este tipo de redes es más adecuado para el tipo de problema que se quiere resolver, debido a que se utilizan comúnmente en tareas de procesamiento de secuencias, como el análisis de series temporales, el procesamiento del lenguaje natural y la generación de texto. Estas arquitecturas se desarrollaron para abordar el desafío de entrenar y utilizar redes neuronales en secuencias de datos largas.

Los tipos de redes neuronales empleadas en este trabajo son las LSTM<sup>8</sup> y las GRU<sup>9</sup>. Ambas variantes son capaces de capturar relaciones a largo plazo mediante el uso de celdas de memoria que actúan como una forma de almacenamiento a largo plazo en la red neuronal y permiten que la información fluya a través del tiempo sin perder relevancia. Estos dos modelos presentan una serie de diferencias que las hace un caso de estudio interesante para el problema que se quiere abordar en este documento. Estas diferencias son [32]:

- Las redes LSTM presentan una estructura más compleja ya que emplean una celda de memoria y tres compuertas diferentes (olvido, entrada y salida) mientras que las GRU utilizan una estructura simplificada con dos compuertas (actualización y reinicio) y una celda de estado<sup>10</sup>. Todo esto hace que las redes LSTM tengan una mayor capacidad para capturar y retener relaciones a largo plazo, esto las hace computacionalmente más complejas.
- Las redes GRU combinan la información antigua y actualizan el estado de la celda de estado mediante una operación de interpolación, lo que les permite retener información relevante de una manera más directa. En cambio, las redes LSTM emplean una compuerta de olvido que controla explícitamente la cantidad de información antigua que se elimina o se mantiene en la celda de memoria.

---

<sup>8</sup>Del inglés, long short-term memory que se traduce como memoria de corto plazo

<sup>9</sup>Del inglés, gated recurrent unit que se traduce como unidad recurrente cerrada.

### 3.5. Entrenamiento de modelos

El entrenamiento de un modelo de predicción es el procedimiento mediante el cual se le suministran unas entradas y salidas relacionadas para permitirle ajustar sus parámetros internos al problema en cuestión y lograr predecir las salidas en función de las entradas.

Todos los modelos de este trabajo han sido entrenados con los mismos datos de entrenamiento. La única diferencia que presentan las variables de entrada de los diferentes modelos son el tamaño de ventana de tiempo que emplean. Algunos modelos, como la regresión lineal, no necesitan una ventana de tiempo grande para realizar las predicciones, ya que las relaciones que buscan no son tan complejas, por el contrario, hay modelos como las redes neuronales que si necesitan una ventana mayor.

Los datos de entrenamiento se corresponden con los precios de cierre diarios de una serie de activos desde enero de 2010 hasta enero de 2023. Los datos de prueba son los cierres diarios de los mismos activos desde enero de 2023 hasta mayo de ese mismo año.

Algunos de los diferentes modelos en este documento presentan una serie de parámetros configurables. Para ajustar estos parámetros se ha empleado el objeto GridSearchCV de Python. El GridSearch realiza una búsqueda exhaustiva en un espacio predefinido de combinaciones de hiperparámetros. Esencialmente, esta técnica prueba todas las combinaciones posibles de valores de hiperparámetros especificados y evalúa el rendimiento del modelo para cada combinación utilizando una métrica de evaluación, para luego devolver la combinación de parámetros que arroja mejores resultados.

### 3.6. Evaluación de los modelos

El proceso de evaluación de un modelo de inteligencia artificial consiste en determinar su capacidad de generalización y medir la calidad de sus resultados mediante la predicción de entradas nunca antes vistas. Este proceso resulta crucial a la hora de detectar problemas y limitaciones de nuestro modelo.

A la hora de validar un modelo, hay que seleccionar unas métricas de evaluación acordes con el problema que se quiere resolver. Se han empleado las mismas métricas para problemas de regresión en todos los modelos implementados, con el fin de ser capaces de compararlos entre sí. Estas métricas se caracterizan por ser las aplicadas a problemas de predicciones numéricas ya que nuestro objetivo es predecir un precio que toma un valor real. Las métricas empleadas son las siguientes: [33]

- 
- **Error cuadrático medio (*MSE*):** Es una métrica que mide el promedio de los errores al cuadrado entre los valores reales y los valores predichos. Con ella medimos la precisión de un modelo.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- **Error de raíz cuadrada media (*RMSE*):** Se calcula como la media o el promedio de las diferencias al cuadrado entre los valores objetivo predichos y esperados en un conjunto de datos. La ventaja de utilizar la raíz cuadrada es que permite dar más peso a los errores grandes. Con ella medimos la precisión de un modelo.

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- **Error absoluto medio (*MAE*):** Mide el promedio de las diferencias absolutas entre los valores reales y los valores predichos. Con ella medimos la precisión de un modelo.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- **Coefficiente de determinación ( $R^2$ ):** Es una métrica que indica la proporción de la varianza en la variable dependiente que es explicada por la variable independiente en un modelo de regresión. Su valor oscila entre 0 y 1 (puede tomar valores negativos si el ajuste es peor que el promedio), siendo 1 el valor óptimo que indica una perfecta correspondencia entre los valores reales y los valores predichos. Con esta métrica medimos la calidad del ajuste del modelo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

## 4. Trabajo realizado

En esta sección se presentará el proceso seguido a la hora de diseñar y evaluar los modelos creados siguiendo la metodología expuesta en la sección anterior.

### 4.1. Análisis exploratorio de los datos

Una tarea previa al diseño de los modelos de predicción de precios es el análisis de los datos que se van a emplear. Esta tarea permite descubrir patrones, tendencias, relaciones y posibles problemas que deben ser tratados para mejorar los resultados.

Todo el análisis realizado es sobre los precios ajustados de Tesla, el índice S&P 500, el Bitcoin y el petróleo.

#### 4.1.1. Histórico de precios

Es importante analizar el histórico de los precios para detectar patrones, tendencias y estacionalidad en los mismos. Como puede verse en la figura 2 se ha representado con un diagrama de líneas el precio de los diferentes activos desde el año 2010 hasta la actualidad.

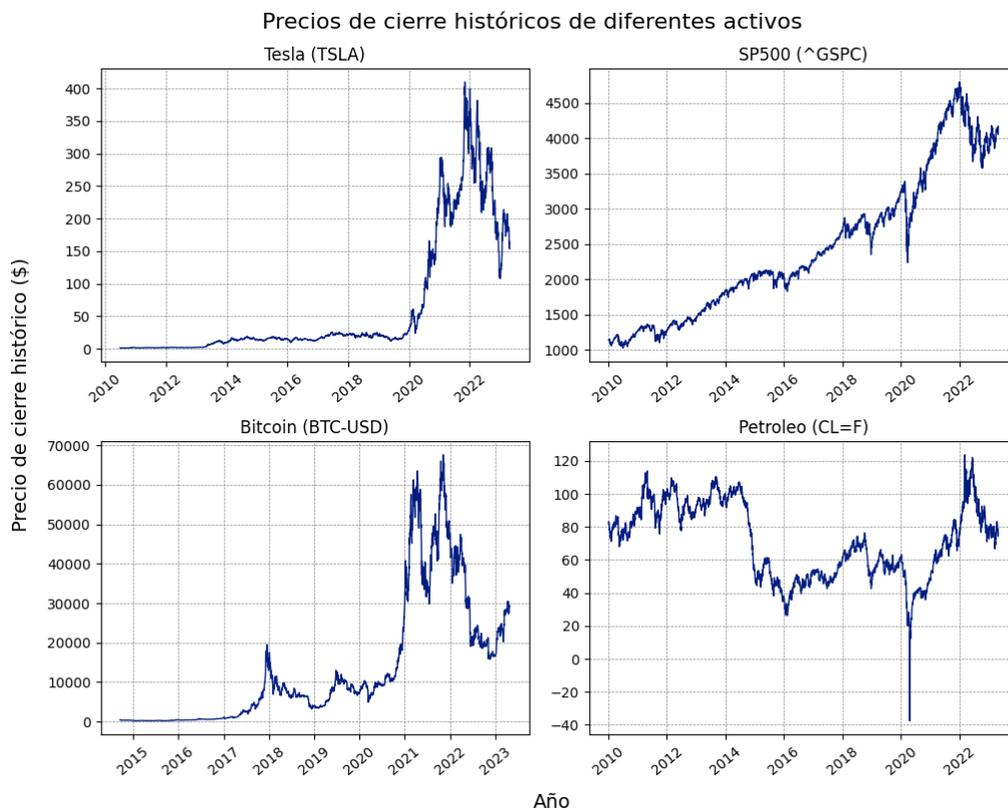


Figura 2: Gráfico de líneas con los precios de diferentes activos financieros.

Los precios de los activos son muy diferentes entre si por lo que es conveniente comentarlos uno por uno:

- **Tesla:** El precio de las acciones de Tesla ha experimentado un crecimiento excepcional desde su salida a bolsa en 2010. Podemos ver cómo a lo largo de su historia su precio ha experimentado una gran volatilidad a lo largo de los años, con períodos de fuertes subidas y correcciones significativas.

