



Facultad de Ciencias Económicas y Empresariales

Estudio económico y cuantitativo de Bitcoin en el año 2023 y comparativa de cripto – robots

Autor: Mar González Hernández

Tutor: Luis Ángel Calvo Pascual

MADRID | Marzo 2023

RESUMEN

En este Trabajo de Fin de Grado se analiza de forma cuantitativa el precio diario de Bitcoin durante el periodo del 8 de marzo de 2022 hasta el 8 de marzo de 2023. Nuestro objetivo es establecer una comparativa entre diferentes estrategias de inversión a través de robots de *trading* cuantitativo programados en Python: análisis técnico, ajuste de curvas y técnicas de aprendizaje supervisado en *Machine Learning*.

Para ello, después del análisis macroeconómico del mercado se han seleccionados las variables más relevantes empleando modelos estadísticos y *mutual information*. Los resultados han demostrado que el precio de Bitcoin se ve afectado por las variables del mercado tradicional y los operadores del mercado financiero deberán tener en cuenta nuestras conclusiones para la gestión de sus carteras.

Se han entrenado y optimizado todos los modelos de regresión y clasificación de Matlab con el fin de incorporar el de mejor precisión a nuestro cripto – robot. El modelo con el menor RMSE fue un Proceso de Regresión Gaussiana que empleó las 6 variables más significativas de acuerdo al algoritmo de Mínima Redundancia y Máxima Relevancia: el Precio de Bitcoin el día anterior, US 10 Year Bond Yield, USD/EUR, Money Supply, NASDAQ y VIX Index. Este fue el mejor cripto – robot y registró una rentabilidad del 124% para el periodo de estudio.

Finalmente, presentamos un robot de *trading* basado en una nueva estrategia de tecnología avanzada que combina el análisis técnico y las predicciones de inteligencia artificial de un Proceso de Regresión Gaussiana. El modelo solo emplea los precios históricos como variable para que su empleo y funcionamiento en Bolsa sea realista.

Palabras Clave: Bitcoin, análisis técnico, selección de variables significativas, ajuste de curvas, *Machine Learning*, Proceso de Regresión Gaussiana, inteligencia artificial, cripto – robot, robot de *trading* cuantitativo.

ABSTRACT

In this Final Degree Project we analyze quantitatively the daily price of Bitcoin during the period from March 8, 2022, to March 8, 2023. Our objective is to establish a comparison between different investment strategies through quantitative trading robots programmed in Python: technical analysis, curve – fitting and supervised learning techniques in Machine Learning.

For this purpose, after the macroeconomic analysis of the market, the most relevant variables have been selected using statistical models and mutual information. The results have shown that the price of Bitcoin is affected by traditional market variables and financial market operators should take into account our conclusions for the management of their portfolios.

All Matlab regression and classification models have been trained and optimized in order to incorporate the one with the best accuracy to our crypto – robot. The model with the lowest RMSE was a Gaussian Regression Process that employed the 6 most significant variables according to the Minimum Redundancy and Maximum Relevance algorithm: the Bitcoin Price the previous day, US 10 Year Bond Yield, USD/EUR, Money Supply, NASDAQ and VIX Index. This was the best crypto – robot and recorded a 124% return for the study period.

Finally, we present a trading robot based on a new state – of – the – art strategy that combines technical analysis and artificial intelligence predictions from a Gaussian Regression Process. The model only uses historical prices as a variable to make its use and performance on the stock market realistic.

Keywords: Bitcoin, technical analysis, feature selection, curve – fitting, Machine Learning, Gaussian Regression Process, Artificial Intelligence, crypto – robot, quantitative trading robots.

ÍNDICE

<i>CAPÍTULO 1: INTRODUCCIÓN</i>	5
1.1 Contexto	5
1.2 Objetivo del TFG	16
1.3 Metodología y antecedentes.....	16
1.4 Estructura del TFG.....	21
<i>CAPÍTULO 2: MODELOS DESCRIPTIVOS, ANÁLISIS TÉCNICO Y CURVE FITTING</i>	23
2.1 Análisis técnico	23
2.2 Curve – fitting.....	36
<i>CAPÍTULO 3: FEATURE SELECTION Y MACHINE LEARNING</i>	41
3.1 Análisis económico de variables relevantes para el precio del Bitcoin	41
3.2 Feature selection	47
3.3 Machine Learning.....	53
<i>CAPÍTULO 4. COMPARACIÓN DE ROBOTS</i>	63
4.1 Robot de análisis técnico	63
4.2 Robot de <i>curve – fitting</i>	65
4.3 Robot Machine Learning	66
4.4 Robot de inteligencia artificial y análisis técnico	67
4.5 Métricas de comparación	69
<i>CAPÍTULO 5. CONCLUSIONES Y PRÓXIMAS LÍNEAS DE INVESTIGACIÓN</i>	71

CAPÍTULO 1: INTRODUCCIÓN

1.1 Contexto

En esta sección, primero explicaremos el **marco temporal** en el que se encuadra el trabajo de investigación y la inflación como una de las variables económicas que más afecta a la economía. También defenderemos el optimismo del mercado hasta principios de marzo de 2023, cuando se redacta este estudio, como una incongruencia ante el cuadro macroeconómico actual.

En el segundo punto introduciremos nuestro activo de estudio, el **Bitcoin**, y veremos de forma breve qué se espera de él en el futuro, además de algunos de los tipos de *trading* que se han llevado a cabo con cripto – robots operando con esta criptomoneda.

1.1.1. Políticas post – pandemia, guerra de Ucrania e inflación

Las presiones sobre los precios en 2022 fueron excepcionales y los países desarrollados presentaron una cifra de **inflación** no registrada desde 1980. En particular, Alemania alcanzó el nivel de dos dígitos por primera vez desde 1951 (The Economist, 2022).

Aunque la inflación en cada país obedece a numerosas peculiaridades, los incrementos de los **precios de la energía y alimentos** han sido factores de impulso comunes en todos ellos. Los precios de los bienes de consumo ya subían desde principios de 2022 por la crisis de las cadenas de suministro derivada de la paralización de la pandemia. Sin embargo, el comienzo de la guerra de Ucrania en febrero fue el elemento restante a la “tormenta perfecta” que seguimos experimentando todavía en marzo de 2023 sin perspectivas de mejora (The Economist, 2022).

La **invasión de Ucrania** y las sanciones de los países occidentales impuestas a Rusia condujeron al incremento del precio del petróleo, fertilizantes y transportes. Por ello, en 2022 presenciábamos una inflación derivada de una crisis de oferta clásica que se podía filtrar

rápidamente a los precios de los principales productos básicos para la población (The Economist, 2022); fenómeno conocido como inflación de segunda ronda y el más preocupante para los bancos centrales, encargados de salvaguardar la estabilidad de los precios (López, 2023).

El incremento de la **inflación subyacente** en Occidente actuó como señal de alerta y vino motivado por dos razones fundamentales: mercados laborales muy ajustados con salarios también elevados, y políticas monetarias expansivas dirigidas a reactivar la economía tras la paralización de 2020 que desembocaron en un sobrecalentamiento de la demanda y el consumo por parte de la población (The Economist, 2022).

Las **expectativas de inflación** ante el aumento de los precios, y con ello, la exigencia de la población de un aumento de los salarios – que agrava más aún la espiral inflacionista – fue precedente suficiente para que los bancos centrales anunciaran **subidas de tipos de interés** durante 2022. El impacto económico de esta medida será analizado con más detalle en el Capítulo 3, pero basta con mencionar que un exceso de contracción de la economía por parte de estas instituciones puede asegurar una posterior recesión a su población (The Economist, 2023).

Tras un año 2022 muy difícil en los mercados de renta variable y renta fija, a principios de 2023 los inversores descontaban que la estrategia de endurecimiento de los bancos centrales había llegado a su fin. Esto se reflejó en el mercado bursátil en una subida del SP500 de un casi 8% desde principios de año hasta mediados de febrero, o en la expectativa de que los beneficios empresariales en 2024 aumentarán casi un 10% (The Economist, 2023).

No es discutible que a principios de 2023 existían elementos que podrían interpretarse como **señales de recuperación económica**: las cadenas de suministro se habían recuperado de la ruptura del confinamiento y ya no estaban desbordadas por el aumento de la demanda de productos postpandemia, el precio del petróleo en la semana del 14 de febrero se situaba por

debajo del nivel anterior a la invasión de Ucrania, y la inflación general y sus factores descendieron en 25 de los 36 países más ricos de la OCDE (The Economist, 2023).

Pero los niveles de inflación general no son un claro indicio de la tendencia subyacente, y, como hemos mencionado, la última es la que preocupa a los bancos centrales. La inflación subyacente en Estados Unidos había crecido en los últimos tres meses a un ritmo anualizado del 4,6% y comenzaba a acelerarse, el crecimiento de los salarios seguía estando muy por encima del *target* de inflación del 2%, y la tasa de desempleo en Estados Unidos era la más baja desde 1969 (The Economist, 2023). Asimismo, el repunte de la inflación subyacente en la Eurozona del 5,3% al 5,6% reforzaba la abundante evidencia de que asistíamos a una inflación de segunda ronda que también presionaba en la dirección de mayores endurecimientos por parte del BCE (Koranyi, 2023).

En febrero de 2023 los bancos centrales no habían dado señales de un cambio en su política ni existían indicios para ello. Tanto la FED como el BCE tenían claro que no iban a cometer los errores de la crisis inflacionista provocada por el petróleo en la década de los 70. En ella, las instituciones pivotaron en sus políticas monetarias contractivas antes de lo necesario y los precios volvieron a explotar, minorando su credibilidad ante la población (The Economist, 2023).

En definitiva, en los inicios de 2023, el mercado se contradecía entre un optimismo de año nuevo y unas circunstancias económicas pésimas, paradigma que podía explotar en la Bolsa en cualquier momento y que propiciaría caídas más fuertes que las presenciadas en 2022 (The Economist, 2023).

