

# Optimización de estrategias de trading a través de redes neuronales



UNIVERSITAT  
ROVIRA I VIRGILI

**TRABAJO DE FIN DE MÁSTER (TFM)**

Máster universitario en Dirección de empresas

Óscar Arrabal Izquierdo --- Junio 2024



## Índice

Resumen .....	3
Resum .....	3
Abstract .....	4
1. Introducción .....	5
2. Revisión de la literatura .....	7
2.1. Técnicas de predicción .....	8
2.1.1. Redes Neuronales utilizadas en la predicción .....	9
2.1.2. Tipos de interacciones online en la predicción de precios .....	15
2.2. Mercados eficientes .....	17
3. Metodología y datos .....	18
3.1. Recopilación de Datos .....	18
3.2. Diseño del Bot de Trading .....	21
4. Resultados .....	25
4.1. Desempeño del Bot de Trading .....	25
4.2. Impacto de las Tendencias de Twitter y Google Trends .....	32
5. Conclusiones .....	33
5.1. Limitaciones del trabajo .....	34
5.2. Recomendaciones para Futuras Investigaciones .....	34
Bibliografía .....	35



## Índice de Figuras

Figura 1 Ejemplo red neuronal.....	10
Figura 2 Red Neuronal ANN .....	11
Figura 3 Red neuronal LSTM.....	12
Figura 4 Red neuronal CNN.....	13
Figura 5 Red neuronal Bi-LSTM .....	13
Figura 6 Resumen Redes Neuronales .....	15
Figura 7 Precio histórico de Bitcoin.....	19
Figura 8 Evolución interés en Bitcoin periodo del 1 de enero al 31 de marzo de 2024	20
Figura 9 Entadas red neuronal.....	22
Figura 10 Predicción Precio de Bitcoin mal ajustada .....	23
Figura 11 Predicción Precio de Bitcoin ajustada .....	23
Figura 12 Predicción precios LSTM .....	29

## Índice de Tablas

Tabla 1 Precio Real vs Precio predicho .....	29
Tabla 2 Comparación rentabilidad de las estrategias para el periodo del 1 de enero al 31 de marzo de 2024.....	31



## Resumen

La automatización de las estrategias de trading, especialmente en el ámbito de las criptomonedas, se ha convertido en una práctica cada vez más habitual en los últimos tiempos, debido a la cantidad de datos disponibles para poder hacer una predicción de precios, permitiendo una diversidad muy grande de estrategias, cada vez más, apoyadas por inteligencias artificiales, más concretamente, redes neuronales con el fin de precisar de mejor manera estas predicciones. En este TFM se realiza un estudio que reúne las diferentes estrategias estudiadas a nivel académico y se implementa la más oportuna mediante un *bot* de trading. Este *bot* no solo emplea dichas estrategias, sino que también considera las interacciones en Twitter y Google trends para optimizar las estrategias de trading.

**Palabras clave:** Criptomonedas, redes neuronales, predicción de precios, LSTM, Bot, bitcoin, twitter, Google trends, inteligencia artificial

## Resum

L'automatització de les estratègies de trading, especialment en l'àmbit de les criptomonedes, s'ha convertit en una pràctica cada vegada més habitual en els últims temps, a causa de la quantitat de dades disponibles per a poder fer una predicció de preus, permetent una diversitat molt gran d'estratègies, cada vegada més, secundades per intel·ligències artificials, més concretament, xarxes neuronals amb la finalitat de precisar de millor manera aquestes prediccions. En aquest TFM es realitza un estudi que reuneix les diferents estratègies estudiades a nivell acadèmic i s'implementa la més oportuna mitjançant un *bot* de trading. Aquest *bot* no sols empra aquestes estratègies, sinó que també considera les interaccions en Twitter i Google trends per a optimitzar les estratègies de trading.



**Paraules clau:** Criptomonedas, xarxes neuronals, predicció de preus, LSTM, Bot, bitcoin, twitter, Google trends, intel·ligència artificial

## Abstract

The automation of trading strategies, especially in the field of cryptocurrencies, has become an increasingly common practice in recent times, due to the amount of data available to make a price prediction, allowing a very large diversity of strategies, increasingly, supported by artificial intelligence, more specifically, neural networks in order to better specify these predictions. In this TFM, a study is carried out that brings together the different strategies studied at the academic level and implements the most appropriate one by means of a trading bot. This bot not only uses these strategies, but also considers interactions on Twitter and Google trends to optimize trading strategies.

**Keywords:** Cryptocurrency, neuronal network, forecasting, LSTM, bot, bitcoin, twitter, google trends, artificial intelligence

## 1. Introducció

No hay duda de que cada vez estamos más interconectados, y que el mundo se ha convertido en un lugar más dinámico. En consonancia con esta realidad, los mercados financieros globales también se han transformado de forma significativa en las últimas décadas (Moreno-García et al., 2015). La automatización de estrategias de inversión y el uso de algoritmos inteligentes se ha convertido en una práctica habitual entre inversores, haciendo sistemas de trading cada vez más complejos (Martín et al., 2019a), incluyendo sistemas impulsados por inteligencia artificial (Akyildirim et al., 2022).

Dentro de todo este avance, podemos encontrar que en el año 2008 se publicó el “*White paper*” que propuso una moneda digital con características especiales, denominada Bitcoin. Este documento introdujo un nuevo paradigma en las transacciones *peer-to-peer*, permitiendo que los usuarios pudieran intercambiar valor digitalmente sin la necesidad de un intermediario (Torres et al., 2020), mediante las criptomonedas. Tal y como afirman Torres et al. (2020), las criptodivisas constituyen un mercado relativamente nuevo y altamente especulativo, los operadores suelen tener un perfil tolerante al riesgo y buscan rendimientos muy superiores a los que podrían obtenerse.

Hasta octubre de 2023, las transacciones diarias en el mercado de criptomonedas alcanzaron más de 42.000 millones de dólares (Brandon, 2023), con una capitalización del mercado global superior a 1.09 billones de dólares. Esta magnitud de operaciones hace que el mercado genere un gran volumen de datos a una gran velocidad. Es en este contexto donde las redes neuronales se vuelven esenciales para tratar de predecir el precio del activo analizado. Sin embargo, es importante destacar que, a diferencia de otros mercados, el de criptomonedas se encuentra bastante desvinculado del entorno macroeconómico general (Aslanidis et al., 2022), y hay otras variables que pueden afectar al valor de estos activos. De ahí que sea muy importante realimentar la red neuronal con datos relevantes que tengan que ver con las interacciones de la red de internet, que estas incluyen Twitter, Google trends, donde gracias a estas plataformas podemos estimar un *fear and greed index*, que, relacionándolo directamente con el precio del activo, podemos estimar su comportamiento. Por lo tanto, podemos apreciar que cuanto más completa sea la red neuronal que tengamos y más variables tengamos,

si los cálculos son los correctos, más precisión tendremos en nuestra predicción del precio.

Por lo expuesto anteriormente, este Trabajo Final de Máster (TFM) tiene como objetivo el desarrollo de un *bot* de *trading* para criptomonedas utilizando técnicas de “*Deep learning*”, “*machine learning*” y redes neuronales. Además, se considerarán las interacciones de la red de internet, como Google trends y Twitter, que puedan impactar directamente en el precio, reajustando la estrategia de trading.

Este TFM pretende enriquecer la investigación en el campo de las criptomonedas, recopilando información de diversos estudios realizados por expertos en la materia y aportando valor con nuestros propios hallazgos.

Además, en este trabajo se pretende desarrollar un *bot* de *trading* preciso y adaptable a la volatilidad del mercado de criptomonedas. Este *bot* puede ser una referencia para los profesionales ya que les puede servir como una herramienta de *trading* más precisa, que pueden adaptar con sus estrategias y ayudar a estimar sus estrategias. Además, es importante remarcar que en este *bot* contempla la información de Google trends o Twitter, característica con la que no cuentan la mayoría de *bots*.

El TFM se distribuye de la siguiente manera: En la sección 2 se describe la revisión de la literatura sobre las técnicas de *machine learning*, *deep learning* y redes neuronales aplicadas al trading. Se identifican y describen las estrategias más eficaces para el contexto específico de este estudio, destacando aquellas que mejor se adaptan a nuestro caso. Además, se examinan cómo las interacciones en internet influyen en las estrategias de trading. En la sección 3 se detalla la metodología utilizada para desarrollar el *bot* de trading, incluyendo la selección y el procesamiento de datos. En la sección 4 se plantea los resultados obtenidos por el *bot* y un análisis de esos resultados. Por último, en el apartado 5 encontraremos las conclusiones del trabajo.

## 2. Revisión de la literatura

En este apartado, se identifican y analizan las principales técnicas de predicción, tanto las metodologías tradicionales como aquellas que utilizan redes neuronales. Con este análisis, se pretende determinar las técnicas más adecuadas para la construcción del *bot de trading*. Además, se analizarán los diferentes tipos de interacciones con la red de internet que pueden afectar a nuestra estrategia de inversión. Posteriormente, se sintetizará lo analizado para definir las estrategias que se van a desarrollar en el *bot*.