- **S&P 500:** Podemos ver como el precio de este activo muestra una tendencia alcista a largo plazo aunque experimentando una serie de correcciones. La tendencia alcista de este activo es debida al crecimiento económico dado y el éxito de las empresas que incluye el índice.
- **Bitcoin:** Al igual que ocurre con Tesla el precio de Bitcoin se ha visto exponencialmente incrementado a lo largo de su historia pero también ha sufrido correcciones significativas. Es un activo altamente volátil.
- **Petróleo:** Observando el gráfico de este activo, podemos ver que siempre se mueve en un rango que va desde los 25 dólares a los 125 dólares. A inicios del año 2020 el precio de este activo llegó a tener un valor negativo lo cual tiene sentido ya que el activo que estamos empleando es el precio de futuros del petróleo.

Algo común a los cuatro gráficos es que en el año 2020 todos sufrieron una corrección importante, esto, se debe a la crisis mundial que hubo a causa del *SARS Co-V-2*. Esto nos indica que si la situación económica mundial es crítica es posible que los precios sufran correcciones por lo que los precios dados durante esta época podrían ser considerados valores atípicos ya que no se corresponden a una situación convencional.

Por último, podemos ver que el Bitcoin presenta datos desde tan solo 2015. Esto se debe a que la API no posee los datos relativos a fechas anteriores ya que la primera cotización de este activo es posterior a la fecha inicial indicada. Se ha decidido mantener el activo a pesar de este problema en los datos ya que resulta interesante ver como se comportan los modelos elegidos dentro de un mercado relativamente nuevo.

### 4.1.2. Índice de volatilidad

Como ya hemos podido ver en el gráfico anterior los precios de algunos activos son altamente volátiles, por ello es conveniente tener en cuenta este factor al diseñar nuestros modelos. Para calcular esta métrica emplearemos el índice de volatilidad en periodos de 10 días, ya que es el tamaño de ventana que emplearemos para las predicciones. Este gráfico aparece en la figura 3.

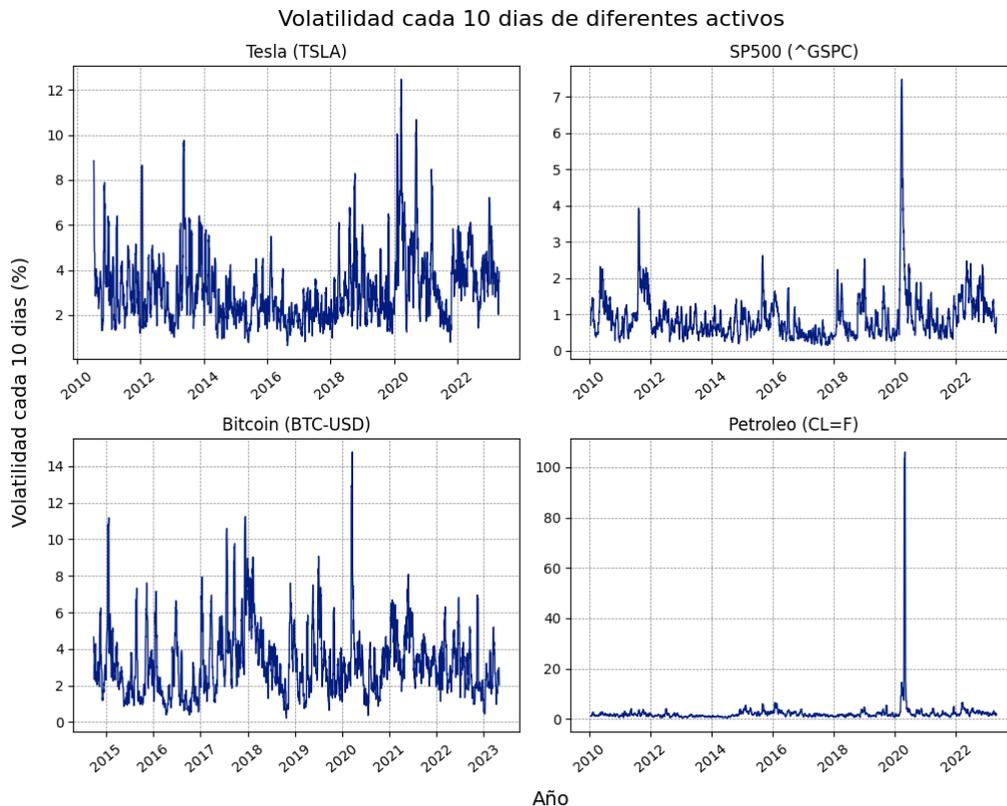


Figura 3: Gráfico con la volatilidad cada 10 días de diferentes activos.

En la figura anterior podemos ver el índice de volatilidad cada 10 días, de los cuatro activos. Este índice se calcula al obtener la desviación estándar de los cambios porcentuales de los precios.

Observando la figura obtenida podemos concluir en que Tesla y Bitcoin tienen una alta volatilidad, entre el 4% y el 6%, mientras que el S&P 500 y el petróleo presentan una volatilidad menor, entre el 1% y el 2%. Por último, vemos cómo a principios del año 2020 todos los activos presentan una volatilidad significativamente mayor que sus cifras normales.

Finalmente, debemos de tener en cuenta que cuanto más alta sea la volatilidad de un activo más variaciones habrá en los precios, por lo que será más difícil la tarea de predecir las tendencias de su valor.

## 4.2. Datos de entrenamiento y evaluación

En vista al análisis exploratorio de los datos se ha observado como en el año 2008 y el 2020 los activos presentan una alta volatilidad debida a crisis económicas a nivel mundial. Se ha decidido emplear dos conjuntos de datos diferentes a la hora de entrenar y evaluar los modelos resultando en dos versiones de cada conjunto. Los datos empleados son:

- **Variante A:** Para los entrenamientos se han usado los precios diarios desde el **1 de enero de 2010** al **1 de enero de 2019**. Para la fase de evaluación se han empleado los precios diarios comprendidos entre el **2 de mayo de 2019** hasta el **2 de Febrero de 2019**.
- **Variante B:** En los entrenamientos se han usado los precios diarios desde el **1 de enero de 2010** al **1 de enero de 2023**. Para la fase de evaluación se han empleado los precios diarios comprendidos entre el **2 de enero de 2023** hasta el **2 de mayo de 2023** ya que interesa que los datos de evaluación de esta variante sean lo más reciente posibles.

Como podemos observar la principal diferencia entre ambas variantes resulta ser que en el caso **A** se han excluido los datos relativos a los periodos de alta volatilidad para evitar su influencia en la calidad de los modelos ya que no se trata de datos “convencionales”. La segunda diferencia es que la variante **B** tiene cuatro años más de datos, esto, puede ayudar a los modelos a reconocer nuevos patrones.

Adicionalmente, se ha creado un método en Python que recibe como entrada el número de días necesarios para realizar una predicción, a partir de estos datos y una serie de predicciones en cadena se han predicho los precios correspondientes a los diez días siguientes. Estos precios se han evaluado comparándolos con los precios reales correspondientes a los días que predicen.

## 4.3. Proceso de diseño de los modelos

La primera decisión que hay que tomar a la hora de diseñar un modelo corresponde con la estructura de los datos de entrada. Para generar los conjuntos de datos con las series temporales de precios y los conjuntos de datos con los precios siguientes a cada serie se ha creado una función de Python que recibe como parámetro el número de días de la serie a generar. Este valor cambiará en función del modelo para el que se quieran preparar los datos por lo que se ha decidido ajustarlo de manera manual

para cada modelo probando diferentes valores múltiples de 5 comprendidos en el rango de 5 a 50.

Algunos modelos de aprendizaje automático tienen una serie de parámetros configurables, estos, son valores que determinan la configuración y el comportamiento del modelo a la hora de reconocer relaciones de los datos y realizar predicciones o clasificaciones. Estos parámetros son ajustables y varían según el tipo de modelo que se esté utilizando.

Existen varias técnicas a la hora de configurar los parámetros de un modelo en Python. Se ha decidido usar la técnica *grid search*<sup>10</sup>. Esta técnica realiza una búsqueda exhaustiva en una cuadrícula de valores predefinidos y evalúa el rendimiento del modelo para cada combinación usando validación cruzada. Al final, se selecciona la combinación de parámetros del modelo con mejor rendimiento.

Toda la configuración de parámetros expuesta en las siguientes subsecciones se corresponde con los datos de la **Variante B** ya que es la que mejores resultados arrojaba a la hora de predecir en la mayoría de modelos para todos los conjuntos de datos. La comparación de las diferentes variantes se estudiará más adelante en la sección 4.5 de este documento.

#### 4.3.1. Regresión Lineal

Este modelo es el más básico de los estudiados en este documento. A la hora de predecir el siguiente valor de una serie temporal tan solo se basa en el valor anterior ya que se trata de una autoregresión de orden 1. Debido a lo anterior el tamaño de las ventanas es de solo un día ya que obtiene mejores resultados en las métricas de evaluación.

#### 4.3.2. Máquinas de vector soporte para la regresión

Durante la fase de diseño de las máquinas de vector soporte para la regresión, se empleó la búsqueda GridsearchCV con una serie de parámetros elegidos intentando cubrir el mayor rango de variantes. Los parámetros empleados son los siguientes:

- **C:** 1, 10, 100, 200, 300, 500, 600, 800, 1000, 1500, 2000, 3500, 4000, 4500, 10000, 20000, 30000, 40000, 50000, 60000, 61000.
- **Gamma:** 1, 0.1, 0.2, 0.4, 0.8, 0.001, 0.002, 0.004, 0.006, 0.0008, 0.000012, 0.000013, 0.000014, 0.000015, 0.000016, 0.000017, 0.000018, 0.000019.