1.1.2 Bitcoin

1.1.2.1 Conceptos generales

Bitcoin es una criptomoneda utilizada alrededor del mundo como medio de pago digital o, de forma más común, como **elemento especulativo con fines de inversión**. El valor añadido de la tecnología *blockchain* que sostiene al Bitcoin radica en la descentralización de la divisa, a diferencia de todas las monedas *fiat* que ya conocemos (Pandey et al., 2021).

El hecho de ser **descentralizada** implica que no hay ninguna autoridad que controle y respalde al Bitcoin como ocurre con el dólar y la Reserva Federal de Estados Unidos, o el euro y el Banco Central Europeo. Bitcoin no es propiedad de ninguna entidad y las transacciones realizadas con la moneda no están vinculadas a ningún país, lo cual entraña ventajas e inconvenientes para sus tenedores (Pandey et al., 2021).

Las operaciones con la criptomoneda se realizan a través de los *exchanges*, definidos como los mercados donde los usuarios pueden comprar y vender criptomonedas usando diferentes divisas. Funcionan como una billetera digital que se asemeja a las cuentas bancarias virtuales que manejamos para nuestras divisas oficiales, pero con una diferencia esencial: mientras que para una cuenta bancaria necesitamos aportar nuestros datos oficiales (DNI, domicilio, etc.), la creación de nuestra billetera virtual es lo que se convierte en nuestro número de serie o de identificación digital (Pandey et al. , 2021).

Lo primero que podría opinar el individuo es la **inseguridad** de operar con una moneda que no es controlada por ningún tipo de institución y que funciona a través de una tecnología en la que no existe una identificación oficial de los usuarios. Pero es la propia tecnología que respalda al Bitcoin la razón por la que las transacciones son seguras (Pandey et al. , 2021).

El sistema o la tecnología *blockchain* se basa en el registro de transacciones (en nuestro caso, compra o venta de Bitcoins) en una red digital descentralizada donde cualquier usuario tiene acceso pero no puede deshacer o reescribir lo ya registrado en ella. Una vez que se ejecuta

una transacción de la criptomoneda, se registra dicha transacción en un nuevo bloque que está a su vez unido a un bloque anterior formando una cadena de registros de información que no es maleable, como ocurre, por ejemplo, con nuestro Registro de la Propiedad (Pandey et al. , 2021). Según el principio de tracto sucesivo, cada titularidad registral debe apoyarse en una “asiento” (registro) anterior y vigente de forma que el acto que pretenda inscribirse derive de otro previamente escrito, y así el Registro refleje de manera perfecta la sucesión de transmisiones de un activo (Enciclopedia Jurídica, s.f.). Si analizamos la definición del sistema *blockchain* y la comparamos con el principio de tracto sucesivo de la Ley Hipotecaria, podemos afirmar que la filosofía es la misma (Martín Meneses, 2021): de la misma forma en que se necesita que el registrado como propietario de una vivienda sea el que protagonice el acto de venta para que el nuevo propietario pueda ser inscrito, cuando un usuario de la red de *blockchain* decide vender un Bitcoin, la información es igualmente comprobada y registrada a través de la identificación de la billetera virtual (Pandey et al., 2021). Igual que ocurre con una vivienda en el Registro, la red *blockchain* permite ver la trayectoria específica de un determinado Bitcoin (Chen, 2023).

En definitiva, podríamos definir a Bitcoin como el sistema de intercambio electrónico descentralizado – no gestionado por ningún banco o gobierno – que funciona sobre una analogía a un sistema de contabilidad abierto, denominado tecnología *blockchain* (Faghih Mohammadi Jalali y Heidari, 2020). Tomando en cuenta los bajos costes de transacción por la ausencia de intermediarios (tradicionalmente, bancos), así como la facilidad en su transferencia y el anonimato de sus tenedores (Merkaš y Roška, 2021), comprendemos por qué Bitcoin ha logrado la popularidad de la que goza hoy en día (Faghih Mohammadi Jalali y Heidari, 2020).

Tras las duras experiencias de los años noventa y las crisis financieras posteriores, en especial la de 2008 (Merkaš y Roška, 2021), la confianza en la gestión de divisas por parte de instituciones públicas y en terceros se ha visto comprometida. La alternativa a las monedas tradicionales que ofrecen criptomonedas como Bitcoin – transacciones seguras y directas entre particulares sin intervención de terceros tradicionales – resulta atractiva para muchos

operadores en el mercado y han propiciado un cambio en el sistema financiero global (Faghih Mohammadi Jalali y Heidari, 2020). Como ejemplo de apuesta más arriesgada, El Salvador adoptó en septiembre de 2021 el Bitcoin como moneda de curso legal e invirtió fondos públicos en ella; estrategia no muy rentable dadas las caídas que ha ido experimentando la criptomoneda desde entonces (Cota, 2022).

Aunque existen numerosas **discusiones y argumentos** acerca de la consideración del Bitcoin como una divisa o como un activo especulativo (Goczek y Skliarov, 2019), lo cierto es que los inversores deben proceder con precaución. La tecnología descentralizada en la que se enmarcan las criptomonedas está en pleno auge y podría argumentarse que estamos ante un panorama similar al que vivió la humanidad cuando nació Internet. Pero el Bitcoin como activo en sí, y la tecnología *blockchain* y su potencial en nuestro sistema económico y financiero, no son lo mismo (Deane y Fines, 2023).

En noviembre de 2021 el precio del Bitcoin llegó a sobrepasar el nivel de 68.000 para situarse a la mitad tan solo dos meses después. El hecho de que ninguna autoridad respalde esta moneda es fuente de riesgo en las transacciones de este activo, pues es discutible si la criptomoneda tiene valor intrínseco o no.

Lo que no ofrece lugar a dudas es que el Bitcoin tiene una volatilidad muy superior al resto de clases de activos. Durante los 7 años transcurridos entre abril de 2015 y abril de 2022, la desviación típica de la tasa de retorno diaria fue del 3,85%, lo cual es 2,68 y 3,36 veces superior a la del oro y SP500 en el mismo periodo de tiempo, respectivamente. Por estas fluctuaciones en la cotización, se ha planteado la función de Bitcoin como un depósito de valor más que como un medio de intercambio o moneda (Chen, 2023). El cómo captar la tendencia del Bitcoin para poder paliar el riesgo de su fluctuación se ha convertido en un problema de investigación recurrente. Uno de los enfoques consiste en analizar la correlación entre el precio de Bitcoin y el de otras clases de activos (oro, mercado bursátil...) para poder enmarcarlo en una tendencia similar. Como contraste, la utilización de sistemas de

inteligencia artificial para la predicción de sus precios tiene ahora mucha popularidad debido al auge de la tecnología *Machine Learning* (Chen, 2023).

1.1.2.2. Análisis macroeconómico

Teniendo en cuenta todo lo explicado hasta ahora de la situación económica actual y el Bitcoin y su tecnología, conviene ofrecer en esta sección un breve apunte sobre lo que podrá deparar el **futuro** a esta criptomoneda; observación fundamental a tomar en cuenta si se quiere comenzar a operar con ella en el mercado.

Situados en la segunda mitad de marzo de 2023 en el momento de redacción de esta sección, ya hemos comprobado que el optimismo del mercado de principios de año no guardaba congruencia con la situación macroeconómica:

Las empresas que hicieron crecer la Bolsa durante enero y febrero de 2023 no habían sufrido todavía los efectos de la subida de los tipos de interés, desapercibidos en el mercado hasta que el **viernes 10 de marzo de 2023 quebró Silicon Valley Bank (SVB)**, el banco especializado en préstamos a emprendedores y pequeños empresarios tecnológicos de Estados Unidos. Aunque la situación inflacionista y de fuerte empleo a principios de 2023 auguraba una medida agresiva por parte de la FED en su reunión del 22 de marzo, asistimos a un cambio de paradigma cuando las instituciones públicas de EEUU intervinieron. Tenían que evitar la quiebra del sistema financiero del país motivada por el pánico de la población. El SVB, al tener alto capital invertido en bonos del Tesoro de EEUU a largo plazo cuando los tipos de interés eran tan bajos, vio caer su activo cuando la FED comenzó la subida de tipos descrita en 2022. Debido a la falta de liquidez y el alto coste de la deuda en el mercado, sus depositantes (empresas tecnológicas) quisieron retirar sus fondos y SVB se vio obligado a liquidar esas posiciones en pérdidas, originando la quiebra de la entidad. Este, por tanto, fue el momento en el que el mercado puede ver de forma tangible los efectos de la subida de tipos en el sistema financiero (Cadenas, 2023).

El 15 de marzo de 2023 Credit Suisse – el cuarto banco más importante de Suiza – registró una pérdida en Bolsa de 7.000 millones de euros (mínimo histórico) y solicitó una inyección de liquidez y respaldo público de su banco central que le fueron concedidos (Sánchez, 2023). Aunque la quiebra de Lehman Brothers en septiembre de 2008 sea considerada el hito que inició la gran crisis financiera de 2008, podríamos definir la de Bear Stearns en marzo del mismo año como la antesala del fenómeno (Gabin, 2021).

Según transcurre el tiempo podremos determinar si nos aproximamos a una repetición de estos eventos, pero es cierto que **esta podría ser la primera gran crisis financiera a la que Bitcoin se enfrenta**. Nacido después de la quiebra del sistema financiero de 2008 y como una posible alternativa al dinero fiat (Goczek y Skliarov, 2019), su comportamiento es incierto en una crisis de este calado.

Como ejemplo similar, solo podemos tomar 2018 por ser el año de desaceleración económica y subida de los tipos de interés de la FED entre la crisis de 2008 y la actual (Celasun et al., 2018). Entre el 8 de enero de 2018 y el 1 de enero de 2019 Bitcoin cayó un 82,76%¹, comparado con la caída del SP500 en un 7% aproximadamente en ese año (Pérez, 2018). En consecuencia, no consideramos que Bitcoin sea un activo refugio, y ante una falta de liquidez en el mercado, lo más probable es que los fondos de la población no vayan destinados a su cotización. Todo ello, agravado por la alta correlación post – pandemia entre ambos mercados demostrada por el Fondo Monetario Internacional (FMI, 2022).