Para entender adecuadamente el análisis planteado en este TFM, hemos de precisar que estas estrategias están enfocadas en criptomonedas, principalmente en Bitcoin (Nakamoto, 2008). Las criptomonedas son activos relativamente recientes, ya que, en 2008, como ya se mencionó anteriormente, se publicó el “*white paper*” de bitcoin, donde se proponía una moneda digital descentralizada y un sistema de registro público en cadena de bloque para todas las transacciones. En enero de 2009 se creó el primer bloque de la cadena de bloques de bitcoin.

A raíz de este evento, la adopción de bitcoin ha sido de forma gradual, empezando por los entusiastas de la criptografía y tecnología financiera, seguido por programadores y aquellos familiarizados con la tecnología de cadena de bloques, para finalmente irse expandiendo a un público más amplio, acabando por empresas e inversores institucionales. En 2013, experimentó su primer aumento significativo, superando los 1000 dólares de valor por primera vez. A pesar de los altibajos en el precio y desarrollo, en 2021 empezó a captar el interés de empresas e inversionistas institucionales, como Tesla o Square, que anunciaron sus inversiones en este activo. Bitcoin no solo ha sido fundamental en el mundo de las criptomonedas, sino que también ha sentado las bases para el desarrollo de la tecnología *blockchain* subyacente. Hoy en día, encontramos diversas aplicaciones y sectores que se benefician de esta tecnología y que confían en que Bitcoin y la *blockchain* seguirán siendo relevantes en el futuro.

## 2.1. Técnicas de predicción

La predicción en criptomonedas es el pronóstico de futuros movimientos y tendencias de precio en el mercado de cryptoactivos. Su objetivo principal de este enfoque es anticipar el comportamiento del precio para tomar mejores decisiones de compra o venta de los cryptoactivos.

Dentro de este ámbito, hay varios tipos de estrategias y varios autores han abordado este tema en la literatura (Akyildirim et al., 2022; Bautista, 2021; Catania & Grassi, 2022; Dunbar & Owusu-Amoako, 2023; Martín et al., 2019b). Gracias a estos estudios, podemos clasificar diferentes enfoques de predicción.

Catania & Grassi (2022) proponen la estrategia de MLE (*Maximum Likelihood Estimation*). Esta estrategia busca estimar una distribución de probabilidad supuesta a partir de datos observados, con el fin de que estos datos sean los más probables posibles y, por lo tanto, permitan predecir el precio.

En cambio, Bautista (2021) destaca un enfoque más tradicional, como el análisis fundamental y el análisis técnico. Su propuesta es combinar estos dos tipos de análisis para entender los motivos subyacentes de los movimientos de precio (como pueden ser el impacto de noticias o la influencia de las redes sociales) y saber, mediante el análisis técnico, predecir sus futuras tendencias. Esta combinación permite conocer de manera más precisa el comportamiento del precio de los cryptoactivos.

Por último, Akyildirim et al. (2022) presentan diferentes estrategias. Una de ellas es el algoritmo k-nn, un método de aprendizaje automático no paramétrico, otros que destacan son los algoritmos *random forest* (algoritmo usado en machine learning que usa la combinación de diferentes árboles de decisión) y *support vector machine* (SVM), un algoritmo de aprendizaje automático diseñado para regresión y clasificación. Estos dos últimos son los que más destacan por su alta precisión en las predicciones (Akyildirim et al. (2022)), lo cual refuerza la decisión de apostar por las redes neuronales en este TFM.

### 2.1.1. Redes Neuronales utilizadas en la predicción

Las redes neuronales son modelos computacionales inspirados en el funcionamiento del cerebro humano, siendo capaces de aprender, detectar patrones y realizar tareas específicas (Freeman & Skapura, 1991). Las investigaciones en este ámbito no son algo de reciente descubrimiento, sino que podemos encontrar investigaciones muy antiguas donde ya se exploraban estos conceptos.

Si seguimos con el concepto de que una red neuronal está inspirada en el cerebro humano. El cerebro humano está repleto de neuronas que nos permiten ver, sentir, entender, oír, etc., es decir, nos permiten tener diferentes habilidades. De manera similar, una red neuronal se representa a menudo como una serie de nodos, de los cuales cada uno simboliza una neurona o perceptrón.

Estos perceptrones son unidades de procesamiento que toman decisiones basadas en la información recibida. Si vemos la Figura 1 correspondiente a una red neuronal como un proceso de toma de decisión, tendríamos que en primer momento tenemos unas entradas que serían el equivalente a los factores para apoyar la toma de decisión, cada entrada sería correspondiente a una característica diferente, posteriormente deberíamos evaluar los factores y, por último, tomar una decisión.

Un ejemplo de esto podría ser, ¿Debería de comprarme este coche? como factores de decisión podríamos plantearnos preguntas como: ¿Tengo suficiente dinero?, ¿Mi pareja está conforme?, ¿Necesito usar el coche? Una vez definidas las entradas o factores, estos entran dentro del perceptrón, dando una ponderación mediante cálculos intermedios procesando la información, ya que, siguiendo el ejemplo, para mi puede ser más importante necesitar el coche por encima de que mi pareja esté conforme y dar un valor de ponderación superior y, por tanto, que la salida que me dé el perceptrón sea que me compre el coche.

Por lo tanto, una vez tenemos las entradas ponderadas, éstas se suman y entran en el perceptrón, que tiene un valor de umbral y una función de activación. Esta función de activación compara si la suma de las entradas es mayor al umbral y toma la decisión. Este proceso se complica al considerar que cada entrada puede ser el resultado de otro perceptrón que previamente ha procesado su propia decisión.

Por lo tanto, a nivel conceptual, podemos ver que detrás de una red neuronal hay una serie de funciones matemáticas. La red neuronal es entrenada y se le dan ejemplos para que pueda realizar de una manera más precisa las ponderaciones en la capa oculta y, de esta manera, se pueda minimizar la función de pérdida.




Figura 1 Ejemplo red neuronal

Fuente: [https://upload.wikimedia.org/wikipedia/commons/c/c2/MultiLayerNeuralNetworkBigger\\_english.png](https://upload.wikimedia.org/wikipedia/commons/c/c2/MultiLayerNeuralNetworkBigger_english.png)

Existen varios tipos de redes neuronales. Diferentes autores han referenciado estrategias de predicción empleando distintas redes neuronales (Hamayel & Owda, 2021; Hasan et al., 2022; Kumar et al., 2021; Lahmiri & Bekiros, 2019; Rodríguez, 2023; Sun et al., 2020; Vásquez et al., 2023; Zhang et al., 1998; Zhang et al., 2021). A través de sus contribuciones, se puede realizar una clasificación de estas redes y exponer sus respectivas estrategias.

En primer lugar, las redes neuronales artificiales o también conocidas como ANN, destacadas por Kumar et al., 2021, son las más básicas y son ampliamente utilizadas para el análisis de series de tiempo y predicción de tendencias. Estas utilizan un algoritmo de aprendizaje supervisado para entrenar sus parámetros internos para mejorar su precisión en las predicciones, llamada "*backpropagation*" (retro propagación). En su estudio específico, estos autores emplearon datos históricos de cuatro criptomonedas emergentes (Bitcoin, Litecoin, Ethereum y Ripple). Este tipo de redes son las más adecuadas para tareas sencillas de clasificación y regresión, pero no tienen memoria a largo plazo, lo que las hace inadecuadas para modelar secuencias complejas.

En la Figura 2 podemos observar una red ANN, donde podemos ver que en la parte izquierda tiene la capa de entrada que puede tener una o más salidas que van dirigidas a la capa intermedia, que sería la capa oculta, donde se realizan las ponderaciones, para acabar generando un resultado o varios en la capa de salida que tenemos en la derecha.

La retro propagación usa un valor de error que se calcula comparando los valores estimados con los valores reales, esta función se propaga hacia atrás para ajustar los parámetros de la red según la regla de gradiente descendente para que, de esta manera, consigamos un error más pequeño posible, y por lo tanto un modelo más ajustado.




Figura 2 Red Neuronal ANN

Fuente: <https://www.researchgate.net/publication/321259051/figure/fig1/AS:614329250496529@1523478915726/Artificial-neural-network-architecture-ANN-i-h-1-h-2-h-n-o.png>

Dentro de las redes neuronales un poco más desarrolladas podemos encontrar algunas como pueden ser las redes neuronales recurrentes o también conocidas como RNN, que son adecuadas para secuencias de datos, pero dentro de éstas hay algunas que tienen memoria a largo plazo y otras que no. Una variante especial, las *Long Short-Term Memory* (LSTM), son excelentes para capturar patrones a largo plazo en los datos. Lahmiri & Bekiros (2019) destacan que las LSTM son significativamente superiores en

comparación con otras arquitecturas. Son superiores porque la estructura de celdas de memoria que tienen les permite retener información durante periodos prolongados de tiempo ya que estas celdas almacenan información y deciden cuándo actualizarla o eliminarla, de esta manera se vuelven eficaces en el largo plazo.