---

<sup>10</sup>Del inglés, búsqueda en rejilla.

Los parámetros anteriores se emplearon junto con funciones núcleo de tipo *RBF*<sup>11</sup> o lineal según el mejor resultado que arroje el modelo. El primer tipo de función núcleo es capaz de modelar relaciones no lineales entre variables mientras que el segundo es más adecuado para determinar relaciones lineales.

Las configuraciones óptimas de parámetros se obtuvieron con la métrica  $R^2$  y una validación cruzada de 3 pliegues para los diferentes conjuntos de datos aparecen en el cuadro 1.

Activo	C	Gamma	Núcleo	$R^2$
Tesla	200	0.006	rbf	0.9849
S&P 500	1	1	rbf	0.9834
Bitcoin	61000	1.4e-05	rbf	0.9771
Petróleo	4000	1.8e-05	rbf	0.9782

Cuadro 1: Parámetros óptimos para cada conjunto de datos.

En el cuadro anterior podemos ver como cada modelo escoge parámetros diferentes en función de sus datos. Se puede apreciar que todos los modelos han obtenido mejores resultados con el núcleo de tipo RBF, ya que las relaciones encontradas entre los datos de entrada y salida son no lineales.

Finalmente los modelos para los activos de Tesla, Bitcoin y Petróleo emplean ventanas de tamaño 10 para los entrenamientos y predicciones mientras que el modelo del S&P 500 tan solo necesita un tamaño de 5.

### 4.3.3. Redes neuronales

A la hora de diseñar los diferentes modelos de redes neuronales presentadas se ha utilizado la búsqueda GridSearchCV con validación cruzada con 3 pliegues y la métrica  $R^2$  para determinar el número de neuronas y la función de activación entre las siguientes alternativas:

- **Units:** [6, 12, 24, 36, 64, 128, 256, 512],
- **Activation:** ['relu', 'sigmoid'].
- **Learning rate:** [0.0001, 0.001, 0.01, 0.1, 1].

Adicionalmente, al ajuste de parámetros se han probado diferentes arquitecturas con distintos tamaños de ventana, resultando 30 el valor que arrojaba mejores resultados en todos los modelos. Se han probado dos arquitecturas diferentes para todos los

<sup>11</sup>Del inglés, Radial Basis Function que se traduce como función de base radial.

modelos, acogiendo aquellas que arrojaban mejores resultados. Estas arquitecturas están formadas por dos niveles jerárquicos y son:

- **Tipo 1:** Arquitectura más sencilla, su primer nivel está formado por una capa LSTM/GRU o dos capas LSTM y GRU (en función de la alternativa).
- **Tipo 2:** Arquitectura más compleja, su primer nivel está formado por tres capas LSTM/GRU o dos capas LSTM y dos capas GRU (dependiendo de la alternativa).

El segundo nivel de ambas arquitecturas está formado por una sola capa de salida de tipo **Dense**<sup>12</sup>, con tan solo una neurona ya que esta capa es la que devuelve un único valor, el precio predicho.

### Redes con capas LSTM

Los parámetros que arrojan un mejor resultado de la métrica  $R^2$  aparecen en el cuadro 2.

Activo	Activación	Neuronas por capa	Arquitectura	Learning rate	$R^2$
Tesla	relu	256	Tipo 1	0.001	0.981
S&P 500	relu	256	Tipo 1	0.001	0.991
Bitcoin	relu	12	Tipo 1	0.01	0.979
Petróleo	relu	512	Tipo 1	0.0001	0.921

Cuadro 2: Parámetros óptimos para cada conjunto de datos.

<sup>12</sup>Del inglés, densa. Son aquellas capas en las que todas las neuronas de una capa están conectadas con todas las neuronas de la capa siguiente y anterior.

### Redes con capas GRU

Los resultados del proceso de búsqueda que mejor métrica  $R^2$  devuelven aparecen en el cuadro 3.

Activo	Activación	Neuronas por capa	Arquitectura	Learning rate	$R^2$
Tesla	relu	24	Tipo 2	0.01	0.995
S&P 500	relu	64	Tipo 1	0.01	0.998
Bitcoin	relu	64	Tipo 1	0.01	0.994
Petróleo	relu	128	Tipo 2	0.01	0.977

Cuadro 3: Parámetros óptimos para cada conjunto de datos.

### Redes con capas LSTM + GRU

Los parámetros que mejor se ajustan a los conjuntos de datos de entrenamiento aparecen en el cuadro 4.

Activo	Activación	Neuronas por capa	Arquitectura	Learning rate	$R^2$
Tesla	relu	256	Tipo 1	0.001	0.982
S&P 500	relu	256	Tipo 2	0.001	0.990
Bitcoin	relu	128	Tipo 1	0.001	0.978
Petróleo	relu	512	Tipo 1	0.01	0.909

Cuadro 4: Parámetros óptimos para cada conjunto de datos.

### Implicaciones

Observando la columna **Función de activación** de los cuadros anteriores podemos ver como la función de activación *relu* arroja mejores resultados con los cuatro conjuntos de datos en todos los modelos. Esto se debe a que la función *relu* siempre toma valores iguales o superiores a cero, lo cual está en concordancia con la distribución de precios de nuestros activos, a excepción del precio del petróleo durante un corto periodo de tiempo específico.

En cuanto a las columnas **Neuronas por capa**, **Arquitectura** y **Learning rate** podemos ver que no siguen ningún patrón ya que dependen puramente de los datos y del entrenamiento que se está realizando. Es conveniente observar que la arquitectura de **tipo 1** es la que arroja mejores resultados a pesar de ser la más sencilla.

Por último, al observar la columna  $R^2$  todos los valores de este coeficiente son superiores a 0.9 llegando en algunos casos incluso a 0.99, lo que nos indica que una

gran parte de la variabilidad de las variables de entrada pueden ser explicadas por el modelo. El valor de esta columna indica que nuestros modelos pueden llegar a tener cierto *overfitting*<sup>13</sup> por lo que en las siguientes secciones conviene revisar la calidad de los modelos diseñados.

#### 4.4. Resultados de la evaluación de los modelos

En esta sección se expondrán y discutirán los resultados de las evaluaciones de los diferentes modelos diseñados en el apartado anterior. Para evaluar los modelos se han realizado dos análisis:

- **Primera evaluación:** En ella se trata de predecir tan solo el precio del día siguiente de las primeras 30 series temporales de los datos de prueba. Se ha decidido realizar esta evaluación para poder medir el ajuste del modelo a datos nunca vistos y con ello poder determinar si los entrenamientos realizados resultan en modelos que no conduzcan al *overfitting*.
- **Segunda evaluación:** Se realiza una predicción en cadena de modo que dada tan solo una serie temporal se predican los 10 siguientes precios de cierre del activo. Se ha decidido realizar esta evaluación para ver cómo se comportan los diferentes modelos a la hora de predecir las tendencias a corto plazo de los precios.

---

<sup>13</sup>Del inglés, sobreajuste. Fenómeno que se da cuando un modelo se ajusta demasiado a los datos de entrenamiento y no predice bien con datos nuevos.

#### 4.4.1. Regresión Lineal

##### Primera evaluación

En la figura 4 se puede ver el gráfico correspondiente a esta primera evaluación.

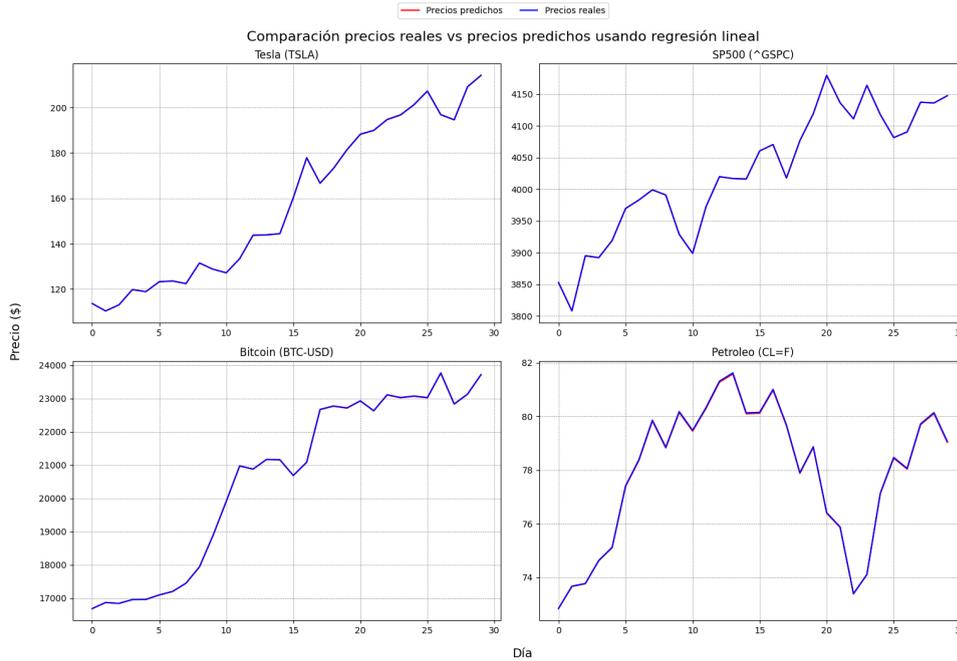


Figura 4: Gráfico con los resultados de la primera evaluación de la predicción sobre los precios de los 4 activos usando Regresión Lineal.