Desde otro punto de vista, muchos bancos centrales están estudiando el lanzamiento de sus monedas digitales e incluso su uso conforme a la tecnología *blockchain* (Reserva Federal de Estados Unidos [FED], 2022). La diferencia fundamental entre estas y Bitcoin sería el respaldo de la propia autoridad, pero sigue existiendo incertidumbre acerca del efecto que

esto puede tener en la cotización de las criptomonedas y será lo que marque el comportamiento de Bitcoin en los próximos años. Los que argumentan el nulo valor intrínseco de las criptomonedas sostienen que el dólar o euro digital supondría el fin de su cotización, mientras que los defensores de su valor como medio de intercambio – más que especulativo – confían en su triunfo como la verdadera alternativa desregulada del sistema financiero tradicional, una vez digitalizado.

1.1.3 Tipos de robots

En esta sección vamos a exponer **literatura previa sobre los robots de *trading* cuantitativo y tres modalidades relevantes para nuestro estudio**: el robot de análisis técnico tradicional, el robot basado en un modelo de aprendizaje supervisado de *Machine Learning*, y el robot basado en aprendizaje por refuerzo. En el último capítulo presentaremos como resultados del estudio robots que siguen las dos primeras aproximaciones y se reserva la tercera modalidad como futura línea de investigación.

Existen numerosos ensayos y artículos dedicados al estudio de los **robots de *trading*** por representar sistemas mecánicos de negociación que permiten a los inversores explorar nuevas oportunidades de negociación. Tienen fuertes ventajas frente a la negociación manual: la automatización, la entrada y salida rápida del mercado – al poder actuar antes que un humano – y la ausencia de sentimiento (Malafeyev et al., 2022).

O. Malafeyev et al. (2022) llevaron a cabo un **análisis comparativo entre dos robots de *trading* de enfoque más tradicional basándose en indicadores técnicos**, empleando en cada uno tres indicadores de los siguientes: media móvil, bandas de Bollinger, KST, Ichimoku indicator, TRIX, y Williams %R. Aysel y Santur (2020), en la misma línea, deciden crear un robot de *trading* basado en un nuevo indicador que empleaba medias móviles que fijan sus pesos de acuerdo a la proporción áurea (Fibonacci). Realizaron un *backtest* a 30 stocks en BIST30 y demostró mejores resultados que los tradicionales indicadores técnicos (divergencias, IFR, estocástico...)(Aysel y Santur, 2022). **En nuestra línea de**

investigación, Gerritsen, D., Bouri, E., Ramezanifar, E., et al. (2020) aplicaron siete indicadores de tendencia para evaluar la rentabilidad del análisis técnico en Bitcoin en el intervalo de 2010 a 2019 con precios diarios. Los resultados demuestran que reglas de análisis técnico específicas superan en términos de rentabilidad la estrategia de “*buy and hold*” por tener un alto poder de predicción de los precios de Bitcoin.

El tema de investigación actual son los sistemas que utilizan inteligencia artificial para la identificación de patrones de tendencia formados por series temporales, y la predicción de los precios gracias al desarrollo de los modelos que aprenden de los datos proporcionados – los modelos *Machine Learning*. En contraste, los robots basados en indicadores técnicos, que pueden calcularse mediante métodos estadísticos, tienen un enfoque más tradicional, pero son utilizados como variables de entrada en el desarrollo de señales de *trading* con *Machine Learning* (Aysel, Ü., y Santur, Y., 2020). Los resultados han demostrado que su empleo evita el problema del sobreajuste en la clasificación de datos de series temporales financieras no estacionarias y logra mejorar el rendimiento de estrategia de inversión tradicional del *trader* en Bolsa (Fang et al., 2022). Estos modelos de regresión y clasificación también son empleados en el mercado de criptomonedas mediante la predicción de la tendencia de los precios, centrándose los distintos estudios en el análisis comparativo de dichos modelos.

Como señala Uzonyi, N. (2021), en los últimos años destaca en la comunidad científica el interés por el empleo de **técnicas de aprendizaje automático para su implementación en estrategias de *trading* de Bitcoin**. Investigó acerca del mejor modelo de clasificación de *Machine Learning* que previera la próxima alteración del precio, para así incorporarlo como estrategia de inversión a su robot de *trading*. Operando con un intervalo de tiempo de seis horas, su objetivo consistía en predecir cuál iba a ser el movimiento del mercado en el siguiente intervalo (un “1” indicará una subida del precio, y un “0” el resto). Logró una rentabilidad del 7.06% para el periodo de prueba de su robot (1-10 de mayo de 2021). Durante la redacción de su trabajo de investigación, en mayo de 2021, el Bitcoin experimentó una inesperada caída de hasta el 40% en solo cuestión de horas, lo cual le permitió comprobar

cómo reaccionaría su robot de *trading* ante situaciones tan extremas que ocurren en el mercado de las criptomonedas por su extraordinaria volatilidad. Consiguió cerrar el periodo con solo una pérdida del 1.5%.

Asimismo, el estudio comparativo entre modelos estadísticos clásicos y de *Deep learning* también ha sido un tema recurrente entre investigadores. Zhang et al. (2022) realizaron contribuciones importantísimas en la materia formulando el aprendizaje de políticas de *trading* cuantitativo como un aprendizaje por refuerzo (*reinforcement learning*). El *reinforcement learning* se basa en la mejora gradual del rendimiento mediante un método de ensayo y error gracias a la interacción con el entorno, aplicado por estos autores en su programa de negociación. Su propuesta se basa en cuatro componentes:

1. Un modelo de aprendizaje supervisado para la predicción del precio futuro del activo, de manera similar a la que haremos nosotros con el uso de *Machine Learning*.
2. Un conjunto de políticas de inversión determinadas por humanos expertos en la materia que determinarán una orden de compra, de venta, etc., con el mismo concepto que el empleado en nuestro Capítulo 2 para el análisis técnico y definición de la estrategia de inversión que emplearemos en nuestro robot de Python.
3. El empleo de la función de recompensa aprendida por el Aprendizaje por Refuerzo Inverso (IRL) que obtiene dicha función a partir de la estimación de una gran recompensa para los rendimientos del experto de inversión.
4. Un entorno como sistema de *backtesting* para el aprendizaje de una estrategia de negociación que proporciona expectativas del rendimiento en operaciones reales.

Con una técnica similar de *reinforcement learning*, Cortés y Hernández (2021) obtuvieron un retorno de la inversión de un 106.58% anual en el periodo de investigación, teniendo en cuenta los costes de transacción asociados.

1.2 Objetivo del TFG

Este trabajo de investigación toma como punto de partida un análisis fundamental del mercado de tipo macroeconómico dirigido a estudiar las variables económicas más significativas para el precio de Bitcoin. Contrastaremos dichas variables mediante un análisis cuantitativo empleando procesos de *feature selection* con el fin de ayudar a analistas, inversores, e instituciones a abordar el tratamiento de esta criptomoneda. Tras la selección de las variables más relevantes, buscamos los modelos de regresión y clasificación con el mayor grado de predicción mediante sesiones de entrenamiento en Matlab y aplicaremos el ajuste de curvas a la búsqueda de una función que realice predicciones del precio pero que evite el *overfitting*. Paralelamente, realizaremos un análisis técnico de forma teórico – práctica con el fin de proyectar las dos aproximaciones tradicionales de la inversión en Bolsa: técnica y fundamental.

Con el modelo de *Machine Learning*, la estrategia de inversión tradicional y el *curve – fitting*, **nuestro objetivo** es analizar el comportamiento del precio de Bitcoin y ofrecer una solución de tecnología avanzada para su inversión. Analizaremos y contrastaremos cripto – robots más tradicionales y cuya estrategia de inversión está programada desde cero a partir de indicadores de análisis técnico, hasta modelos obtenidos por inteligencia artificial que brindan asombrosos resultados de predicción. Y, como aportación fundamental, la combinación de ambos.

1.3 Metodología y antecedentes

1.3.1 Metodología

Los datos utilizados en este estudio son obtenidos de páginas especializadas como Yahoo Finance, Federal Reserve Bank of Sant Louis, Nasdaq Data Link, etc. Todos los gráficos incluidos para la representación de los indicadores de análisis técnico han sido elaborados con las herramientas de Investing y para su exposición teórica se ha utilizado el libro de John Murphy (1999) de “*Análisis técnico de los mercados financieros*”.

El análisis cuantitativo de las secciones de “*Curve – fitting*”, “*Feature Selection*” y “*Machine Learning*” se ha llevado a cabo con el empleo de las herramientas de software matemático Matlab y Jupyter y todos los cripto – robots han sido programados en Python (Spyder). Por último, se han realizado reuniones semanales con el director y hemos empleado los conceptos dados en sus prácticas visuales.

1.3.2 Antecedentes

En esta sección exploramos los **resultados obtenidos por previos trabajos de investigación acerca de los modelos de predicción del precio de Bitcoin**. Zhi, Huang y Ni (2019) demostraron altos niveles de predicción para precios de cotización diarios mediante la implementación de indicadores de análisis técnico y el uso de la inteligencia artificial y el *data science*. Esta es la base de nuestro estudio y sobre la que versará el Capítulo 3 de *feature selection* y *Machine Learning*.

Señala Chen (2023) la **difícil comparación entre la precisión de los distintos modelos de predicción debido a la volatilidad de Bitcoin**, pues las grandes burbujas o caídas provocan un gran impacto si los datos de estudio se encuentran en ese periodo.