En la Figura 3 podemos apreciar una red neuronal LSTM, donde podemos apreciar que internamente tiene memoria y son algo más complejas que las explicadas anteriormente.




Figura 3 Red neuronal LSTM

Fuente: [https://upload.wikimedia.org/wikipedia/commons/thumb/9/93/LSTM\\_Cell.svg/1200px-LSTM\\_Cell.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/9/93/LSTM_Cell.svg/1200px-LSTM_Cell.svg.png)

Siguiendo esta misma línea, Vázquez et al. (2023) afirman que el modelo LSTM generalmente supera a los modelos ARIMA, ya que pueden hacer frente a las no linealidades. También nos dicen que es importante los datos que se seleccionan para esta red, ya que no todos los datos son relevantes para la predicción de precio, por lo tanto, más datos no significa mejores resultados, prevaleciendo la calidad de los datos por encima de la cantidad.

En la Figura 4 podemos apreciar la red neuronal convolucional (CNN), como pasaba con las anteriores, podemos observar cómo está dividida en 3, una zona de entradas, una zona de salidas y una parte de ponderación, en el caso de esta red neuronal es más indicada para el procesamiento espacial, es decir para imágenes.

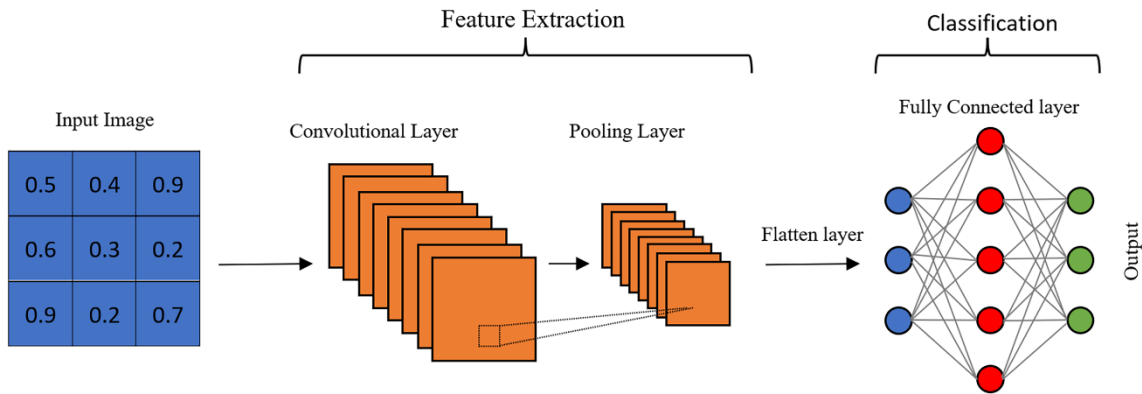


Figura 4 Red neuronal CNN

Fuente: <https://dfzjdn9uc3pi.cloudfront.net/2023/cs-1395/1/fig-1-full.png>

Éstas son adecuadas para analizar patrones espaciales, como podrían ser los gráficos de velas. Están compuestas por una capa convolucional, una capa de agrupación y capas totalmente conectadas. Hasan et al. (2022) utilizan esta red para filtrar entre una multitud de tweets y refinar estrategias de predicción.

En la Figura 5, se detalla una red neuronal Bi-LSTM. Estas redes son bidireccionales, como podemos observar son dos redes LSTM en paralelo donde una red LSTM procesa la secuencia de datos del pasado hasta el presente y la otra procesa los datos del presente hasta el pasado.




Figura 5 Red neuronal Bi-LSTM

Fuente: [https://miro.medium.com/v2/resize:fit:766/0\\*ZsTT3zzTNGF-6OsR.jpg](https://miro.medium.com/v2/resize:fit:766/0*ZsTT3zzTNGF-6OsR.jpg)

Básicamente esta red analiza los datos en los dos sentidos para posteriormente combinar la salida de ambas y generar la predicción. Lo que permite este tipo de red es tener un contexto completo del mercado, ya que le da una visión completa y contextualizada de los movimientos del mercado.

Como ocurría antes con las RNN, éstas también engloban las Bi-LSTM, que serían las que tienen memoria a largo plazo, en el fondo es como tener dos redes neuronales LSTM, una que procesa hacia un lado la información y la otra en el contrario. Esto genera una computación que necesita más recursos y, por lo tanto, es más costosa en tiempos de procesado. Este tipo de redes puede ser útil en situaciones donde el criptoactivo puede depender de algún evento o noticia. A pesar de su potencial, Hamayel & Owda (2021) indican que, en algunos contextos, las Bi-LSTM no necesariamente superan a las LSTM en términos de precisión.

En resumen, la elección de una red neuronal específica y la calidad de los datos que alimentan estos modelos son cruciales para el éxito en la predicción en criptomonedas, ya que cuanto mejor calidad tenga los datos y mayor número de datos tengamos, más precisa podrá ser nuestra predicción. Como podemos ver en la Figura 6, que contiene las redes neuronales anteriormente comentadas, cada red neuronal tiene una complejidad diferente, evidentemente los resultados son mejores cuanto más sofisticado es el sistema, pero hay que entrar a valorar si los recursos que se quieren destinar a implementar esos sistemas serían amortizados por los resultados obtenidos. Cada red neuronal tiene sus ventajas y sus inconvenientes.

La aplicación de las redes neuronales en el ámbito financiero ha proporcionado un gran número de herramientas en la predicción, además de poder dar una mejor gestión de riesgos ya que podemos evaluar qué riesgos potenciales tenemos y ayudar a la toma de decisiones. Por otro lado, también la parte de automatización de estrategias, y que podamos poner “un piloto automático” que nos vaya generando operaciones si se cumplen unos requisitos determinados y poder tener un análisis de sentimientos y pronósticos basado en noticias, ya que las redes neuronales pueden procesar grandes cantidades de datos no estructurados para poder extraer la información relevante.

Por tanto, la red que mejor se nos adapta al *bot* que se desea implementar es la LSTM, ya que estas son capaces de capturar patrones complejos en series temporales y son adecuadas para este tipo de predicciones además de que disponen de memoria.

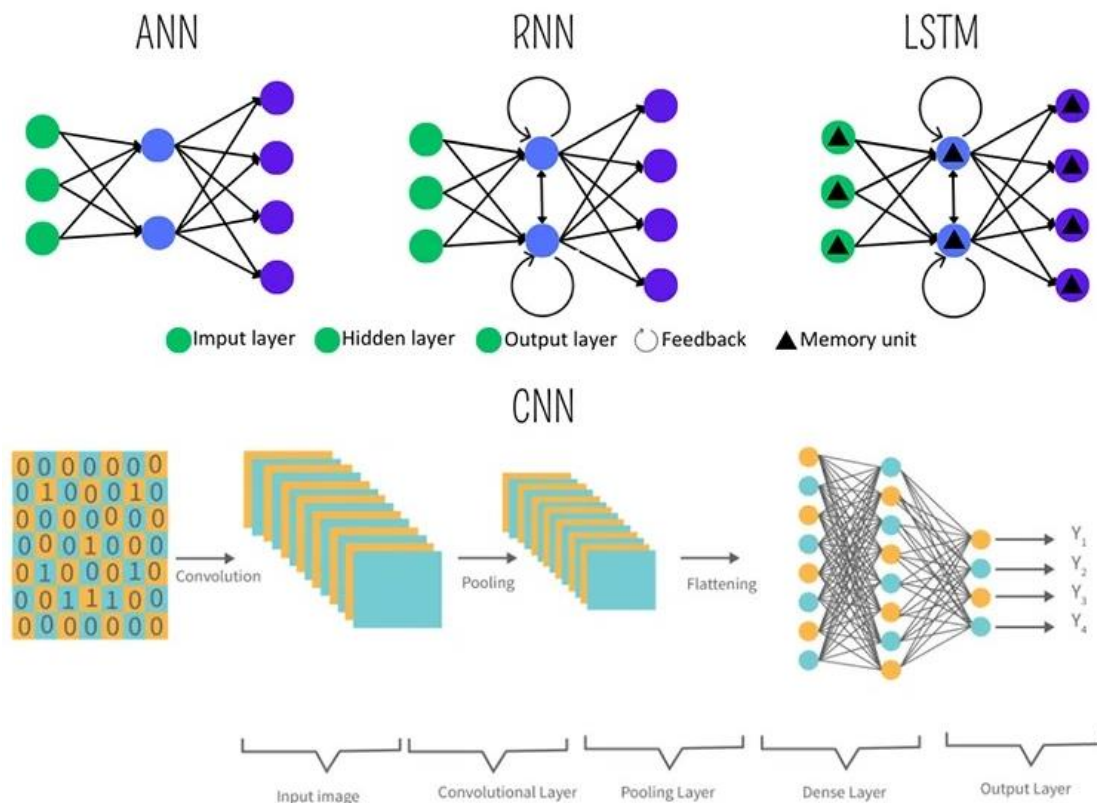


Figura 6 Resumen Redes Neuronales

Fuente: <https://equinoxailab.ai/wp-content/uploads/2023/03/artificial-neural-networks.webp>