En el gráfico anterior podemos ver como la regresión lineal es perfectamente capaz de predecir el precio del día siguiente fallando tan solo cuando se producen cambios de tendencia ya que el modelo empleado no es capaz de predecirlos empleando tan solo el día anterior.

En el cuadro 5 se pueden ver los resultados de las diferentes métricas correspondientes a esta primera evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	6.8701	47.1980	5.3726	0.9405
S&P 500	39.7974	1583.8345	31.6457	0.8131
Bitcoin	663.1991	439833.0644	461.9794	0.9675
Petróleo	1.6120	2.5984	1.2895	0.8150

Cuadro 5: Resultados de las métricas de evaluación.

Las métricas de evaluación obtienen valores relativamente buenos del coeficiente de determinación, superior al 0.81 en todos los modelos, sobre el conjunto de test por lo que el modelo no está sobreajustado. Sobre los errores no resultan ser muy elevados respecto al rango de precios en el que se mueven los activos en el caso de  $RMSE$  y  $MAE$ . En cambio, si nos fijamos en los valores del  $MSE$  solo tiene un valor aceptable en el caso del petróleo ya que esta métrica penaliza los errores más grandes.

### Segunda evaluación

En la figura 5 se puede ver el gráfico correspondiente a esta segunda evaluación.

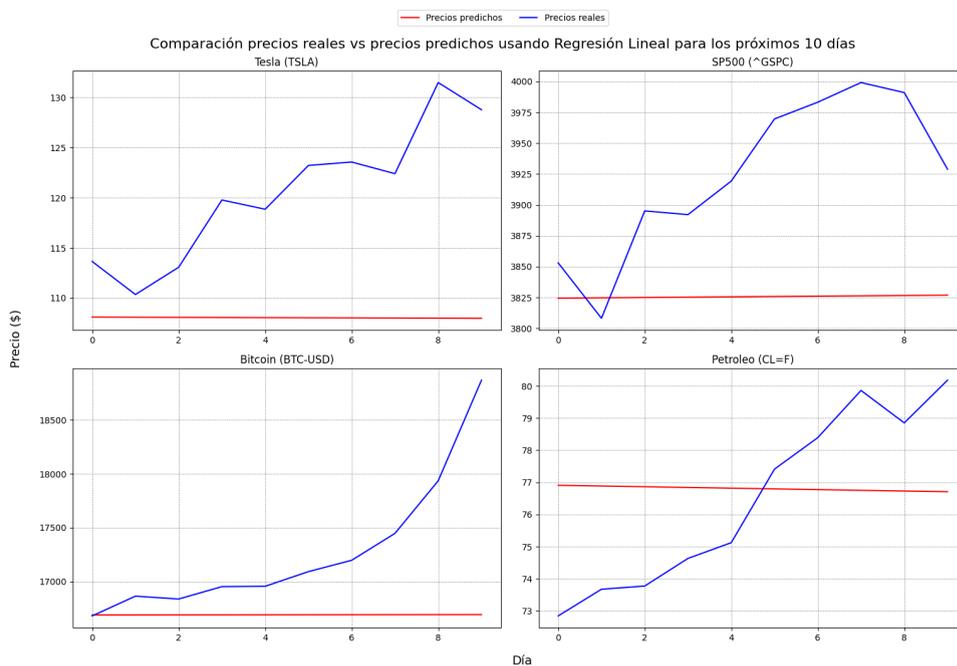


Figura 5: Gráfico con los resultados de la segunda evaluación de la predicción sobre los precios de los 4 activos usando Regresión Lineal.

En este caso vemos cómo el modelo no es capaz de predecir los días siguientes y devuelve prácticamente los mismos resultados para los precios de los 10 días que se intentan calcular. En los casos de Tesla y S&P 500, acierta los precios en cierto momento, pero esto se debe a una coincidencia, por lo que podemos concluir que las predicciones de este modelo son desechables para este caso.

En el cuadro 6 se pueden ver los resultados de las diferentes métricas correspondientes a esta segunda evaluación.

---

Activo	RMSE	MSE	MAE	$R^2$
Tesla	14.076	198.148	12.483	-139776.469
S&P 500	114.872	13195.638	101.613	-22055.067
Bitcoin	863.951	746410.766	593.891	-709882.661
Petróleo	2.710	7.342	2.522	-1792.963

---

Cuadro 6: Resultados de las métricas de evaluación.

Observando el cuadro de métricas podemos confirmar que este modelo no arroja buenos resultados ya que no es capaz de predecir ni tan siquiera la tendencia del precio y los errores son bastante elevados. Si nos fijamos en el valor del coeficiente  $R^2$  podemos ver que el modelo no es capaz de explicar la varianza de los datos y que toma un negativo elevado<sup>14</sup>, esto implica un mal ajuste.

---

<sup>14</sup>Los valores del coeficiente  $R^2$  cuando el modelo no explica nada de la varianza de los datos a predecir toma un valor negativo alto debido a la implementación que toma el cálculo de esta métrica en la librería de Python utilizada. Una alternativa a para evitar estos valores es la de sustituir los valores negativos por 0 ya que en ese caso el modelo no explica nada de la varianza de los datos, no obstante, en este documento se mantendrán los valores originales intactos.

#### 4.4.2. Máquinas de vector soporte para la regresión

##### Primera evaluación

En la figura 6 se puede ver el gráfico correspondiente a esta primera evaluación.

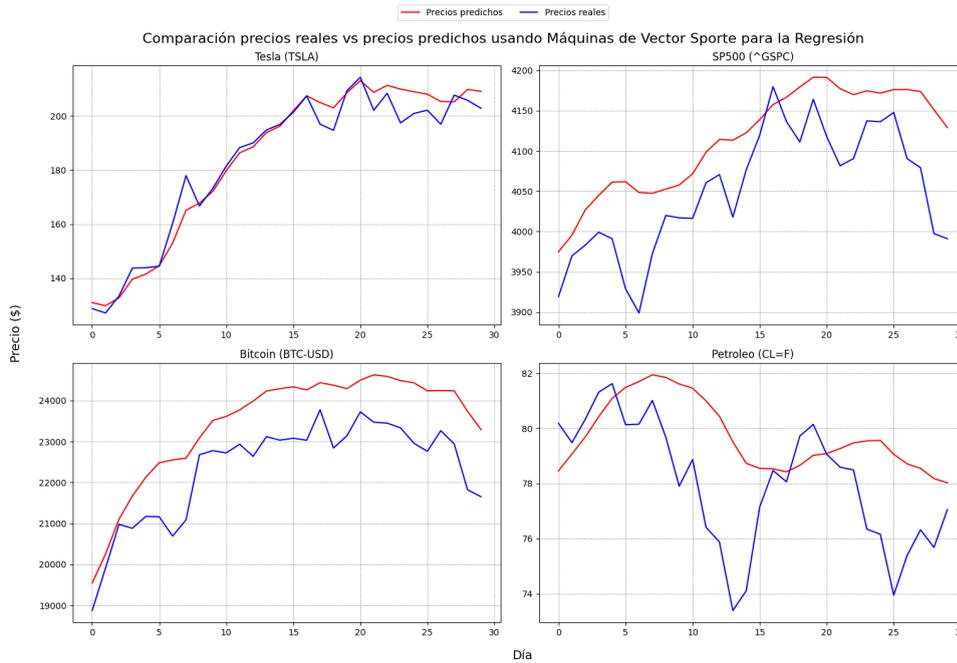


Figura 6: Gráfico con los resultados de la primera evaluación de la predicción sobre los precios de los 4 activos usando Máquinas de vector soporte para la regresión.

En los gráficos podemos ver como este modelo capaz de ajustarse a la tendencia de los precios en los datos de entrenamiento pero no es capaz de predecir los precios exactos.

En el cuadro 7 se pueden ver los resultados de las diferentes métricas correspondientes a esta primera evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	9.840	96.819	8.004	0.788
S&P 500	83.027	6893.485	67.292	-0.626
Bitcoin	1217.697	1482786.195	1030.716	0.829
Petróleo	3.764	14.164	3.033	-0.408

Cuadro 7: Resultados de las métricas de evaluación.

En el cuadro podemos ver que en el caso de Tesla y Bitcoin son los únicos que obtienen un coeficiente  $R^2$  aceptable mientras que en el resto de modelos no es capaz de ajustar correctamente. Los errores resultan ser elevados si los comparamos con la regresión lineal. Podemos concluir que para este tipo de problemas este modelo no es correcto para predecir el precio del día siguiente.

### Segunda evaluación

En la figura 7 se puede ver el gráfico correspondiente a esta segunda evaluación.