Él llega a la conclusión de que el *random forest* (bosque aleatorio en español) es el mejor modelo de predicción, a diferencia de la mayoría de estudios que suelen considerar el **LSTM – redes neuronales** – más acertado (Bahrammirzaee (2010) y Kobiela et al. (2022)). Faghih Mohammadi Jalali (2020), en la misma dirección, señala que los modelos de redes neuronales son muy sensibles a las variables de entrada, y no se ajustan o no son lo suficiente estables como para predecir el precio de Bitcoin. En el mismo sentido, Gradojevic et al. (2023) descubrieron que el modelo RF producía las previsiones más precisas de los rendimientos a un nivel de significatividad del 1%. Como anotación, señalar que el modelo *random forest* presentó limitaciones por no poder predecir precios que no se encuentren en los datos de entrenamiento (los valores que superaban los 60.000 de cotización a finales de 2021). Pero, para un nivel de cotización menor, la predicción fue óptima (Chen, 2023).

En su investigación, Faghieh Mohammadi Jalali (2020) propone la *Grey system theory* como mejor modelo de predicción de forma diaria, trabajando con un número limitado de información y siendo esta incompleta. Sus resultados implican que con GM(1,1) puede lograrse la predicción de Bitcoin en una ventana de 5 días con un error de un solo 1,14%.

Darius Kobiela et al. (2022) realiza un **estudio comparativo entre los niveles de predicción de los precios del NASDAQ de un modelo ARIMA tradicional y LSTM**. Los modelos ARIMA son modelos estadísticos que utilizan datos históricos para predecir valores futuros a partir de la diferenciación. Convierten una serie temporal no estacionaria en estacionaria, usando correlaciones y medias móviles sobre los errores de los datos. La diferencia fundamental entre estos modelos y los LSTM es que las redes neuronales pueden emplear múltiples variables de entrada además de los precios históricos. En su estudio, el modelo ARIMA supera los resultados de las redes neuronales, pero apunta que habría que comparar el rendimiento una vez se incorporan más *inputs* al LSTM. Así lo demuestran Siami-Namini y Namin (2018), donde la incorporación de múltiples características en el modelo de redes neuronales hizo que este modelo de aprendizaje profundo funcionara mucho mejor que el estadístico. El uso de un modelo híbrido que combine las ventajas de ambos y compense sus inconvenientes es un tema de investigación en desarrollo a día de hoy (un modelo que emplee tanto redes de autoregresión como aprendizaje profundo) (Kobiela et al., 2022).

Los estudios mencionados y sus conclusiones representan una parte ínfima de todos los trabajos de investigación realizados en torno a la predicción del precio de Bitcoin, al ser una cotización que ha despertado mucha curiosidad entre los académicos por sus altos rendimientos y volatilidad.

Pero este trabajo de investigación complementa y se extiende frente a las previas contribuciones por tener un planteamiento distinto. El valor de nuestro estudio no se encuentra en analizar las diferencias en el rendimiento de las predicciones entre los modelos competidores ya mencionados, al ser un área de estudio ya muy extendida y que ofrece

distintas conclusiones dependiendo del periodo de análisis escogido y las variables que cada autor haya querido incorporar.

Nosotros vamos a comparar los resultados obtenidos por nuestros cripto – robots que representan el modo más “clásico” de proceder en Bolsa, y los basados en tecnología más avanzada de *Machine Learning* después de la selección estudiada de variables y su importancia relativa en la predicción.

Después de explicar de forma teórica cómo funcionan algunos de los **indicadores técnicos** más conocidos del *trading* y cómo los vamos a combinar para crear una estrategia de inversión, procederemos a incorporar dicha estrategia a Python para operar con los datos históricos de Bitcoin. Con ello, veremos cuál es la rentabilidad que hubiera obtenido un analista con nuestra estrategia en el periodo de tiempo seleccionado, y esta rentabilidad es la que utilizaremos para contrastar los resultados con los rendimientos que brinda el modelo “ganador” de inteligencia artificial.

Para la **predicción del precio en *Machine Learning***, además de tomar como variables aquellas relacionadas con el price *momentum* y el sentimiento del mercado ya utilizadas por académicos anteriores (por ejemplo, el volumen de sus transacciones (Gradojevic et al., 2023)), incorporaremos variables relacionadas con el contexto macroeconómico actual tras un análisis fundamental del mercado. En el mismo sentido, autores como Gradojevic et al. (2023) aportaron a la comunidad científica un análisis empírico exhaustivo que combinaba indicadores técnicos y macroeconómicos con técnicas de aprendizaje profundo, revelando altos niveles de predicción para un horizonte temporal diario. La limitación de estas conclusiones frente a nuestra investigación es que los datos que utilizan son anteriores a la crisis inflacionista que estamos experimentando en 2023. Tenemos el privilegio de analizar de forma empírica el peso de estas variables con la importancia que tienen hoy en el mercado.

Podremos demostrar que, aunque miles de estudios concluyan la no significatividad de factores macroeconómicos para la predicción del precio de Bitcoin, estas conclusiones

pueden no corresponderse con la realidad actual. El Fondo Monetario Internacional (2022) demostró que la correlación entre los rendimientos del Bitcoin y el SP500 se había incrementado de un 0,01 a un 0,36 comparando los años previos a la pandemia (2017-2019) a los posteriores (2020 y 2021) solo pudiendo tomar los precios hasta 2021, por lo que podemos empezar a comprender cuánto de valioso es nuestro análisis.

Someteremos el espectro de variables ya seleccionadas a un análisis de *feature selection* en *Jupyter* y *Machine Learning* para determinar si efectivamente tienen peso en la predicción del precio de Bitcoin. Como se desprende de lo anterior, esta es una de las aportaciones más importantes de nuestra investigación desde el punto de vista económico: tanto para analistas y gestores de cartera, dedicados al estudio de la evolución de los precios de las distintas clases de activos, como para instituciones y gobiernos, encargados de salvaguardar la estabilidad financiera de los países. Con las variables explicativas más significativas procederemos a determinar qué modelo de predicción es mejor según nuestros datos gracias al *Machine Learning*. Vamos a trabajar con modelos de regresión y clasificación, lo cual significa que no solo buscamos predecir el siguiente precio de Bitcoin en términos absolutos, sino también si el precio va a subir o bajar en el siguiente intervalo. El modelo escogido se incorporará a Python para evaluar el funcionamiento de sus señales de compra y venta en base a su predicción en el mercado de Bitcoin y así calcular su rentabilidad como robot de *trading*.

El intervalo de estudio escogido para nuestro análisis es el precio de Bitcoin diario entre el 8 de marzo de 2022 y el 8 de marzo de 2023.

En conclusión, este trabajo de investigación va a comparar mediante el *backtesting* las rentabilidades de robots de *trading* en el mercado de Bitcoin de 2022 a 2023: uno de ellos programado conforme a un análisis técnico imitando el *modus operandi* que hace un *trader* de Bolsa, otro de ellos conforme a la predicción obtenida a través de la función seleccionada del *Curve fitting*, y los otros programados según señales de compra y de venta de acuerdo a un modelo de regresión y/o de clasificación obtenidos en *Machine Learning*. Los últimos

robots utilizan, por tanto, tecnología mucho más avanzada que el primero, pero no sabemos cómo será su funcionamiento operando en el mercado.

1.4 Estructura del TFG

El trabajo de investigación se va a dividir en **cuatro capítulos fundamentales**:

En el capítulo de “*Modelos descriptivos*”, primero expondremos indicadores de análisis técnico bursátil de forma teórica, al tiempo que los empleamos en los gráficos de cotización de Bitcoin y evaluamos cómo de acertada hubiera sido nuestra entrada o salida del mercado siguiendo dichas señales. En resumen, se expone una estrategia de *trading* de forma teórico – práctica. Para continuar, introduciremos cuál va a ser nuestra estrategia de inversión en Python para saber nuestra teórica rentabilidad operando en Bitcoin durante el periodo seleccionado, resultado que servirá después de comparación con el resto de cripto – robots. En último lugar, buscaremos la curva diferenciable de nuestros datos históricos a través del *Curve – fitting* de *Machine Learning*, y utilizaremos esta curva para otro robot de *trading* y análisis de su rentabilidad.

En el capítulo de “*Feature selection y Machine Learning*” crearemos un cripto – robot con inteligencia artificial analizando qué variables son más importantes en la predicción del Bitcoin de acuerdo a nuestro análisis fundamental y literatura previa. Tomando en consideración las variables macroeconómicas más relevantes ya discutidas, así como las obtenidas en trabajos de investigación anteriores, evaluamos si se tratan, en efecto, de variables explicativas. Una vez seleccionadas las de mayor importancia relativa, buscamos cuál es el mejor modelo predictivo de regresión y clasificación según *Machine Learning* para incorporarlos a Python y analizar la rentabilidad de sus señales de compra y venta en el mercado mediante el *backtesting*.

El penúltimo capítulo, “*Comparación de robots*”, es el más importante por ser donde analizamos los resultados obtenidos de forma empírica para determinar cuáles son los cripto – robots más rentables en el *trading* de acuerdo al periodo de tiempo seleccionado.

Asimismo, proponemos una combinación de los robots anteriores para lograr la máxima rentabilidad y ventajas de la estrategia tradicional e inteligencia artificial.

En “*Conclusiones y Próximas Líneas de Investigación*” repasamos los resultados obtenidos más notables y los contrastamos con nuestras hipótesis iniciales. Finalmente, expondremos cuáles son las limitaciones de nuestra investigación y cómo se podría ir más allá en un futuro estudio.

CAPÍTULO 2: MODELOS DESCRIPTIVOS, ANÁLISIS TÉCNICO Y *CURVE FITTING*

2.1 Análisis técnico

En esta sección vamos a exponer de forma teórica y gráfica los **indicadores técnicos** a utilizar en nuestro robot de *trading* en Python, para continuar con un breve resumen de cómo se combinan todos ellos en una estrategia de inversión. Los conceptos del análisis técnico serán explicados de acuerdo al “*Análisis técnico de los mercados financieros*” de John J. Murphy (1999):

2.1.1 *Medias Móviles*

Comenzamos con la media móvil por ser uno de los indicadores más utilizados en el mercado y por su versatilidad:

Se trata de la media/promedio de la información que elijamos. Por ejemplo, si calculáramos la media móvil del precio de cierre de los últimos 30 días, sumaríamos los 30 precios de cierre y los dividiríamos por el mismo número. Es un indicador muy intuitivo, sencillo de calcular y fácil de representar gráficamente, pero al ser tan versátil (pues podemos elegir precios máximos, mínimos, promedio, distintos periodos de tiempo, etc.), la dificultad radica en determinar qué información es la útil para obtener su máxima rentabilidad (Murphy, 1999).