## 2.1.2. Tipos de interacciones online en la predicción de precios

Las criptomonedas son activos volátiles y la percepción de los inversores juega un papel importante, ya que hay diferentes variables que pueden influir en la predicción del precio, al haber en el mercado muchos inversores no profesionalizados, hace que se genere esta volatilidad dejándose llevar más por sentimientos. De ahí la importancia de consultar las redes sociales o los índices de codicia y miedo. Las redes sociales, en particular Twitter (ahora conocida como "X"), se han convertido en la red social preferida para medir las opiniones y sentimientos en relación con estas monedas digitales. Tal y como indican autores como Aslanidis et al. (2022), Park & Seo (2023), Youssfi et al. (2023), hay que ir más allá de una sola plataforma para obtener una visión completa. Youssfi et al. (2023) no solo se basan su análisis en Twitter sino también utilizan Google

news, lo que les permitió alcanzar correlaciones más ajustadas en sus modelos de predicción de precios usando redes neuronales LSTM. Park & Seo (2023), enfocándose exclusivamente en Twitter, encontraron un aumento del 3% en el rendimiento de su modelo respecto a métodos tradicionales. Concluyeron que la antigüedad de los tweets también influyó en la precisión de sus predicciones, siendo aquellos tweets de un día de antigüedad los más reveladores en comparación con los de 3 y 7 días.

Por otro lado, Aslanidis et al. (2022) se centraron en Google Trends, identificando una relación bidireccional entre las tendencias de búsqueda y los rendimientos diarios de las criptomonedas. Esta relación se prolonga hasta 6 días y tan solo cinco palabras clave son necesarias para influir en el mercado. Esta relación no se limita solo a Bitcoin, sino que se extiende a otras criptomonedas. Es una evidencia de cómo las búsquedas online, aunque puedan parecer simplistas, tienen un impacto tangible en el comportamiento del mercado.

La digitalización de la información y las opiniones han creado un nuevo paradigma en la predicción de precios de criptomonedas. Eventos extremos, como que El Salvador acepte bitcoin como moneda de curso legal o que grandes bancos generen noticias alrededor de los cryptoactivos hace que se vea influenciado en el precio, y sea información muy relevante a la hora de tratar de predecir el precio.

En el fondo, al ser un activo digital, la gente busca información y es mucho más accesible ya que los inversores que podemos encontrar no solo son los tradicionales. Y al abrir estos activos a un nuevo público, podemos encontrar que el sentimiento puede llegar a ser más importante que la atención de un activo, la prueba está en que cuando Elon Musk dice de invertir en una criptomoneda, la gente en masa replica ese movimiento con afán de conseguir una gran rentabilidad sin ser un activo que antes tuviese una especial atención en el mercado. Esto es así, porque principalmente no hay fundamental, las criptomonedas son su utilización o uso su único valor intrínseco.

## 2.2. Mercados eficientes

Para identificar y aprovechar las ineficiencias del mercado, es fundamental comprender la Hipótesis de Mercado Eficiente (HME). Según esta teoría, los precios de los activos financieros reflejan toda la información disponible en el momento, por tanto, siempre son justos y correctos, es decir, no encontraremos ganancias fáciles o, dicho de otra manera, no hay manera, de ganar al mercado porque reflejan el valor real del activo (Brealey et al., 2019).

Para tratar de sintetizar esta teoría, podemos extraer 5 grandes lecciones:

- Los mercados no tienen memoria, es decir, la hipótesis defiende que las secuencias de variaciones pasadas no contienen información de las variaciones futuras. Un ejemplo claro es el impacto de noticias inesperadas en el mercado, como la aprobación del ETF de bitcoin, que alteró significativamente el precio antes de ser conocido por la mayoría.
- Confiar en los precios del mercado, dentro de un mercado eficiente, el precio recoge toda la información disponible sobre el activo, por lo tanto, se puede confiar en su valor.
- Leer con profundidad, siguiendo con la lección anterior, en un mercado eficiente el precio tiene toda la información oculta, por tanto, saber leer con detalle y saber interpretar los precios, nos puede indicar mucho sobre el futuro del activo.
- En un mercado eficiente, los inversionistas actúan racionalmente, desinvirtiendo en activos que ya no cumplen con sus expectativas.
- Autonomía de los Inversores: Los inversores en un mercado eficiente no necesitan pagar por servicios que pueden realizar por sí mismos, a menos que posean información exclusiva.
- Homogeneidad de las Acciones: Desde esta perspectiva, todas las acciones son intercambiables, y la elección se basa únicamente en el rendimiento esperado.

En el caso concreto de los criptoactivos se ha encontrado que la hipótesis del mercado eficiente no se ha cumplido adecuadamente, sobre todo en altcoins y meme coins (Bariviera, 2017; Shen et al., 2020).

Este incumplimiento de la HME puede ser debido a comportamientos de manada inducidos por la especulación o por sesgos cognitivos que producen ilusiones financieras (Barberis et al., 2002; Kahneman & Smith, 2002).

El objetivo de este trabajo es captar estas ineficiencias temporales para poder explotarlas mediante una estrategia de negociación que permita obtener rendimientos superiores o extraordinarios.

### 3. Metodología y datos

Dentro de todas las posibles acciones al realizar una estrategia de trading para tratar de predecir de manera más certera el precio de los criptoactivos seleccionados, se ha escogido una red neuronal LSTM que tenga en cuenta las iteraciones de X (antigua *Twitter*) y Google trends, con una escala de tiempo de 1 día. La moneda que se va a realizar el análisis va a ser bitcoin, ya que es la criptomoneda por excelencia, la primera de todas. También se ha decidido desarrollar diversas estrategias para poder comparar el rendimiento de la estrategia seleccionada. Para poder hacer un análisis más ajustado se ha tomado la decisión de centrar la investigación en 90 días del precio del activo, concretamente, del 1 de enero al 31 de marzo de 2024.

#### 3.1. Recopilación de Datos

Primero, hemos de preparar los datos históricos del precio de bitcoin, hemos de conseguir los datos históricos y dividirlos en conjuntos de entrenamiento y prueba para poder alimentar la red neuronal. Para ello se extraen los datos históricos de precios de bitcoin de Yahoo finance, los cuales serán proporcionados a la red neuronal, a pesar de que nuestra predicción será en una parte muy pequeña de la secuencia de datos que se van a proporcionar. Los datos los extraemos mediante la librería “yfinance” usando

Python, ya que esta librería<sup>1</sup> nos permite descargar datos a diferentes frecuencias y proporcionando información detallada de los precios de cierre, máximos, mínimos o volumen de transacciones. En el caso concreto de nuestro *bot* usamos la moneda euro con un intervalo de 1 día. Como podemos apreciar en la Figura 7, el precio de bitcoin ha ido experimentando diferentes etapas de crecimiento y decrecimiento siendo un activo bastante volátil, especialmente notable en el período comprendido entre 2021 y 2024.



Figura 7 Precio histórico de Bitcoin

Fuente: Creación propia con los datos extraídos en Yahoo Finance

Además de los precios históricos de bitcoin, la red neuronal también ha de considerar otros tipos de datos, en este caso, también consideramos los datos de Twitter para poder realizar un análisis de sentimiento del inversor para poder determinar de una manera más precisa la variación del precio del activo.

Nuestra red neuronal incorpora el análisis del sentimiento de los inversores a través de datos extraídos de Twitter. Según Sattarov et al. (2020) existe una fuerte correlación entre la fluctuación porcentual de bitcoin y el sentimiento en Twitter. Se utilizará el API

---

<sup>1</sup> La librería es muy fácil de usar, tiene unos parámetros principales, que son el ticker, start, end y el interval. Donde el ticker es el símbolo de la criptomoneda, el start y el end son la fecha de inicio y de fin de los datos que se quieren descargar y el Interval es la frecuencia de los datos

de Twitter para recopilar diariamente tweets con *hashtags* específicos, en nuestro caso, #Bitcoin y #BTC. Estos tweets se clasificarán como positivos, negativos o neutrales, proporcionando tres variables diferentes para nuestra red neuronal. Esta clasificación se realiza mediante PLN (Procesamiento de lenguaje natural). Para ello, primero obtenemos los tweets relacionados, clasificamos estos tweets y los ponderamos siendo 1: positivo, 0: neutral y -1: negativo, se alinean temporalmente con el precio y se entrena la red con las características adicionales.