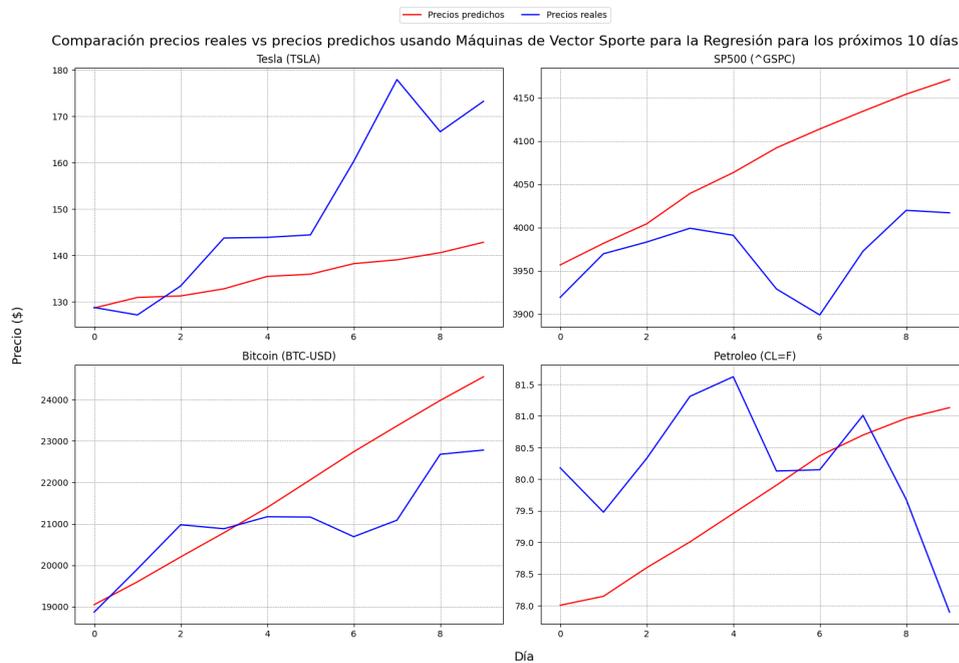


Figura 7: Gráfico con los resultados de la segunda evaluación de la predicción sobre los precios de los 4 activos usando Máquinas de vector soporte para la regresión.

Si nos fijamos en las gráficas las predicciones de Tesla no son capaces de ajustarse a los precios esperados. Las gráficas del resto de activos nos indican que este tipo de modelo es capaz de predecir la dirección de sus precios pero arrojando grandes errores a la hora de predecir el precio exacto a medida que vanzan los días.

En el cuadro 8 se pueden ver los resultados de las diferentes métricas correspondientes a esta segunda evaluación.

Activo	RMSE	MSE	MAE	$R^2$
Tesla	19.696	387.931	15.122	-19.159
S&P 500	122.357	14971.337	101.178	-2.007
Bitcoin	1256.223	1578097.444	987.216	0.504
Petróleo	1.781	3.172	1.496	-1.623

Cuadro 8: Resultados de las métricas de evaluación.

El cuadro de métricas nos ayuda a ver que los mejores resultados son los del Bitcoin ya que el coeficiente  $R^2$  toma un valor positivo pero no es cercano a 1. Para el resto de activos este coeficiente nos indica que no el modelo no es capaz de explicar la varianza de sus datos. Por último, si nos fijamos en los errores a la hora de predecir los precios podemos concluir en que el modelo no es capaz de ajustarse predecir el precio exacto ya que los errores son elevados.

### 4.4.3. Redes neuronales

#### LSTM: Primera evaluación

En la figura 8 se puede ver el gráfico correspondiente a esta primera evaluación.

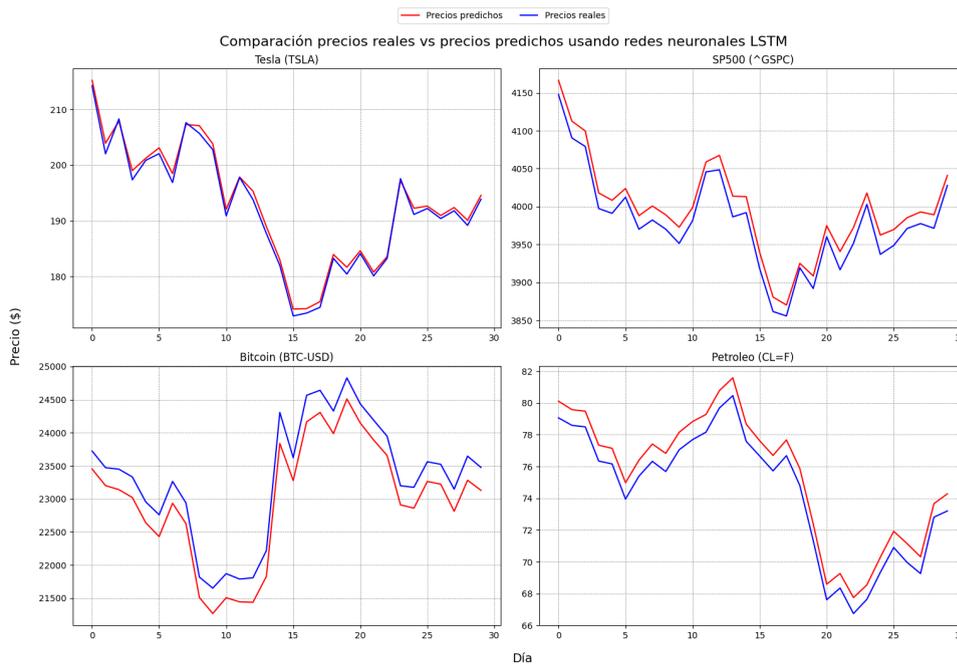


Figura 8: Gráfico con los resultados de la primera evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo LSTM.

Observando las gráficas con los resultados de evaluación podemos ver como las redes neuronales con capas LSTM no son capaces de predecir los precios exactos en tres de los cuatro activos pero si se ajustan bien a las tendencias de los mismos. Este tipo de modelo es capaz de predecir los precios exactos al día siguiente tan solo durante las bajadas y subidas de los precios, aumentando los errores en los cambios de tendencia.

En el cuadro 9 se pueden ver los resultados de las diferentes métricas correspondientes a esta primera evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	6.567	43.123	5.094	0.763
S&P 500	42.186	1779.647	33.235	0.751
Bitcoin	819.529	671627.668	595.392	0.922
Petróleo	2.014	4.055	1.571	0.774

Cuadro 9: Resultados de las métricas de evaluación.

Los resultados del coeficiente  $R^2$  indican que el modelo es capaz de explicar la varianza de los datos de entrenamiento para los cuatro activos de manera aceptable. Si nos fijamos en el resto de métricas los errores en los precios no son muy elevados si los comparamos con los rangos en los que se mueven los activos por lo que podríamos considerar este modelo para predecir los precios al día siguiente.

### LSTM: Segunda evaluación

En la figura 9 se puede ver el gráfico correspondiente a esta segunda evaluación.

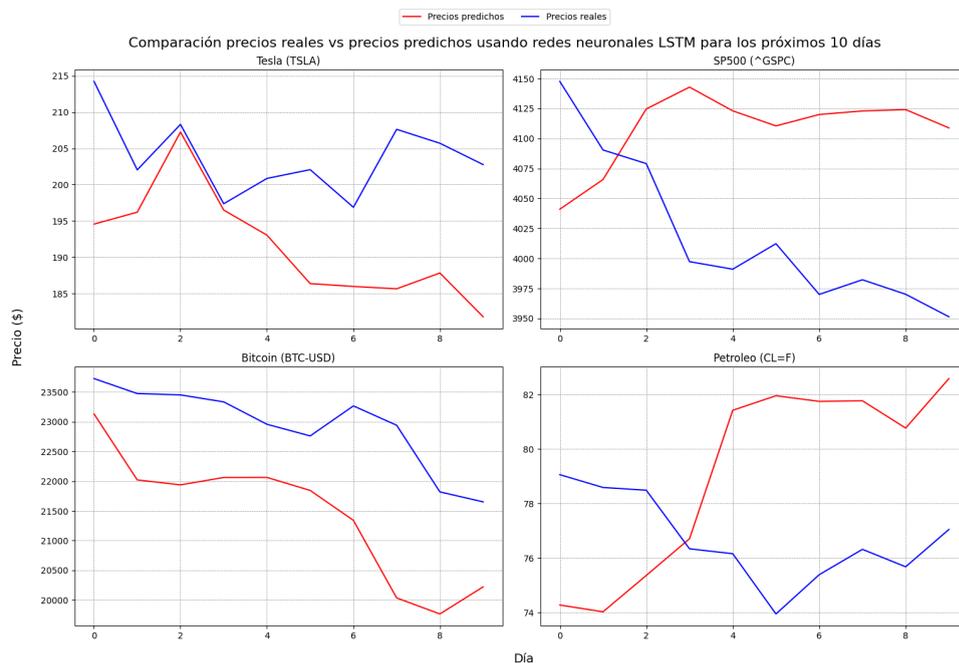


Figura 9: Gráfico con los resultados de la segunda evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo LSTM.

Los gráficos con los resultados de las predicciones nos indican que este tipo de modelo es capaz de predecir las tendencias de los precios de los activos con una mayor

precisión los primeros días de la ventana de tiempo ya que la distancia entre ambas líneas es menor e incluso se llegan a cruzar en los activos Tesla, S&P 500 y Petróleo. Los errores de predicción tampoco resultan ser muy elevados si los comparamos con los precios de los activos ya que no llegan ni al 7%.