La **finalidad** de este indicador técnico, a diferencia de algunos que veremos más adelante, es avisar al inversor de cuándo una tendencia de mercado ha comenzado, finalizado, o ha cambiado de dirección. Pero, al ser una media de los precios, opera a continuación del movimiento del mercado. En palabras de John Murphy (1999), “*La media móvil es un seguidor, no un líder*”.

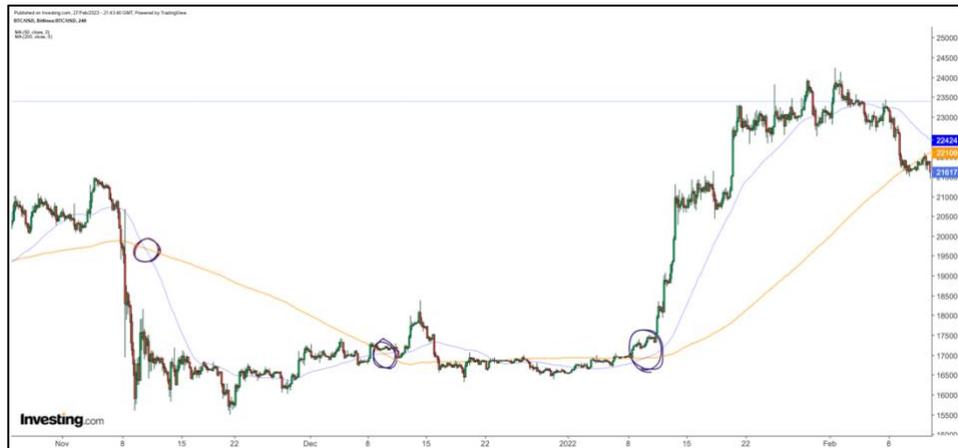
El problema principal de la media móvil simple es que otorga el mismo valor al precio de cada día de análisis, mientras que muchos analistas consideran que los precios más recientes son los que deberían suponer una mayor carga en el cálculo. Surgen por ello figuras como la media móvil ponderada o suavizada, pero nosotros nos vamos a centrar en la media móvil simple (Murphy, 1999).

En cuanto a la elección de una media móvil a corto y a largo plazo, el analista juega con dos extremos. Si tomamos una media móvil de 10 días, la media es muy sensible y unas mínimas oscilaciones en el precio podrían dar falsas señales de compra o de venta. Al contrario, una media móvil a largo plazo de 200 días es mucho menos sensible y se pueden perder importantes oportunidades de inversión. (Murphy, 1999).

La opción más acertada es trabajar con dos medias móviles de distinta duración que generen bandas de precio, técnica también conocida como el “*método del doble cruce*”. Consiste en considerar el cruce entre las dos medias como señal de compra – cuando la media móvil de corto plazo cruza por encima a la de largo – o señal de venta (viceversa). Como inconveniente, señalar que esperar el cruce puede retrasar el momento de entrada o salida del mercado de mayor rentabilidad, pero es recomendable para evitar las señales falsas (Murphy, 1999).

A continuación mostraremos qué señales de compra y venta de Bitcoin nos dan dos medias móviles (50 días y 200 días) para un intervalo de 4 horas durante los últimos meses de 2022 y primeros de 2023; siendo la media móvil a corto plazo de color azul y la de largo plazo de color naranja:

Ilustración 1: cruce de medias móviles en un intervalo de 4 horas en Bitcoin



Fuente: elaboración propia en Investing.com

En el **primer cruce**, las medias móviles me están dando una señal de venta. Vemos que es una señal adecuada porque comenzó en el mercado una tendencia bajista que se prolongó durante meses. El **segundo cruce** nos muestra una señal de compra adecuada y temprana que permitía aprovechar la subida de la siguiente semana para vender y obtener rentabilidad. El **tercer cruce** vuelve a indicar una señal de compra muy acertada. Durante el mes siguiente, el precio comenzó una espiral alcista de mucha fuerza tras unos meses de un mercado bajista con movimientos laterales. Comprar Bitcoin en ese cruce es una de las mejores decisiones de inversión del mercado de la criptomoneda del último medio año. Al contrario, vemos que en la bajada del 14 de diciembre de 2022 en adelante, las medias móviles no brindaron ninguna señal de salida.

Este **análisis** demuestra que aunque la combinación de medias móviles y el método del doble cruce son indicadores de tendencia con alta fiabilidad, deben combinarse con otros para lograr una mayor rentabilidad.

2.1.2 Bandas de Bollinger

Las bandas de Bollinger son creadas por John Bollinger y surgen a raíz de la utilización de **extremos alrededor de la media móvil** que nos permiten comprobar si el precio se ha sobreextendido en alguna dirección. Para su utilización, se colocan dos bandas de fluctuación por encima y por debajo de la media de acuerdo a su desviación típica. Esto asegura que el 95% de los precios de cotización estará dentro de las bandas. Si los precios tocan la banda superior están sobrecomprados, mientras que si tocan la banda inferior estarán sobrevendidos (Murphy, 1999).

Ilustración 2: Bandas de Bollinger en un intervalo de 4 horas en Bitcoin



Fuente: elaboración propia en Investing.com

Tomando el ejemplo anterior, añadimos unas bandas de Bollinger con una media móvil de 20 días para ver la información que nos muestra este indicador. Desde mitad de noviembre de 2022 hasta mitad de enero de 2023 el precio ha realizado movimientos laterales, tocando las bandas de fluctuación tanto superior como inferior. No obstante, a partir de 2023, los precios operaban entre la banda superior y la media móvil de 20 días, dando signos de la tendencia al alza que iba a lograr el mercado a partir del 8 de enero. Del mismo modo, se aprecia la fuerza con la que el precio fluctuó en la banda inferior durante la gran caída de Bitcoin en noviembre de 2022.

La gran **ventaja** de las bandas de Bollinger es su colocación en función de un parámetro estadístico que depende del precio y mide su dispersión en torno a su promedio, la desviación típica. Realmente, lo que nos muestran estas bandas de fluctuación es la mayor o menor volatilidad del activo y esto resulta muy útil para identificar la **tendencia** del mercado: cuanto más anchas sean las bandas de Bollinger (y por tanto la dispersión del precio), menos clara será la tendencia del precio. En consecuencia, muy poca volatilidad puede ser indicio de que una nueva tendencia va a comenzar (Murphy, 1999) (ver *supra* la poca volatilidad del precio antes de la tendencia alcista de enero de 2023).

Su **inconveniente** es que también son indicadores de tendencia y como tal, aunque pueden servir de pretexto para realizar operaciones, deben combinarse con otros indicadores técnicos. En efecto, su combinación con los osciladores que veremos a continuación es la mejor elección para el inversor (Murphy, 1999).

En definitiva, las medias móviles y las bandas de Bollinger siguen la tendencia del mercado y esto puede ser arriesgado cuando se prolongan en el tiempo los movimientos laterales del precio. *A sensu contrario*, sí que son indicadores muy útiles cuando el mercado está en una clara tendencia porque nos permiten identificar la tendencia existente (Murphy, 1999). Por todo ello, debemos incorporar a nuestro análisis indicadores que no sigan la tendencia, así como los que determinen cuándo estamos en tendencia y cuándo no (lo cual veremos más adelante con el ADX)(Murphy, 1999).

2.1.3 Osciladores

Los osciladores son **indicadores técnicos de “momento”** que ofrecen una alternativa a la tendencia. Al contrario que los anteriores, son extremadamente útiles en los escenarios de fluctuaciones laterales donde no existe un claro movimiento del precio (Murphy, 1999).

Como **ventajas** de los osciladores, además de complementar a los indicadores de tendencia durante movimientos horizontales, destacar su papel fundamental en la alerta de momentos

de sobrecompra o sobreventa y donde la tendencia del mercado está perdiendo fuerza mediante divergencias (Murphy, 1999).

Como **limitación**, recordar que estos indicadores sirven de manera especial para momentos específicos y como complemento secundario a los indicadores vistos anteriormente. Los resultados mostrados por los osciladores deben ser siempre contrastados con la tendencia del mercado para evitar operar en la dirección contraria. El “*momento*” debe seguir siempre a la tendencia del mercado (Murphy, 1999).

El valor del “*momento*” es su medida de aceleración o desaceleración de los precios. Si queremos construir un oscilador de 20 días, el *momento* será igual a la diferencia entre el último precio de cierre y el de hace 20 días. Los valores negativos o positivos de este cálculo son los que se anotan alrededor de la línea cero que utilizamos de cruce. Si el oscilador indica un valor positivo, significa que los precios en los últimos 20 días se han movido al alza y estará representado por encima de la línea cero. Cuanto más corto sea el periodo, más sensible será el oscilador a los precios y por tanto, más volátil (Murphy, 1999).

El “*momento*” también nos alerta de la fuerza de la tendencia del mercado. Cuando la línea de momento se sitúa de forma ascendente a la línea cero, el oscilador nos está señalando una tendencia alcista que está tomando mayor velocidad. Al contrario, si la línea de momento, aunque se mantenga por encima de la línea cero, comienza a aplanarse, significa que la tendencia está perdiendo fuerza – pues las plusvalías obtenidas en los últimos días son muy parecidas a las obtenidas 20 días antes – y puede estar advirtiendo de un cambio de dirección (Murphy, 1999).

Los **pasos** a seguir ante las señales de los osciladores son los siguientes (Murphy, 1999):

1. El inversor debería vender cuando la línea del oscilador esté en la parte superior de la banda (sobrecompra) y comprar cuando esté en su parte inferior (sobreventa). Se suele utilizar el cruce de la línea media como señales de compra y de venta.