Del mismo modo, también consideramos los datos de Google trends (Google, 2024a) como relevantes, ya que es un indicador que nos dice las veces que la gente realiza la búsqueda en Google de la criptomoneda, siendo otra fuente de datos a alimentar en nuestra red. La mayoría de los inversores en criptomoneda se informan principalmente a través de internet, según Bianchi, (2024), la cuota de mercado mundial de búsquedas de Google es del 86,6%, por lo tanto, Google trends se considera como medida fiable de las búsquedas en línea. La integración de estos datos en nuestro modelo busca refinar nuestras predicciones, aprovechando el impacto de la información disponible en internet sobre las decisiones de los inversores en criptomonedas.

En la Figura 8 podemos apreciar la evolución del interés de la gente que busca en Google información sobre el precio del activo en un periodo de 90 días, concretamente, del 1 de enero al 31 de marzo de 2024, que es donde vamos a centrar nuestro análisis y nuestros datos testeados.




Figura 8 Evolución interés en Bitcoin periodo del 1 de enero al 31 de marzo de 2024

Fuente: <https://trends.google.es/trends/explore?date=today%203-m&q=bitcoin&hl=es>

### 3.2. Diseño del Bot de Trading

Antes de hacer el desarrollo y diseño de nuestra red neuronal, es esencial definir claramente las entradas que la alimentarán. Como se puede apreciar en la Figura 9, nuestra red se alimenta de tres entradas principalmente, tal y como se detalló anteriormente: precios históricos de Bitcoin, análisis de sentimiento de Twitter y tendencias de búsquedas de Google. Estas entradas son fundamentales para la generación y estructuración de nuestra red neuronal, la cual, a través de varias capas y una arquitectura específicamente diseñada, desarrollará la capacidad de predecir variaciones en el precio de Bitcoin.

Para implementar nuestra red neuronal, se decide usar la plataforma de Google Colab (Google, 2024b). Esta plataforma nos permite poder desarrollar toda la red neuronal y todos los requisitos que queremos valorar en nuestro *bot*.

Además, esta elección nos permite concentrarnos en el diseño y la optimización de la red sin preocuparnos por limitaciones de hardware, y garantiza la reproducibilidad de nuestro trabajo en un entorno accesible y ampliamente utilizado. Ya que, Google Colab es una plataforma de computación en la nube, que nos permite poder escribir y ejecutar Python directamente en el navegador, siendo una gran ventaja el poder acceder remotamente a nuestro proyecto con una simple conexión a internet y además aprovechando los recursos gratuitos que nos proporciona Google. Como es una plataforma que fue diseñada para tareas de análisis de datos y aprendizaje automático, ofrece una solución muy optimizada gracias a su procesamiento de datos sin necesidad de configurar el hardware local. Además, otro punto muy positivo es que, al ser una plataforma de Google, podemos usar herramientas como Google drive, para un mejor almacenamiento y manejo de archivos.

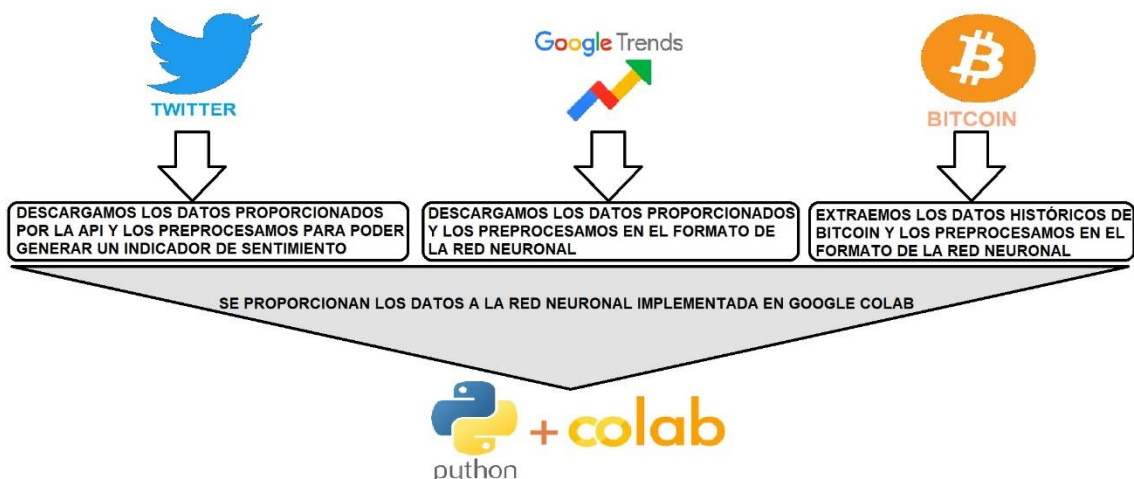


Figura 9 Entadas red neuronal

Fuente : Creación propia

El desarrollo de la red se lleva a cabo utilizando Python, lenguaje de programación ampliamente reconocido por su eficacia en proyectos de aprendizaje automático u ciencia de datos. El primer paso consiste en importar las diferentes librerías<sup>2</sup> que son necesarias para el desarrollo, seguidamente cargamos el conjunto de datos que hemos comentado en el apartado anterior y definimos la arquitectura del modelo, es decir, número de neuronas, funciones de activación, etc.

Posteriormente, también compilamos el modelo y por último entrenamos el modelo con nuestros datos para que finalmente podamos hacer nuestras predicciones sobre los precios de Bitcoin.

La importancia de la cantidad de datos de entrenamiento y la complejidad de la arquitectura de la red neuronal se evidencia claramente en nuestras pruebas. En la figura 10 se observa una predicción muy mal ajustada al precio real del activo, lo cual indica un ajuste inadecuado del modelo.

---

<sup>2</sup> Principales librerías utilizadas:

-Pandas: Manipulación de datos      -Matplotlib/Seaborn: Creación de gráficos      -Tensorflow      -Tweepy  
-NumPy: Operaciones numéricas      -Yfinance: Descarga de datos BTC      -Scikit-learn      -TextBolb

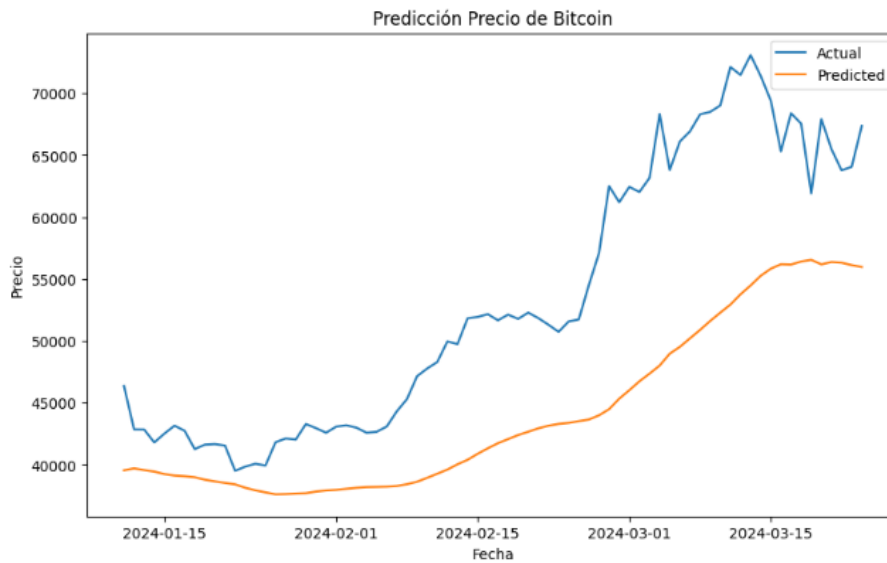


Figura 10 Predicción Precio de Bitcoin mal ajustada

Fuente: Creación propia resultado LSTM

En cambio, la Figura 11 muestra una predicción notablemente más cercana al precio real. Esta mejora se atribuye a la inclusión de un mayor volumen de datos de entrenamiento, lo que permite que el modelo capture con más precisión las tendencias y patrones subyacentes del mercado. Además, la implementación de capas adicionales en la red, diseñadas para un análisis más profundo, ha resultado en una representación más refinada de los datos, estas modificaciones en la estructura de la red han facilitado unas predicciones que se alinean mejor con la realidad, demostrando la superioridad de una arquitectura más elaborada en comparación con una más simple.