En el cuadro 10 se pueden ver los resultados de las diferentes métricas correspondientes a esta segunda evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	14.472	209.438	12.274	-3.133
S&P 500	123.705	15303.032	115.440	-16.773
Bitcoin	1624.070	2637603.371	1494.486	-1.480
Petróleo	5.216	27.205	4.854	-1.445

Cuadro 10: Resultados de las métricas de evaluación.

Los resultados de los cuadros de la segunda evaluación indican que este modelo no es capaz de explicar la varianza de los datos pero si es capaz de predecir la tendencia del precio en los próximos 10 días de Tesla tolerando errores del 7% a la hora de predecir el precio exacto.

## GRU: Primera evaluación

En la figura 10 se puede ver el gráfico correspondiente a esta primera evaluación.

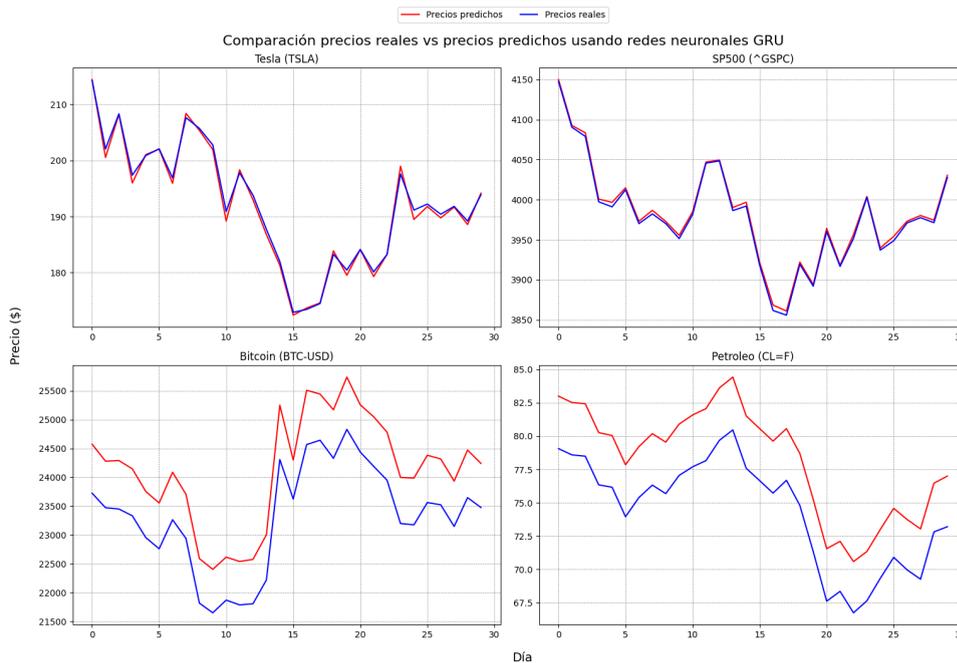


Figura 10: Gráfico con los resultados de la primera evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo GRU.

Si observamos las gráficas podemos ver que los modelos no son capaces de predecir correctamente en el caso de Bitcoin y Petróleo ya que las predicciones siguen la tendencia de los resultados esperados pero no son capaces de devolver los precios exactos. Por el contrario para los activos Tesla y S&P 500 el ajuste si que es correcto y se obtienen buenos resultados. Esto nos indica que este modelo debería ser empleado tan solo en el caso de los dos primeros activos para predecir los precios.

En el cuadro 11 se pueden ver los resultados de las diferentes métricas correspondientes a esta primera evaluación.

Activo	RMSE	MSE	MAE	$R^2$
Tesla	6.688	44.728	5.328	0.768
S&P 500	38.400	1474.545	29.341	0.793
Bitcoin	1076.077	1157941.552	935.773	0.870
Petróleo	4.301	18.496	3.990	-0.016

Cuadro 11: Resultados de las métricas de evaluación.

El cuadro de métricas nos confirma que los modelos son capaces de ajustar correctamente en el caso de los tres primeros activos ya que el coeficiente  $R^2$  es superior a 0.8. En el caso del petróleo no es capaz de realizar un buen ajuste. Si nos fijamos en los errores podemos ver que para los cuatro activos no resultan ser muy elevados en comparación con el rango de precios en los que se mueven los precios.

### GRU: Segunda evaluación

En la figura 11 se puede ver el gráfico correspondiente a esta segunda evaluación.

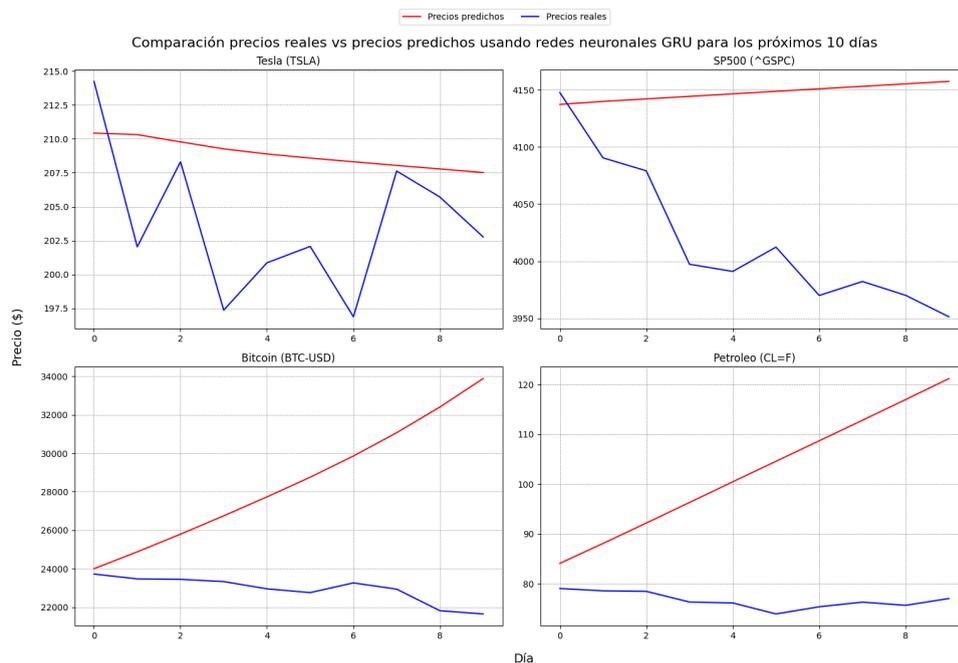


Figura 11: Gráfico con los resultados de la segunda evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo GRU.

Gráficamente se aprecia como tan solo el modelo para Tesla un buen resultado para las predicciones la tendencia del precio con errores relativamente elevados en la

predicción del precio exacto. Para el S&P 500, el Bitcoin y el Petróleo los modelos solo son capaces de acertar el precio del día siguiente mientras que para el resto de días no son capaces de predecir la tendencia y arrojan errores elevados.

En el cuadro 12 se pueden ver los resultados de las diferentes métricas correspondientes a esta segunda evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	7.008	49.115	5.866	-50.318
S&P 500	144.658	20926.068	130.370	-514.695
Bitcoin	6699.398	44881930.467	5573.475	-3.630
Petróleo	28.868	833.353	25.851	-4.937

Cuadro 12: Resultados de las métricas de evaluación.

Observando los cuadros de errores vemos como los modelos que mejor explican la varianza de sus datos de entrenamiento son el del Bitcoin y el del Petróleo. Respecto a los errores a la hora de predecir los precios vemos como para toda la serie los mejores resultados son los de Tesla mientras que el resto de modelos tienen errores más elevados. Podemos concluir en que este modelo no devuelve buenos resultados a la hora de predecir la tendencia y los precios de los activos.

## LSTM + GRU: Primera evaluación

En la figura 12 se puede ver el gráfico correspondiente a esta primera evaluación.

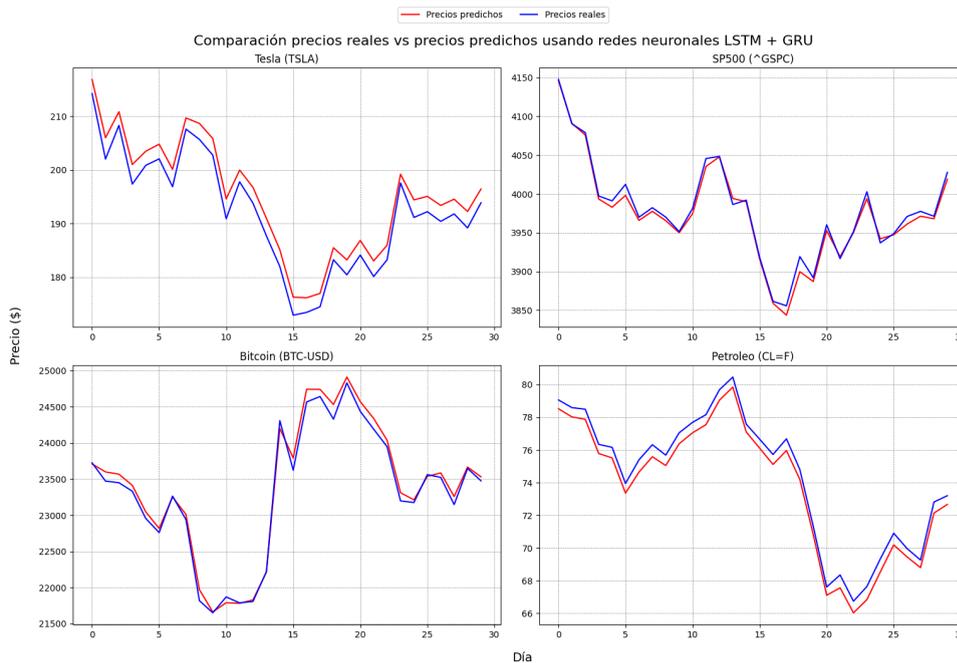


Figura 12: Gráfico con los resultados de la primera evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo LSTM + GRU.