2. El inversor no debe operar de forma inmediata ante un valor extremo del oscilador. Esto suele indicar que el movimiento del precio ha fluctuado con mucha rapidez y probablemente le siga una corrección o consolidación.

A raíz de esta explicación, definimos la anticipación a los movimientos del precio como el valor añadido de los osciladores en nuestro análisis. La línea de momento se mantiene estable – cercana a la línea cero – mientras el mercado está en una tendencia, y su cambio advierte del retroceso o avance de los precios (Murphy, 1999).

2.1.3.1 Índice de Fuerza Relativa (IFR)

El Índice de Fuerza Relativa ('RSI' en inglés) fue desarrollado en 1978 por J. Welles Wilder y es uno de los osciladores más utilizados en el mercado por solucionar los problemas intrínsecos de su categoría (Murphy, 1999):

- El movimiento falso de la línea de momento ante un cambio extremo del precio, por no incluir la dispersión de los valores en su cálculo.
- La inexistencia de un número constante para la comparación de los distintos valores de la línea.

El IFR soluciona estos dos problemas: en primer lugar, para su cálculo se emplea la diferencia entre los valores ascendentes medios de los últimos X días y los valores descendientes medios, buscando eliminar la volatilidad de los precios. Asimismo, se representa a través de una escala vertical de 0 a 100, de forma que en valores superiores a 70 se interpreta que el activo está en sobrecompra, e inferiores a 30 en sobreventa. Esta escala nos permite ir comparando el IFR de un momento u otro con facilidad (Murphy, 1999).

La mayor aportación del IFR al análisis técnico son la divergencia con la línea del precio del activo y las “oscilaciones de fracaso” y. Las oscilaciones de fracaso pueden ser inferiores o superiores. Por ejemplo, si el IFR situado por debajo de 30 registrara el siguiente mínimo por encima de ese nivel, formando una línea de mínimos ascendientes, nos encontraríamos en una oscilación de fracaso inferior . No obstante, la divergencia entre la

línea del precio y la IFR es lo que más debería alertar al inversor, definida como su característica más significativa por su autor (Murphy, 1999).

Para evitar las señales falsas, en nuestro **ejemplo práctico** interpretaremos el primer movimiento del IFR a los niveles de 70 o 30 como una simple advertencia, y decidiremos en función del segundo movimiento del oscilador.

Ilustración 3: IFR de 14 días en gráfico diario de Bitcoin



Fuente: elaboración propia en Investing.com

Como podemos comprobar, después de la segunda semana de enero de 2023 tuvimos una **divergencia** entre la línea de IFR y la línea de precio de Bitcoin (comparación líneas azules). Los máximos del IFR situados en altos niveles de sobrecompra (valores entre 80 y 90) son decrecientes y los máximos del precio son ascendientes. Esto debería haber advertido al inversor del fin de la tendencia alcista del mercado desde el inicio de 2023, como posteriormente demuestra el descenso de los precios que comienza en febrero. Utilizar la divergencia para salir del mercado en ese momento hubiera sido una opción rentable, y observar las oscilaciones de la línea de momento revelan con qué fuerza se aproxima o se aleja una tendencia del mercado.

2.1.3.2 El proceso estocástico

El proceso estocástico de George Lañe es un oscilador que emplea dos líneas en vez de una: la %K y la %D. La última es la que servirá al inversor para tomar señales de entrada y salida del mercado. También se mide en una escala vertical de 0 a 100, y de forma similar al IFR, un nivel de 80 indica sobrecompra y un nivel de 20 sobreventa. El periodo de 14 días es el más utilizado (Murphy, 1999).

La **línea %K** es la más sensible de las dos y se calcula de la siguiente forma (Murphy, 1999):

$$\%K = 100 [(C-L14) / (H14-L14)]$$

Donde C es el precio del último cierre; L14 el precio de cierre mínimo de entre los últimos 14 periodos; y H14 el precio de cierre máximo de entre los últimos 14 periodos.

La **línea (%D)**, donde reside el valor del oscilador, se calcula como una media móvil de 3 periodos de la línea %K. La utilización de ambas líneas es lo que se conoce con el nombre de “*estocástica rápida*”: la línea %K es más rápida por ser muy sensible a los movimientos del mercado, mientras que la línea %D está calculada para suavizar la anterior. También tendremos que prestar especial atención a la divergencia entre la línea %D en escenarios de sobrecompra o sobreventa y la línea de precios. A diferencia del IFR, en el proceso estocástico las señales de compra y de venta las brinda el cruce de la línea %K al alza o a la baja de %D (Murphy, 1999). Pero la alta sensibilidad del oscilador y la fácil comparación entre ambos indicadores, hace recomendable combinarlo con el IFR para realizar entradas y salidas en el mercado más seguras (Murphy, 1999).

Tomando el gráfico anterior y añadiendo el oscilador estocástico, comprobamos que el oscilador estocástico fluctúa con mucha más frecuencia que el IFR en los niveles de sobrecompra y sobreventa, ofreciendo por ello más señales de entrada y salida:

Ilustración 4: comparación IFR y oscilador estocástico de 14 días en gráfico diario de Bitcoin



Fuente: elaboración propia en Investing.com

Prestando ahora atención al oscilador estocástico en particular:

Ilustración 5: comparación señal 10 de febrero de 2023 oscilador estocástico e IFR de 14 días en gráfico diario de Bitcoin



Fuente: elaboración propia en Investing.com

Este es un **ejemplo ilustrativo** de una señal de compra del oscilador estocástico acertada y adelantada al IFR. La línea roja representa la línea menos sensible (%D) y la línea azul la más sensible (%K). El 10 de febrero de 2023 la línea %K cruzó al alza a la línea %D y emitió

la señal. El IFR (situado debajo) no dio ninguna señal de entrada en el mercado pues se mantuvo en los niveles de 45-50. Si el analista solo se hubiera guiado por el IFR, hubiera perdido la oportunidad de comprar a un precio de 21.747 que subió a 23.707 tan solo 5 días más tarde, momento en el que estocástico e IFR advirtieron de sobrecompra – señal de venta. Esto significa una rentabilidad del 9,01% que el IFR no registró.

En el gráfico anterior vemos que en la **espiral alcista** que comenzó después de la primera semana de enero de 2023, los osciladores (especialmente el estocástico) ya se encontraban en niveles de sobrecompra. Ante este escenario, el inversor tenía que escoger entre comprar la ruptura alcista o abstenerse por las señales de sobrecompra del oscilador. En esta divergencia es recomendable ignorar los osciladores y tomar posición en la tendencia, pues en los puntos de ruptura un nivel extremo de oscilador es usual (Murphy, 1999).

En conclusión, el inversor debe prestar más atención a las señales de tendencia en los primeros momentos del movimiento, pero más a los osciladores cuando la tendencia comience a estabilizarse. De lo contrario, podría perder su entrada en un mercado alcista esperando a que los niveles de sobrecompra del oscilador descendan. (Murphy, 1999).

2.1.4 Los indicadores ADX y DMI

A modo de cierre del análisis técnico que emplearemos en nuestro robot, vamos a exponer el **indicador ADX** en primer lugar. También creado por Wilder, permite distinguir cuándo el mercado está en tendencia con el fin de determinar si el uso de los indicadores de tendencia o el de los osciladores es el más adecuado (Murphy, 1999).

El indicador ADX mide la fuerza que tiene la tendencia en el mercado según su escala de valores de 0 a 100. Un ADX ascendente implica que el mercado tiene una tendencia cada vez más fuerte y el descendente la ausencia o pérdida de fuerza de una tendencia en el mercado. Pero también actúa como una **señal de preaviso**. Si se sitúa en un nivel de 60 y comienza a descender desde este nivel, sabremos que la tendencia se está debilitando y se

avercinan movimientos laterales de los precios. Si la línea empieza a subir y sobrepasa el nivel de 20, indica que el mercado ha comenzado un nuevo movimiento (Murphy, 1999).

Para combinar la información sobre la fuerza de la tendencia con posibles señales de compra y de venta, **vamos a incorporar a nuestra estrategia el análisis del movimiento direccional**. Para ello, se generan dos líneas que miden los movimientos positivos o ascendentes (+DI) y negativos o descendentes (-DI) y nos fijamos en el cruce entre las dos líneas: si la línea +DI cruza al alza a la -DI significa que estamos ante una señal de compra y viceversa. Cuanto mayor sea la distancia entre estas dos líneas, más segura es la señal de compra o de venta que ofrece su cruce (Murphy, 1999).

En definitiva, las señales de los indicadores explicados en este capítulo se contrastarán con la información que brinde el movimiento direccional o el índice de dirección del mercado (DMI) y la fuerza de su tendencia (ADX) (Murphy, 1999).

Mostramos a continuación un **ejemplo ilustrativo** de su funcionamiento en el mercado:

Ilustración 6: indicadores ADX y DMI de 14 periodos en gráfico diario de Bitcoin



Fuente: elaboración propia en Investing.com

En este gráfico se muestran **dos ejemplos** ocurridos en gráfico diario en los últimos meses en Bitcoin que ilustran muy bien la estrategia explicada para estos dos indicadores. La línea roja se corresponde con la ADX, la azul con la línea +DI y la naranja con la línea -DI.

1. En la primera semana de noviembre de 2022, el mercado asistió a un cruce de la línea -DI por la línea +DI, indicando un movimiento del mercado a la baja. La distancia entre las dos líneas es muy amplia y esto se refleja en los precios con la enorme caída que aconteció a partir de ese mismo día (31,4% dos días después). No obstante, en el momento de cruce la línea ADX se situaba a un nivel por debajo de 20, por lo que el mercado todavía no mostraba síntomas del comienzo de una tendencia. Cuando llega al nivel de 25 y por tanto es prueba indiciaria de una tendencia en el mercado, el precio ya ha caído.
2. El 6 de enero de 2023, el cruce de la línea +DI hacia arriba de la línea -DI indica un movimiento del mercado en dirección ascendente. En este caso, la diferencia entre las líneas direccionales es mucho más acentuada que en el anterior. La línea ADX también se situaba todavía en niveles bajos pero cuando registra un nivel de 25 (el 12 de enero de 2023), el precio todavía tenía mucho recorrido y hubiera sido un momento de entrada acertado.