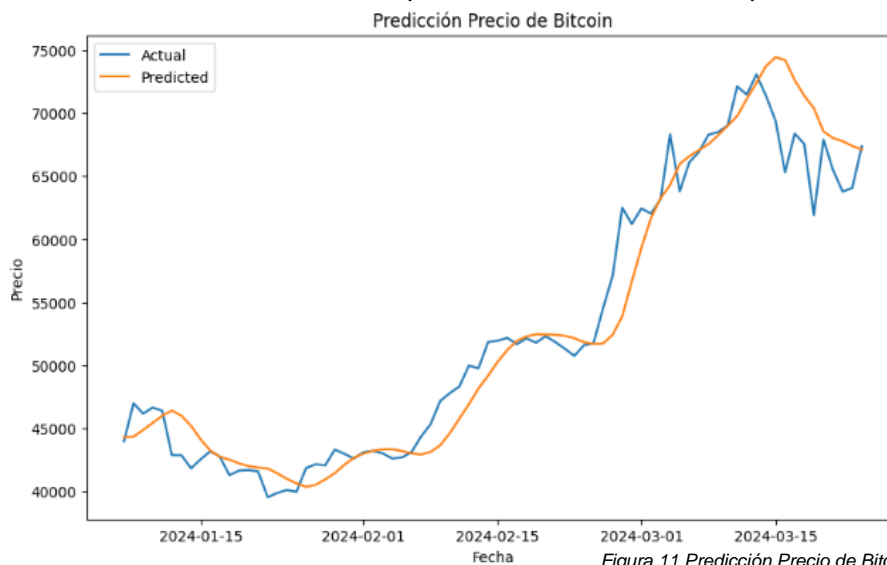


Figura 11 Predicción Precio de Bitcoin ajustada

Fuente: Creación propia resultado LSTM

También hay que destacar que en el diseño del *bot* se ha tenido en cuenta el “*overfit*”, es decir, el sobreajuste. Este es un problema común en el aprendizaje automático como es el caso de las redes neuronales LSTM. Este sobreajuste suele suceder cuando el modelo aprende a ajustarse demasiado a los datos de entrenamiento y no es capaz de diferenciar entre los patrones y el ruido aleatorio presente en los datos, y de esta manera, pierde su capacidad de generalización y no funciona de manera adecuada con datos nuevos no vistos en el entrenamiento.

Para solucionar el problema del sobreajuste, este *bot* implementa la técnica del “*Early stopping*”, que monitorea la pérdida en un conjunto de datos y detiene el entrenamiento cuando dicha pérdida comienza a aumentar considerablemente, señalando el inicio del sobreajuste. En el caso específico del *bot*, se define un límite máximo de pérdida, que en nuestro caso, se ajusta a 1000€, pero es completamente ajustable en cualquier momento, y es comparada constantemente con el error absoluto medio, una vez se supera ese límite si la pérdida no mejora durante las 5 siguientes iteraciones de la red, el entrenamiento se detiene, en caso de que vuelva a ajustarse y bajar del valor máximo, la red espera a sobrepasar de nuevo el valor definido.

También, se introduce una capa “*dropout*” entre las capas LSTM, diseñada para prevenir que las neuronas se especialicen en ciertos patrones ya que durante el entrenamiento apaga de forma aleatoria un porcentaje de las neuronas utilizadas.

Aunque tengamos en cuenta estas dos soluciones para evitar el sobreajuste, esto no significa que el modelo no pueda tenerlo, ya que estas técnicas ayudan a mitigarlo, pero no lo eliminan por completo. Para ello, la validación continua de los resultados del modelo contra un conjunto de datos de prueba independiente es esencial para asegurar la fiabilidad y la generalización de las predicciones del *bot*.

## 4. Resultados

### 4.1. Desempeño del Bot de Trading

Para poder ver el desempeño del *bot*, hemos de repasar la estrategia implementada. Como se ha comentado en el apartado anterior, se ha desarrollado una red neuronal LSTM, ya que estas son capaces de capturar patrones complejos en series temporales y son adecuadas para este tipo de predicciones. Además, esta red es alimentada con datos históricos de precios, el sentimiento en las redes sociales, en nuestro caso Twitter, y las búsquedas realizadas por los inversores en Google. Se ha centrado el análisis en una única criptomoneda, Bitcoin, la moneda que lo inicio todo. Además, se ha implementado un sistema de “*early stopping*” y una capa de “*dropout*” para evitar el sobreajuste. Por último, se realiza una predicción a 30 días vista para poder ayudar a la decisión de compra del activo, concretamente, del 1 al 30 de abril de 2024, en el caso del *bot*, en este caso se utilizan estos 30 días posteriores diferentes al periodo previo de 90 días analizado, ya que se trata de datos futuros y esto nos ayuda a ver que tanto se dispersa la estimación y nos ayuda a la toma de decisiones.

Teniendo esto claro, para evaluar la rentabilidad y los riesgos asociados se ha decidido tener en cuenta 4 indicadores (MAE, MASE, MSE y SMAPE) y además comparar la rentabilidad contra 4 estrategias distintas (*Buy and Hold*, *random*, *DCA*, *EMAs*). A continuación, se detallan los indicadores y las estrategias utilizadas en este trabajo.

#### Indicadores:

- MAE (*Mean absolute error*): El indicador del error absoluto medio, es el que se ocupa de medir la media de las diferencias absolutas entre las predicciones del modelo y los valores reales.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i|$$

Donde:

- $n$  es el número de observaciones (en nuestro modelo, como entramos datos diarios  $n$  son el número de días, es decir, 90 días.)
  - $y_i$  son los valores reales
  - $x_i$  son las predicciones del modelo
- **MASE (*Mean absolute scaled error*):** El indicador del error absoluto escalado, compara el error absoluto medio de un modelo de predicción con el error de un modelo de referencia.

$$MASE = \frac{\frac{1}{n} \sum_{i=1}^n |y_i - x_i|}{\frac{1}{h} \sum_{i=n+1}^{n+h} |y_i - y_{i-1}|}$$

Donde:

- $n$  es el número de observaciones (en nuestro modelo, como entramos datos diarios  $n$  son el número de días, es decir, 90 días.)
  - $y_i$  son los valores reales
  - $x_i$  son las predicciones del modelo
  - $h$  es el horizonte de pronóstico
  - $y_{i-1}$  son los valores reales desplazados por  $h$  períodos
- **MSE (*Mean squared error*):** El indicador del error cuadrático medio, es parecido al MAE pero en vez de coger la diferencia absoluta entre predicción y el valor real, se coge el cuadrado de esa diferencia y se promedian para obtener el error.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2$$

Donde:

- $n$  es el número de observaciones (en nuestro modelo, como entramos datos diarios  $n$  son el número de días, es decir, 90 días.)
- $y_i$  son los valores reales
- $x_i$  son las predicciones del modelo

- *sMAPE (Symmetric Mean absolute percentage error)*: El indicador del error porcentual absoluto medio simétrico, mide el error porcentual promedio entre predicciones y valores reales, considerando a ambos en la ecuación, esto es lo que lo convierte en simétrico.

$$sMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - x_i|}{(|y_i| + |x_i|)/2} * 100\%$$

Donde:

- $n$  es el número de observaciones (en nuestro modelo, como entramos datos diarios  $n$  son el número de días, es decir, 90 días.)
- $y_i$  son los valores reales
- $x_i$  son las predicciones del modelo

### Estrategias:

- *Buy and hold*: La estrategia de comprar y mantener, esta es una de las estrategias más simples, simplemente se trata de comprar en el momento que se inicia el análisis y mantener esa compra hasta el horizonte de venta que hayamos planteado y ver qué porcentaje de pérdidas y ganancias hemos obtenido. Este tipo de estrategias son muy efectivas a largo plazo ya que históricamente el activo siempre ha ido aumentando su valor, aunque haya tenido caídas importantes por el medio.
- *DCA (Dollar cost averaging)*: La estrategia de rentabilidad media, esta estrategia es una de las más seguras al largo plazo ya que lo que hace, en el fondo, es promediar el precio de compra. Lo que hace esta estrategia es comprar el activo en periodos  $x$  de tiempo independientemente de su precio, es decir en lugar de intentar comprar en precios bajos y vender en precios altos, lo que hace es

realizar compras periódicas para suavizar el impacto de la volatilidad, y olvidarse del corto plazo.

- EMAs (*Exponencial moving average*): La estrategia de media móvil exponencial, se utiliza dos o más EMAs con diferentes periodos de tiempo y cuando estas EMAs se cruzan en el gráfico se considera como una señal de compra o venta dependiendo si el cruce ha sido por encima o por debajo de la EMA con un periodo de tiempo superior si es por arriba se considera señal de compra y si es por debajo de venta. Este tipo de estrategias van muy bien para identificar tendencias del activo.
- *Random*: La estrategia aleatoria, esta estrategia es una de las más arriesgadas de las que hemos planteado, ya que únicamente lo que hace es comprar y vender de manera aleatoria sin tener consideración de los indicadores. Se ha ajustado a un *bot* automático que aleatoriamente ejecute acciones de venta y de compra para poder observar que ocurriría y si consigue rendimientos más altos de lo que somos capaces de conseguir con el resto de las estrategias.

Pero antes de compararlo con los indicadores y las estrategias vamos a valorar que tal se ha comportado el *bot* que se ha desarrollado (Figura 12 y Tabla 1).