Gráficamente las predicciones de estos modelos son capaces de ajustarse a las tendencias de los precios e incluso durante algunos tramos predecir el precio exacto. Si el día anterior ha habido un cambio de tendencia este modelo tiene problemas a hora de predecir el precio de los activos.

En el cuadro 13 se pueden ver los resultados de las diferentes métricas correspondientes a esta primera evaluación.

Activo	RMSE	MSE	MAE	R <sup>2</sup>
Tesla	7.395	54.683	5.844	0.702
S&P 500	39.206	1537.117	30.229	0.788
Bitcoin	710.824	505271.440	520.493	0.943
Petróleo	1.745	3.046	1.414	0.827

Cuadro 13: Resultados de las métricas de evaluación.

Si nos fijamos en el cuadro de métricas vemos como todos los modelos son capaces de explicar la varianza de los datos con una precisión aceptable. A la hora de evaluar los errores estamos ante el modelo que emplea redes neuronales que presenta los menores valores.

### LSTM + GRU: Segunda evaluación

En la figura 13 se puede ver el gráfico correspondiente a esta segunda evaluación.

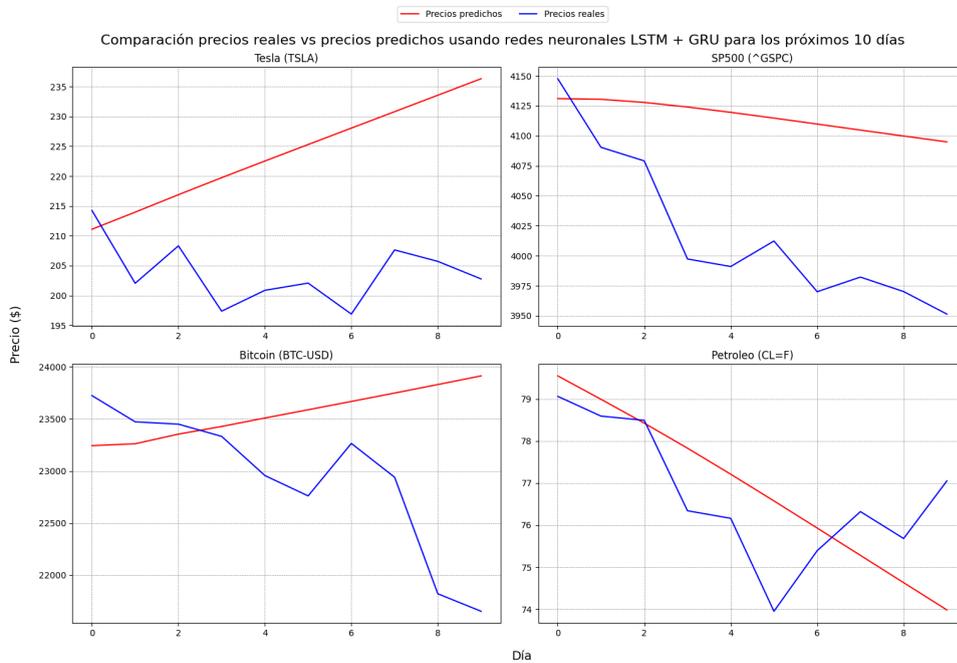


Figura 13: Gráfico con los resultados de la segunda evaluación de la predicción sobre los precios de los 4 activos usando redes neuronales de tipo LSTM + GRU.

Gráficamente las predicciones nos indican que en el caso del Petróleo es posible predecir tan solo la tendencia del precio mientras que en el resto de activos las predicciones no son capaces realizar buenas predicciones.

En el cuadro 14 se pueden ver los resultados de las diferentes métricas correspondientes a esta segunda evaluación.

Activo	RMSE	MSE	MAE	$R^2$
Tesla	22.669	513.863	20.653	-6.972
S&P 500	109.214	11927.645	99.850	-77.414
Bitcoin	1061.228	1126204.633	774.819	-21.615
Petróleo	1.500	2.249	1.181	0.296

Cuadro 14: Resultados de las métricas de evaluación.

El cuadro de métricas nos indica que a la hora de predecir los precios en cadena este tipo de modelo no destaca ya que sus errores son elevados respecto a modelos anteriores presentando valores negativos del coeficiente  $R^2$  exceptuando el Petróleo. Este modelo predice correctamente la tendencia del precio del Petróleo durante los primeros cinco días, también es capaz de explicar parte de la varianza de sus precios por lo que se podría emplear para predecir este activo arrojando unos buenos resultados.

## 4.5. Comparación de resultados

En esta sección se van a comparar los diferentes resultados obtenidos a lo largo del proceso de evaluación.

### 4.5.1. Variantes de datos

Como ya se ha mencionado anteriormente, los modelos han sido entrenados empleando dos variantes de los datos. En base a los entrenamientos y evaluaciones realizadas se ha decidido emplear la **variante B**, es decir, la que empleaba datos desde 2010 hasta 2023. La decisión de emplear la segunda variante se debe a las siguientes características de ambos entrenamientos:

- Los modelos de la primera variante ajustan mejor a los datos de prueba y sus predicciones son más precisas (en términos de errores), no obstante, los modelos no son capaces de predecir correctamente la tendencia de los precios con exactitud. La segunda variante intenta resolver el problema con datos de entrenamiento actuales, por lo que puede ponerse en práctica desde el momento de publicación de este monumento.
- La segunda variante trata de resolver el problema con datos de entrenamiento actuales por lo que puede ponerse en práctica.

Las regresiones lineales entrenadas aportaban resultados similares no obstante en el caso de las SVR en activos como el Petróleo o el S&P 500 los resultados eran mejores en el caso de la primera variante. Esto se debe a que el comportamiento del S&P 500 es lineal hasta la llegada del año 2020 y en el caso del petróleo la bajada de este año lo llevó a precios negativos lo que influye en el ajuste del modelo SVR.

El resto de modelos se comportaban mejor con la segunda variante ya que no solo eran capaces de ajustar mejor sino que también arrojaban mejores predicciones por regla general. Esto se debe a que en esta alternativa la cantidad de datos es mucho mayor lo que proporciona una mayor cantidad de relaciones entre las variables dependientes e independientes al entrenar.

La comparación directa entre las predicciones de ambas variantes no resulta del todo justo no obstante la decisión de emplear esta variante no se debe solo a que los modelos arrojen mejores resultados sino a que resulta interesante emplear los datos más actuales posibles ya que no se pueden predecir las tendencias de los precios actuales habiendo entrenado un modelo con solo datos hasta el año 2019.

#### 4.5.2. Modelos

En la sección 4.4 se realiza un análisis individual de las predicciones sobre el conjunto de test al día siguiente (primera evaluación) y los 10 días siguientes (segunda evaluación). En esta sección se elegirán los mejores modelos para cada situación.

##### Mejores modelos para la primera evaluación

Los modelos que obtienen mejores resultados en general a la hora de predecir los precios del día siguiente son la regresión lineal y el modelo que mezcla redes neuronales con capas LSTM y GRU.

Si tuviéramos que elegir un solo modelo para realizar esta tarea, sin duda, el mejor sería el de regresión lineal ya que emplea ventanas de tan solo un día para sus predicciones por los tiempos de entrenamiento y predicción son más cortos. Este modelo proporciona mejores resultados debido a que el precio del día siguiente de un activo suele corresponderse con el precio del día anterior junto con una pequeña variación positiva o negativa de este mismo.

##### Mejores modelos para la segunda evaluación

A la hora de la predicción en cadena los mejores resultados para todos los activos en conjunto se obtienen empleando los modelos basados en redes neuronales, destacando el modelo formado únicamente por capas LSTM. Este modelo es el ideal si tuviéramos que elegir una arquitectura similar para todos los activos.

No existe un modelo que arroje los mejores resultados para todos los activos fi-

nancieros. En el apartado anterior hemos visto que para la segunda evaluación los mejores modelos para los activos seleccionados son:

- **Tesla:** el modelo que aporta mejores resultados es el que emplea redes neuronales con capas LSTM.
- **S&P 500:** el modelo que arroja mejores predicciones es el basado en máquinas de vector soporte para la regresión.
- **Bitcoin:** el modelo que devuelve mejores resultados es el basado en máquinas de vector soporte para la regresión.
- **Petróleo:** el modelo que realiza mejores predicciones es el que emplea redes neuronales recurrentes con capas LSTM + GRU.