Estos resultados demuestran que los indicadores ADX y DMI tienen más valor como indicadores de fuerza y dirección de la tendencia. En momentos de volatilidad y movimientos laterales de los precios, los cruces de las líneas +DI y -DI no funcionan como señales de entrada o salida (ver supra). Es decir, sirven como medida para el uso del resto de indicadores (Murphy, 1999).

2.2 Curve – fitting

El *Curve fitting*, también conocido como **ajuste de curvas**, consiste en la minimización de los mínimos cuadrados para obtener una función modelo parametrizada que se ajusta a los datos de la forma más próxima posible. Obtenemos una curva diferenciable – una función – que se aproxima a los datos de entrada (en nuestro caso, los precios de Bitcoin) (Guruswami, V. and Zuckerman, D., 2016).

Dentro de sus amplias posibilidades, nosotros vamos a utilizar la **función** de la curva diferenciable para operar en Bolsa. Del mismo modo que con el resto de robots, obtendremos esta función en Matlab para llevar el robot a Python y así evaluar sus resultados.

En esta tarea nos encontramos como obstáculo principal la elección del grado de ajuste o complejidad que queremos para nuestra curva. Considerando los precios de Bitcoin, suponemos que cada uno de los datos diarios refleja una doble realidad: por un lado, la tendencia subyacente del precio – que es en esencia lo que tratamos de obtener – y por otro, un ruido aleatorio que no se explica por la tendencia y es diferente para cada dato (Johnson, S., Jin, A., and Keil, F., 2014).

Si elegimos una *curva demasiado compleja* nos estaremos ajustando en exceso al conjunto de datos, y aunque así nos ajustemos a la tendencia subyacente, también lo estamos haciendo para el ruido. El efecto directo y la base por la cual muchos analistas temen el uso del *curve – fitting* para operar en el mercado es la sobre – optimización que esto conlleva y que desemboca en una predicción muy pobre para la siguiente muestra en el mismo conjunto de datos (es decir, para el siguiente precio) (Johnson, S., Jin, A., and Keil, F., 2014).

Si elegimos una *función muy simple*, que podría ser una recta o incluso una parábola (lo que ocurre, por ejemplo, cuando trabajamos con indicadores del análisis técnico), no nos estaremos ajustando lo suficiente y no aprovecharemos la información que nos brinda nuestro conjunto de precios para la identificación de la tendencia. De la misma forma que en el

extremo anterior, el resultado será la obtención de predicciones deficientes (Johnson, S., Jin, A., and Keil, F., 2014).

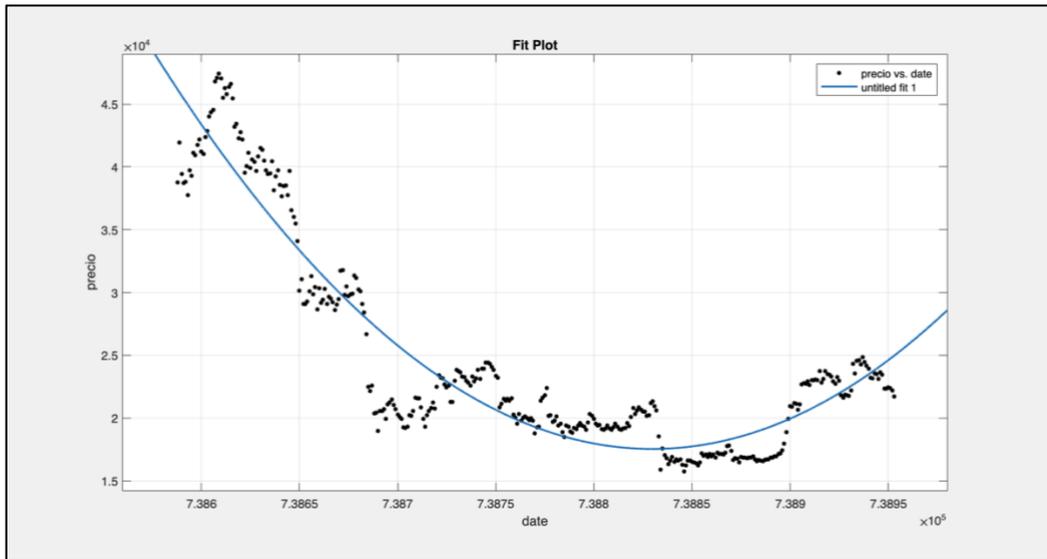
En definitiva, el inversor debe buscar un **equilibrio** en el cual se disminuya el grado de *overfitting* de la curva pero la función se ajuste lo suficiente a los datos como para lograr un alto valor predictivo.

En este sentido, definen Johnson, S., Jin, A., y Keil, F (2014) el *curve – fitting* “bueno” como el modelo que consigue ajustarse a la población de forma que se asume que sus características representativas han conseguido capturarse en el modelo. Al contrario, el *curve – fitting* “malo” ocurre cuando el modelo consigue capturar las características fortuitas, no necesariamente representativas de la población analizada – el modelo que los analistas deberían temer.

Utilizamos la función “*Curve fitter*” de **Matlab** con el fin de analizar las mejores funciones para nuestros datos, tomando solo el tiempo y los precios de cierre de Bitcoin en el periodo seleccionado. El indicador que vamos a utilizar para la comparación del ajuste de las funciones será el **R cuadrado ajustado**, que toma valores de 0 a 1, donde 1 indica que el ajuste es del 100% y por tanto perfecto. En base a la teoría explicada, un menor R cuadrado (es decir, un menor ajuste), será la función con menor optimización y menor riesgo de *overfitting*.

Si utilizamos una parábola como ejemplo:

Ilustración 7: Curve – fitting en nuestro periodo de análisis con una función polinómica de grado 2



Fuente: elaboración propia en Matlab

En primer lugar, observamos la representación gráfica de nuestros datos de estudio para situar la tendencia bajista del periodo. **El gráfico anterior muestra la evolución de los precios diarios de Bitcoin en nuestro intervalo de análisis** (8 de marzo de 2022 – 8 de marzo de 2023) en Matlab, una vez convertidas las fechas en números para poder trabajar con los datos y obtener la función.

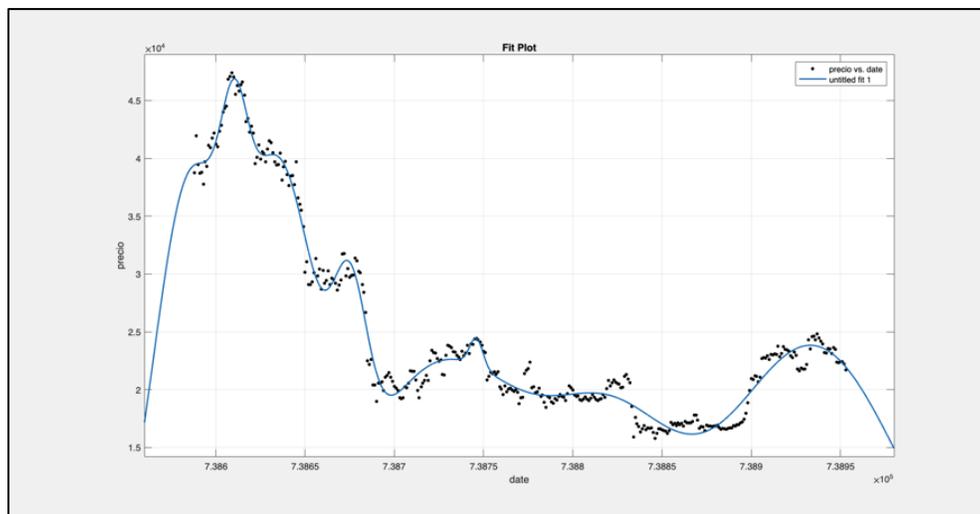
En este caso, el R cuadrado ajustado de la función polinómica es de 0.89 y el error (RMSE) de 2759, lo cual demuestra unos buenos resultados a pesar de ser una función de grado 2.

Aunque esta **función parabólica** es una buena elección para nuestro robot de *trading* debido a su alto nivel de ajuste (casi del 90%) y menor riesgo de sobre – optimización que las siguientes, sería una aproximación muy similar a la realizada con los indicadores de análisis técnico y no ofrecería grandes resultados comparativos para la investigación.

Por ello, optamos en este estudio por asumir un riesgo mayor de *overfitting* a fin de comparar el funcionamiento de robots de *trading* que operen de forma muy distinta.