A modo de comportamiento del *bot*, hemos apreciado que cuanto mayor era el número de datos de precio que añadíamos, mejor resultado obteníamos, y que las iteraciones de noticias y redes sociales no han acabado de dar el resultado óptimo que esperábamos, aunque, en algunos casos, sí que ha ayudado a la predicción.

En cuanto a indicadores hemos obtenido un MAE de 1776.74, un MASE de 0.99, un MSE de 6792314.24 y un SMAPE de 3.24%.

Como podemos apreciar en la Figura 12, los datos y la predicción reales son cercanos con algunos puntos de divergencia notable. Para una comprensión detallada de estas diferencias, la Tabla 1 ofrece una comparación directa entre los precios predichos y los reales, facilitando un análisis más profundo de la efectividad de nuestro *bot* en términos de precisión y fiabilidad.



Figura 12 Predicción precios LSTM

Fuente: Creación propia

Fecha	Real	Predicho
2023-01-31	23139.283203	23614.185547
2023-02-01	23723.769531	23594.642578
2023-02-02	23471.871094	23685.519531
2023-02-03	23449.322266	23770.236328
2023-02-04	23331.847656	23830.871094
...	...	...
2024-03-20	67913.671875	67798.132812
2024-03-21	65491.390625	67361.539062
2024-03-22	63778.761719	67300.398438
2024-03-23	64062.203125	66996.609375
2024-03-24	67373.453125	66752.867188

Tabla 1 Precio Real vs Precio predicho

Fuente: Creación propia

Observando estas discrepancias, se ha probado de tomar el *bot* como un indicador de tendencias, en vez de un *bot* automático que nos realice las órdenes de compra y venta en el mercado directamente.

Se ha podido comprobar que, haciendo un buen análisis previo antes de realizar las opciones de compra y de venta, da mejores resultados (entorno al 5 - 10% superior) que no dejar toda la decisión a la red neuronal, es decir, aunque el *bot* nos indique comprar o vender se debe de repasar el resultado ya que, al ser un mercado tan volátil, es más fácil que nosotros detectemos cosas inusuales que la red neuronal no es capaz. Este análisis previo se puede simplificar en cuatro pasos.



Con el resultado que obtenemos de la red neuronal, se compara con otros indicadores y otras estrategias para poder detectar discrepancias entre estrategias o similitudes, dando siempre un mayor peso a nuestra estrategia implementada, donde si coincide el resultado, podemos considerar la operación como menos arriesgada. Posteriormente, se analiza la parte fundamental que el *bot* no está contemplando como, pueden ser, diferentes eventos relativos al precio, tanto positivos como negativos que pueden afectar directamente al precio. Si no hay ningún elemento que pudiese hacer variar el precio de manera considerable a la orden que íbamos a ejecutar, ejecutamos la orden de compra o de venta.

En cuanto a compararlo con las demás estrategias, se ha hecho un análisis, estrategia por estrategia, para determinar cuál de ellas tiene una mayor rentabilidad en un periodo de 90 días, concretamente, del 1 de enero al 31 de marzo de 2024, que es donde vamos a centrar nuestro análisis y nuestros datos testeados.

En la Tabla 2 se puede observar el resultado sintetizado de este análisis.

En la primera columna, podemos apreciar la estrategia que se ha tomado, tenemos las anteriormente comentadas y además cuatro estrategias para nuestro *bot*. En el caso específico de nuestro *bot*, valoramos cuatro escenarios, de menos a más riesgo, es

decir, se decide tomar las transacciones tomando más o menos riesgo. Este ajuste se realiza ajustando de una manera más restrictiva los *stop loss* y los *take profits*.

En la segunda columna, podemos apreciar el número de transacciones que ha realizado el *bot*. El número de transacciones serían las órdenes de compra o venta en el mercado. Y, por último, en la tercera columna tenemos la rentabilidad que hemos obtenido con cada uno de los casos.

Estrategia	Nº de transacciones	Rentabilidad
Buy & hold	2	62.487%
Random	3	10.723%
DCA	4	15.895%
EMAs	7	56.616%
Bot muy conservador	5	62.025%
Bot conservador	9	60.354%
Bot arriesgado	23	65.652%
Bot muy arriesgado	35	75.698%

Tabla 2 Comparación rentabilidad de las estrategias para el periodo del 1 de enero al 31 de marzo de 2024

Fuente: Creación propia

Claramente se observa que la estrategia de *buy and hold* es la estrategia que mejor rendimiento ha generado, un resultado influenciado por el contexto de un mercado alcista, impulsado por noticias muy positivas para Bitcoin. Eventos como la aprobación del ETF (“Exchange Traded Funds”) de Estados Unidos, este ETF<sup>3</sup> fue aprobado el 10 de enero de 2024. Otro evento muy significativo es el *halving* de bitcoin, realizado en abril de 2024, este es un evento programado que ocurre aproximadamente cada cuatro años, donde se reduce a la mitad la recompensa que reciben los mineros por validar y agregar nuevos bloques a la cadena de Bitcoin. Este evento tiene la intención de controlar la inflación de Bitcoin y regular la oferta de nuevas monedas en circulación, al reducirse la cantidad de Bitcoins de creación nueva, genera una escasez relativa que puede aumentar su valor a largo plazo.

---

<sup>3</sup> Fondo cotizado en bolsa que permite a los inversionistas acceder a bitcoin por medio de un vehículo de inversión tradicional que se negocia en la bolsa de valores, es decir, aquellos que no quieren lidiar con la seguridad o el almacenamiento de la criptomoneda, simplemente poseen acciones del ETF que a su vez este posee Bitcoin, la ventaja de esto es que los ETF están sujetos a regulaciones y deben cumplir con los requisitos establecidos por la SEC (Comisión de valores y bolsa) antes de operar en los mercados

Estos dos eventos han tenido un impacto directo en el precio del activo ya que, al verse reducida la capacidad de generación de nuevos Bitcoins, y que la compra de Bitcoin se ha institucionalizado más, más agentes pueden acceder al activo que se encuentra limitado, y por lo tanto, esto genera un escenario alcista donde el precio aumenta su valor. Sin embargo, es importante reconocer qué tanto la estrategia de *buy and hold* como DCA, en un mercado bajista, no obtendrían esta rentabilidad tan alta debido a que por el propio movimiento del mercado irían hacia abajo.

Por otro lado, la estrategia *random* aunque generalmente considerada como la menos efectiva, ha logrado generar rentabilidad, subrayando el impacto del mercado alcista actual en todas las estrategias evaluadas. Sin embargo, en condiciones de mercado menos favorables, es probable que esta estrategia no sostenga el mismo nivel de éxito.

Las dos estrategias que podrían mantenerse en un mercado bajista serían la estrategia de EMAs y la del *bot* que se ha diseñado. Ambos enfoques, al actuar sobre señales específicas de compra y venta derivadas del análisis técnico, han demostrado ser más adaptativos a las fluctuaciones de mercado. El resultado del *bot*, aunque no sea el de mayor rentabilidad, se podría considerar como muy positivo.

## 4.2. Impacto de las Tendencias de Twitter y Google Trends

En este *bot* hemos tenido dos indicadores externos al precio de bitcoin, que han sido Twitter y Google trends, en este apartado, valoraremos su utilidad en el *bot*.

Twitter, al ser una plataforma activamente utilizada por inversores en criptomonedas, ofrece información valiosa para el análisis del sentimiento de mercado. Sin embargo, la dificultad de filtrar de forma eficaz el ruido y el impacto de los *bots* limita su fiabilidad. Para nuestro análisis, se han generado tres señales de los datos extraídos, siendo una positiva, una negativa y una neutra y con la suma de las tres poder sacar un indicador. El problema de esta red social y de cualquier otra que analicemos es que siempre tendremos el factor de riesgo que pueda ser alterada mediante *bots* que hagan que nuestros indicadores puedan dar opciones de compra erróneas.

Por otro lado, aunque Google trends es una herramienta útil para capturar el interés general en Bitcoin, sus limitaciones, como la falta de datos concretos sobre el volumen de búsqueda y la ambigüedad en la interpretación de los porcentajes, limitan su utilidad en hacer predicciones precisas.

Por último, también habría que tener en cuenta que los datos pueden ser manipulados por *bots*, haciendo aumentar artificialmente el número de búsquedas y, por tanto, alterarnos el resultado y si tenemos automatizada una estrategia, hacernos comprar el activo en momentos que no serían los ideales, son factores para tener en cuenta.

## 5. Conclusiones

El objetivo de este TFM era poder realizar un *bot* para tratar de predecir el precio de Bitcoin, por medio de una red neuronal LSTM, teniendo en cuenta las iteraciones de Twitter y Google Trends, a escala de tiempo de 1 día, en un periodo de 90 días, concretamente, del 1 de enero al 31 de marzo de 2024.