Respecto a la complejidad de los modelos de redes neuronales podemos decir que por regla general, los modelos con arquitecturas más sencillas y capas más densas son los que ofrecen mejores resultados.

En conclusión, para predecir la tendencia de los precios es mejor usar tan solo redes neuronales recurrentes con capas LSTM ya que son los que mejor explican la varianza de los datos mientras que mantienen un nivel de error similar al de las demás variantes. Si lo que se quiere es predecir el precio exacto de un activo en un futuro el mejor modelo es aquel que combina capas LSTM y GRU pero solo ofrece resultados aceptables para los primeros días de las predicciones ya que luego el error aumenta significativamente.

### 4.5.3. Activos

A priori podríamos pensar que para la tarea que se aborda en este documento, el activo más sencillo de predecir tiene que ser el que tenga el comportamiento más lineal a lo largo de su historia (el S&P 500) y el más complicado debería ser el más volátil (Bitcoin).

Si observamos los resultados de las evaluaciones de los modelos podemos concluir que la primera de las afirmaciones anteriores no aplica a nuestros entrenamientos ya que el activo más sencillo de predecir resulta ser el petróleo, mientras la segunda sí es correcta ya que las predicciones de Tesla son las que obtienen peores resultados.

---

## 5. Conclusiones

El objetivo principal de este trabajo era determinar que algoritmos de aprendizaje automático se comportan mejor a la hora de realizar predicciones entorno a los ciclos de mercado del precio de un activo en temporalidades diarias, más en concreto determinar la tendencia del precio de un activo durante las próximas dos semanas (10 días). Queda claro que es posible determinar la tendencia de los precios mediante el uso de ciertos algoritmos y que unos se comportan mejor que otros en función del tipo de activo que se quiera predecir.

Según los resultados de la evaluación, ninguno de los modelos muestra un rendimiento sobresaliente en términos de precisión de predicción (RMSE) y ajuste a los datos ( $R^2$ ) al tratar de predecir la serie completa de días. Cuanto más lejana en el tiempo sea la predicción, peores resultados se van a obtener, ya que para este tipo de problemas el error es acumulativo, por ende, a medida que se vayan encadenando predicciones los errores aumentarán significativamente. No obstante, si reducimos a la mitad el periodo de predicción, las tendencias resultan predecibles e incluso se pueden llegar a obtener precios exactos.

De los modelos seleccionados los más indicados para el problema que se ha abordado en este documento, de manera general, resultan ser los que se basan en redes neuronales. Estos modelos requieren de mayor capacidad computacional pero su capacidad para capturar relaciones no lineales, aprender características relevantes y modelar las relaciones entre las secuencias de datos las convierte en la mejor elección de las elegidas para la predicción de tendencias y precios de activos financieros.

Los resultados del experimento nos han indicado que resulta ser complicado encontrar un modelo que realice buenas predicciones para todos los activos. Debido a lo anterior, resulta conveniente probar con diferentes arquitecturas y algoritmos hasta encontrar el que mejor se ajusta al activo con el que vamos a trabajar.

En el análisis técnico se suelen emplear varios indicadores en conjunto antes de tomar una decisión financiera por lo que los modelos diseñados en este trabajo pueden actuar como un indicador complementario novedoso para las decisiones en el corto plazo. Emplear tan solo los modelos como único indicador no resulta ser conveniente debido a que puede proporcionar información limitada sobre el comportamiento del mercado. Es recomendable utilizar múltiples indicadores ya que ayuda a obtener una imagen más completa y precisa de la situación del mercado y mejora la calidad de las decisiones comerciales.

Por último, cabe mencionar que tanto el diseño de los modelos como de los datos de entrenamiento y prueba son tareas que deberían realizarse acorde con las características de los activos con los que se quiera operar. Es posible que los modelos elegidos no sean los que mejor se ajusten a los datos de entrenamiento y existan

---

variantes que arrojen predicciones más precisas incluso haciendo uso de los mismos activos.

## 6. Líneas futuras

Como ya se ha comentado en el apartado anterior los modelos diseñados son posiblemente mejorables. Para mejorar estos dos aspectos existen diferentes alternativas como el uso de medias móviles exponenciales para entrenar y predecir las tendencias de los precios o el empleo de arquitecturas más complejas con estructuras diferentes. Adicionalmente se podrían añadir datos no financieros, como noticias, sentimiento de mercado, eventos económicos y factores macroeconómicos relevantes. Este tipo de datos pueden proporcionar una visión más amplia del entorno del mercado, lo que puede mejorar la precisión de las predicciones.

En este documento se han intentado predecir las tendencias en temporalidades diarias, pero queda pendiente aplicar estos modelos para intentar predecir los precios de los activos financieros en temporalidades menores usando datos en tiempo real de alta frecuencia. Esto implica la mejora de los modelos creados para que sean capaces de manejar grandes volúmenes de datos y proporcionar predicciones rápidas y precisas con el fin de aprovechar las oportunidades comerciales de corto plazo.

---

## 7. Bibliografía

### 7.1. Documentos

- [1] Data science: ¿qué es y qué no es? <https://aukera.es/blog/data-science-que-es-y-que-no-es/>, 2021.
- [2] Jordi Guillamón. Ciclos de mercado: ¿cómo funcionan? <https://formacioneninversion.com/ciclos-de-mercado-como-funcionan/>.
- [3] Saahil Chadha. Clinical oracle: Machine learning in medicine. *Clinical Oracle*, 2019.
- [4] Andrés Sevilla Arias. Activo financiero. <https://economipedia.com/definiciones/activo-financiero.html>. Fecha de acceso: 1 marzo 2023.
- [5] Isabel Nogales Naharro. *Manual de análisis técnico de los mercados*. Isabel Nogales, 2015.
- [6] Víctor Sacristán Robles. Desarrollo de un sistema automático de inversión basado en reconocimiento de patrones, junio 2014.
- [7] Grupo Actinver. Inversión inteligente: ¿qué son los ciclos de mercado? — actinver, 2020.
- [8] Richard Meese and Andrew Roesse. An empirical assessment of non-linearities in models of exchange rate determination. *Review of Econometric Studies*, 58:601–619, 1991.
- [9] Francisco Fernández and Simón Sosvilla. Testing nonlinear forecastability in time series: Theory and evidence from ems. *Economic Letters*, 59:49–63, 1998.
- [10] Donghui Zhang and Xiaoli Zhang. Study on forecasting the stock market trend based on stochastic analysis method. *International Journal of Business and Management*, 4(6):163–170, 2009.
- [11] Abdullah Yalama and Tayfun Sevil. Forecasting world stock markets volatility. *International Research Journal of Finance and Economics*, 15:159–174, 2008.
- [12] Robert R. Trippi and Efraim Turban. *Neural networks in finance and investing*. McGraw Hill, New York, United States, revised edition edition, 1996.
- [13] Yuhong Li and Weimin Ma. Application of artificial neural networks in financial economics: a survey. In *International Symposium on Computational Intelligence and Design*, pages 211–214, 2010.
- [14] Stelios D. Bekiros and Dimitris A. Georgoutsos. Evaluating direction of change

- forecasting: Neurofuzzy models vs. neural networks. *Mathematical and Computer Modelling*, 46:38–46, 2007.
- [15] Huanan Hao. Short-term forecasting of stock price based on genetic-neural network. In *6th International Conference on Natural Computation*, pages 1838–1841, 2010.
- [16] P.D. Yoo, M.H. Kim, and T. Jan. Machine learning techniques and use of event information for stock market prediction: A survey and evaluation. In *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, volume 2, pages 835–841, 2005.
- [17] Weiwei Jiang. Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184:115537, 2021.
- [18] Bruno Miranda Henrique, Vinicius Amorim Sobreiro, and Herbert Kimura. Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124:226–251, 2019.
- [19] Philip Ndikum. Machine learning algorithms for financial asset price forecasting. *arxiv*, 1:113–118, 2020.
- [20] Paloma Recuero de los Santos. Tipos de aprendizaje en machine learning: supervisado y no supervisado, 2021.
- [21] Sergio Gómez Vilas. Bootstrap y métodos de ensamblado en modelos de regresión y clasificación. Master's thesis, Universidad de Coruña, 2021. Trabajo Fin de Máster, Máster en Técnicas Estadísticas.
- [22] Ran Aroussi. *yfinance Documentation*, 2023.
- [23] Matplotlib Development Team. *Matplotlib Documentation*, 2023.
- [24] Michael Waskom and contributors. *Seaborn Documentation*, 2023.
- [25] Pandas Development Team. *Pandas Documentation*, 2023.
- [26] NumPy Developers. *NumPy Documentation*, 2023.
- [27] Scikit learn Developers. *Scikit-learn Documentation*, 2023.
- [28] Michael C. Ehrhardt and Eugene F. Brigham. *Finanzas corporativas: enfoque central*. Cengage Learning México, 2018.
- [29] AprendeIA. Algoritmo de Regresión Lineal Simple en Machine Learning, 2018.
- [30] KeepCoding. SVR o SVM en regresión, diciembre 21 2022.

- [31] IBM. Neural networks, Fecha de acceso: 19 de mayo, 2023.
- [32] Elad Kfir and Yoshua Bengio. Deep Learning (con PyTorch), 2020.
- [33] Métricas de regresión para el aprendizaje automático, 2021.