En cuanto al *bot*, podemos determinar que el resultado es positivo, aunque en ocasiones no es del todo preciso se ha podido ver que, si se complementa el análisis realizado por el *bot* con unos *stop loss* y *take profits* bien medidos en el mercado de futuros del activo, el *bot* se convierte mucho más fiable y la tasa de acierto se vuelve mayor y, por lo tanto, es un indicador que se puede tener en cuenta para nuestra estrategia de trading.

En cuanto al rendimiento comparado con las otras estrategias, el *bot* no ha conseguido estar en la estrategia con mayor rentabilidad debido al mercado alcista bajo el que se ha realizado el análisis. Si esta casuística no llega a ocurrir, de las estrategias que se mantendrían con una rentabilidad positiva en un mercado bajista, sí que ha conseguido posicionarse como la estrategia más rentable y, por lo tanto, la estrategia a elegir.

En cuanto indicadores externos al precio propiamente, podemos sufrir de manipulación mediante *bots*, o no tener una correlación 100% al precio. El mercado de las criptomonedas al tratarse de un mercado tan volátil donde hay una gran competencia en *bots* de predicciones, en caso de detectar este tipo de *bots* que estén automatizados, pueden manipular la compra con publicaciones en las redes sociales o búsquedas en

los principales buscadores. Por este motivo, se debe prestar una especial atención y que un solo indicador no dé la opción de compra únicamente.

## 5.1. Limitaciones del trabajo

Una de las principales limitaciones en el trabajo ha sido a la hora de implementar la extracción de datos de la API de Twitter, ya que, con la nueva directiva de X, la extracción de datos se ha visto muy limitada, y la capacidad de análisis de los tweets se ha visto muy reducida ya que no permite hacer un gran análisis en específico y sería conveniente tener que pedir permisos especiales y específicos a la compañía para poder hacer un mejor uso de la información. Esto se ha tratado de hacer para poder ampliar de mejor manera el trabajo, pero a día que se realiza este análisis práctico (7 de junio de 2024), aún no se ha recibido contestación por parte de la empresa. Para solicitar estos permisos, se ha realizado una petición a un formulario donde debíamos explicar en detalle para qué queríamos estos permisos especiales y qué íbamos a hacer con los datos extraídos, y una persona debería de aprobarnos o rechazarnos esos permisos.

## 5.2. Recomendaciones para Futuras Investigaciones

Una de las posibles mejoras que se podrían realizar a este estudio es explorar otras fuentes de datos, ya que estas pueden ser nuevas capas añadidas al modelo que tenemos en funcionamiento y mejorar el resultado de nuestra predicción.

También se podrían testear nuevos modelos de redes neuronales que no se hayan planteado en el estudio, ya que quizás nos puede sorprender que algún modelo de red neuronal se adapte mejor que el que nosotros tenemos implementado.

También se podría plantear mejoras en el diseño del bot de trading. Ya que la manera en la que hemos implementado la red neuronal no tiene por qué ser la más eficiente, sino la que nosotros hemos encontrado que nos funciona de mejor manera.

## Bibliografía

- Akyildirim, E., Bariviera, A. F., Nguyen, D. K., & Sensoy, A. (2022). Forecasting high-frequency stock returns: a comparison of alternative methods. *Annals of Operations Research*, 313(2), 639–690. <https://doi.org/10.1007/s10479-021-04464-8>
- Aslanidis, N., Bariviera, A. F., & López, Ó. G. (2022). The link between cryptocurrencies and Google Trends attention. *Finance Research Letters*, 47. <https://doi.org/10.1016/j.frl.2021.102654>
- Barberis, N., Thaler, R., Brunnermeier, M., Constantinides, G., Daniel, K., Harris, M., Huang, M., Lamont, O., Ritter, J., Shleifer, A., Stein, J., & Vuolteenaho, T. (2002). *NBER WORKING PAPER SERIES A SURVEY OF BEHAVIORAL FINANCE*. <http://www.nber.org/papers/w9222>
- Bariviera, A. F. (2017). *The inefficiency of Bitcoin revisited: a dynamic approach*. <https://doi.org/10.1016/j.econlet.2017.09.013>
- Bautista, P. (2021). *Bot de Trading Automático en Mercados Financieros*. <https://oa.upm.es/67989>
- Bianchi, T. (2024, March). *Market share of leading search engines worldwide from January 2015 to January 2024*. <https://www.statista.com/statistics/1381664/worldwide-all-devices-market-share-of-search-engines/>. <https://www.statista.com/statistics/1381664/worldwide-all-devices-market-share-of-search-engines/>
- Brandon, C. (2023, October). *Today's Cryptocurrency Prices by Market Cap*. <https://coinmarketcap.com/>
- Brealey R, Myers SC, & Allen F. (2019). *Principles of Corporate Finance*. 13th ed.
- Catania, L., & Grassi, S. (2022). Forecasting cryptocurrency volatility. *International Journal of Forecasting*, 38(3), 878–894. <https://doi.org/10.1016/J.IJFORECAST.2021.06.005>

- Dunbar, K., & Owusu-Amoako, J. (2023). Predictability of crypto returns: The impact of trading behavior. *Journal of Behavioral and Experimental Finance*, 39, 100812. <https://doi.org/10.1016/J.JBEF.2023.100812>
- Freeman, J. A., & Skapura, D. M. (1991). *Neural networks : algorithms, applications, and programming techniques*. Addison-Wesley.
- Google. (2024a). *Bitcoin-Explorar-Google Trends*. <https://Trends.Google.Es/Trends/Explore?Date=today%203-M&q=%2Fm%2F05p0rrx&hl=es>.  
<https://trends.google.es/trends/explore?date=today%203-m&q=%2Fm%2F05p0rrx&hl=es>
- Google. (2024b). *Google Colaboratory*. <https://Colab.Research.Google.Com/?Hl=es>.  
<https://colab.research.google.com/?hl=es>
- Hamayel, M. J., & Owda, A. Y. (2021). A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms. *AI (Switzerland)*, 2(4), 477–496. <https://doi.org/10.3390/ai2040030>
- Hasan, S. H., Hasan, S. H., Ahmed, M. S., & Hasan, S. H. (2022). A novel cryptocurrency prediction method using optimum cnn. *Computers, Materials and Continua*, 71(1), 1051–1063. <https://doi.org/10.32604/cmc.2022.020823>
- Kahneman, D., & Smith, V. (2002). *Advanced information on the Prize in Economic*.
- Kumar, C. S., Behera, A. K., Nayak, S. C., & Dehuri, S. (2021). QORA-ANN: Quasi Opposition Based Rao Algorithm and Artificial Neural Network for Cryptocurrency Prediction. *2021 6th International Conference for Convergence in Technology, I2CT 2021*. <https://doi.org/10.1109/I2CT51068.2021.9417870>
- Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, 35–40. <https://doi.org/10.1016/j.chaos.2018.11.014>
- Martín, C., Quintana, D., & Isasi, P. (2019a). Evolution of trading strategies with flexible structures: A configuration comparison. *Neurocomputing*, 331, 242–262. <https://doi.org/10.1016/j.neucom.2018.11.062>

- Martín, C., Quintana, D., & Isasi, P. (2019b). Evolution of trading strategies with flexible structures: A configuration comparison. *Neurocomputing*, 331, 242–262. <https://doi.org/10.1016/J.NEUCOM.2018.11.062>
- Moreno García, E., Cotera, D. V., Mejía, S. H., Alberto, L., & Ojeda, L. (2015). *Interdependencia de los mercados de valores en el mundo\* Interdependence of the Stock Markets around the World*.
- Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. [www.bitcoin.org](http://www.bitcoin.org)
- Rodríguez, J. M. (2023). *DevelopmentOfACryptocurrencyBot*.
- Shen, D., Urquhart, A., & Wang, P. (2020). Forecasting the volatility of Bitcoin: The importance of jumps and structural breaks. *European Financial Management*, 26(5), 1294–1323. <https://doi.org/10.1111/eufm.12254>
- Sun, X., Liu, M., & Sima, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32. <https://doi.org/10.1016/j.frl.2018.12.032>
- Torres, R., Solis, M. A., Salas, R., & Bariviera, A. F. (2020). A dynamic linguistic decision making approach for a cryptocurrency investment scenario. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.3045923>
- Vásquez, J., Quiroga, F. M., & Bariviera, A. F. (2023). Data vs. information: Using clustering techniques to enhance stock returns forecasting. *International Review of Financial Analysis*, 88. <https://doi.org/10.1016/j.irfa.2023.102657>
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks:: The state of the art. *International Journal of Forecasting*, 14(1), 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)
- Zhang, Z., Dai, H. N., Zhou, J., Mondal, S. K., García, M. M., & Wang, H. (2021). Forecasting cryptocurrency price using convolutional neural networks with weighted and attentive memory channels. *Expert Systems with Applications*, 183, 115378. <https://doi.org/10.1016/J.ESWA.2021.115378>