El mejor ajuste lo ofreció una **función gaussiana de grado 8**, con un R cuadrado ajustado igual a 0.9841 y un RMSE de 1049, pero no fue la finalmente escogida para nuestro modelo por no ser realista en los extremos:

Ilustración 8: Curve –fitting en nuestro periodo de análisis con una función Gaussiana de grado 8

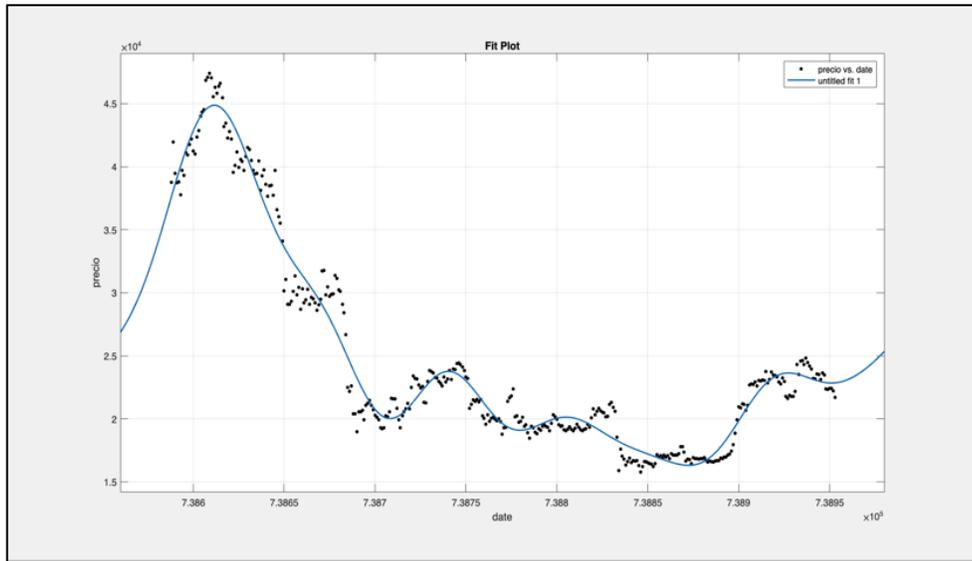


Fuente: elaboración propia en Matlab

La función predice que en el futuro muy próximo (1 mes aproximadamente) el precio de Bitcoin será igual a 0 y eso no es sensato, de la misma forma en que no creció en marzo de 2022 desde 0 y es lo que sugiere la función en su extremo izquierdo. La función sufre de un extremo *overfitting* que nos avisa de su mal funcionamiento en la Bolsa.

En consecuencia, buscamos una función con un ajuste más pequeño pero que tuviera un comportamiento más transversal en sus extremos, resultando la mejor en una **función Fourier de grado 7** que obtuvo un R cuadrado ajustado de 0.9703 y un RMSE de 1434, además de predicciones más realistas en sus extremos:

Ilustración 9: Curve – fitting en nuestro periodo de análisis con una función Fourier de grado 7



Fuente: elaboración propia en Matlab

Aunque el ajuste sea un poco menor comparado con la función anterior, sigue siendo muy bueno (del 97%) y refleja con más sentido cómo se puede comportar Bitcoin en el futuro.

El 8 de marzo de 2023 (último día de nuestro periodo de estudio) el precio de cierre de Bitcoin fue de 21.718,08. Aunque registró caídas durante los 4 días posteriores – hasta los 20.000 aproximadamente – a partir de este punto remontó hasta situarse a 27.350,74 a día de hoy, 18 de marzo de 2023 (*Yahoo Finance*). Podemos comprobar que esta función Fourier predijo, solo con los precios del periodo de análisis y sus fechas, la recuperación del precio a partir de la segunda mitad de marzo (extremo derecho del gráfico anterior).

Define Misael, A. (2015) la *Serie de Fourier* como la herramienta matemática que nos brinda información sobre la frecuencia de un ciclo/función periódica a través de la aproximación mediante funciones simples de senos y cosenos. El valor añadido de la herramienta es permitir encuadrar la señal en el dominio del tiempo y su frecuencia para mejorar el análisis de las señales.

CAPÍTULO 3: FEATURE SELECTION Y MACHINE LEARNING

3.1 Análisis económico de variables relevantes para el precio del Bitcoin

Una vez explicada en el capítulo de **Introducción** la inflación actual sin precedentes, en esta sección **ilustraremos por qué esta contextualización es esencial para operar en el mercado de Bitcoin** y cuáles son las variables relacionadas que vamos a incorporar a los modelos objeto de esta investigación.

Las **expectativas de los individuos** influyen en gran medida en la formación de los precios de los activos financieros. En el caso concreto de la Bolsa, se pueden observar ciertos comportamientos que no tienen explicación pero se han generalizado con el tiempo, y son, por tanto, irracionales. A modo de ejemplo, los precios de cotización de las acciones del mercado estadounidense suelen subir en el mes de enero, el día antes de las vacaciones y los viernes, pero descender en la apertura del mercado el lunes (Farràs y García-Arenas, 2018).

El desajuste vivido en 2022 entre las proyecciones de los bancos centrales y la inflación real llevó a los inversores a recalibrar sus expectativas. Ya no solo preocupaba en el mercado el hecho de que la inflación hubiera alcanzado un nivel estructural y pudiera considerarse irreversible, sino que los bancos centrales tenían que aumentar aún más sus políticas monetarias contractivas. Esto impulsó a los mercados financieros a descontar los efectos de las subidas de tipos de interés incluso antes de que los bancos centrales orientaran sus acciones futuras. Cuando en junio de 2022 el BCE dejó entrever que tomaría después del verano "*una senda gradual pero sostenida de nuevas subidas de los tipos de interés*", las primas de riesgo de las deudas soberanas de los países del sur de Europa se dispararon, activando las alertas del mercado (Carbó Valverde y Rodríguez Fernández, 2022).

Una subida de los tipos de interés implica una mayor rentabilidad de los depósitos y los activos sin riesgo que motiva a los inversores a retirar sus fondos de la Bolsa – considerada una inversión de mayor riesgo y volatilidad – para aprovechar las rentabilidades “libres de riesgo” del momento y huir de la caída del mercado de renta variable. Cabe

puntualizar que una subida de tipos de interés favorece la inversión en renta fija solo de nueva emisión, pues los bonos ya emitidos sufren caídas en su precio que solo pueden paliarse manteniendo el activo hasta su vencimiento. Esto puede generar problemas de liquidez a entidades y gestoras financieras por estar invertidas en esta clase de activos a largo plazo (De la Cruz, 2021).

La FED comenzó antes que el BCE con la subida de los tipos de 2022 y multiplicó sus esfuerzos aumentándolos en 75 puntos básicos, su medida más agresiva desde 1994. (Carbó Valverde y Rodríguez Fernández, 2022). El anuncio de mayo provocó la bajada en picado de los índices bursátiles y valores, e inició una época de correcciones y espiral bajista que afectó al sector tecnológico (incluidas las criptomonedas) en especial². Estas empresas tienen que hacer frente a grandes inversiones que suponen un alto nivel de deuda, y si las deudas ya contraídas estaban referenciadas a tipo variable, o tienen necesidades de financiación en 2023, se ven muy afectadas por la política monetaria contractiva (Ruiz Dotras, 2022).

Ilustración 10: precios SP500 2022 y fechas en las que la FED anunció la subida de tipos de interés



Fuente: Caro Mora. (2023). Admiral Markets

En el gráfico podemos observar cómo reaccionó el mercado estadounidense (SP500) ante las tres subidas de los tipos de interés aprobadas en el año 2022 por la FED – marcadas por las líneas discontinuas. La primera subida, en marzo de 2022, no se recibió con caídas por ser únicamente de 25 puntos básicos. Las dos subidas posteriores, mucho más agresivas (de 50 y 75 puntos básicos)(Expansión, s.f.), fueron las que propiciaron las caídas y tendencia bajista (Caro Mora, 2022).

Como señala *The Economist* (2023), los bancos centrales han fijado su atención en los tipos de interés para el control de la inflación, desechando la importancia que tiene la cantidad de dinero en circulación (*money supply*). En los países de la OECD, su medida general aumentó un 12% solo en los 6 meses posteriores a febrero de 2020. Por ello, incorporar esta variable en el análisis mejora la predicción de la inflación y con ello, del comportamiento de la Bolsa.

Como indicio del **sentimiento de inquietud entre los inversores del mercado, el índice VIX (el Índice de Volatilidad)** es una medida porcentual muy útil para el mercado de Estados Unidos. Se calcula en función de la volatilidad esperada del índice SP500, para lo cual se toman las opciones *call* y *put* cuyo vencimiento se encuentra entre los 23 y 37 días. El VIX solo ha superado los 40 puntos 6 veces en su historia, y todas las ocasiones estaban relacionadas con momentos de extrema tensión en el mercado: con el estallido de la crisis hipotecaria en 2008 el VIX llegó a situarse en 79 puntos, y el 18 de marzo de 2020, fecha clave de noticias del coronavirus, superó los 80 puntos por primera vez en la historia. La guerra de Ucrania situó al VIX en 35 puntos, y se volvieron a alcanzar en fechas relacionadas con los anuncios de subidas de tipos de interés de la FED en 2022. Desde comienzos de 2023 nos situamos en niveles de entre el 20 y 25% (Admirals, 2023).

Ya establecidas las consecuencias generales que tiene un panorama macroeconómico inflacionista sobre los activos de renta variable y renta fija, y en especial, qué está ocurriendo en la Bolsa con este periodo inflacionista que comenzó en 2021, es preciso ver cómo vamos a incorporar este análisis a nuestra investigación y qué variables vamos a tomar en cuenta:

Existen numerosos **estudios recientes** que tratan de relacionar el Bitcoin con factores macroeconómicos y la inflación, con el interés específico de ver si esta criptomoneda podría actuar como un activo de cobertura (Abul Basher y Sadorsky, 2022), (Kumer Sarker y Wang, 2022), (Smales, 2022), (Marmora, 2022), o (Pinchuk, 2023).

La mayoría de los activos de renta variable se mueven en la misma dirección que el ciclo económico. Por ello, resulta fundamental encontrar activos que se comporten del modo contrario en Bolsa para poder lograr una mayor diversificación del *portfolio* (Abul Basher y Sadorsky, 2022).

Para nuestro modelo de predicción también es importante estudiar el impacto de estas variables en el precio de Bitcoin. Si podemos catalogarlo como un activo de cobertura ante la inflación y por tanto, ajeno al contexto macroeconómico, significa que no serán variables significativas para predecir su precio (Abul Basher y Sadorsky, 2022).

Teniendo en cuenta que vamos a tomar como periodo de análisis un momento sin precedentes desde el punto de vista macroeconómico (2022 y 2023), podemos ver si las variables macroeconómicas han tenido una mayor influencia frente a estudios de años anteriores; lo cual tendría sentido dada la dinámica global que hemos explicado en este capítulo.

El estudio llevado a cabo por el **Fondo Monetario Internacional** ('IMF' en inglés) y publicado en enero de 2022 revela resultados sorprendentes. Utilizando dos periodos de comparación "2017 – 2019" y "2020 – 2021", demuestra el enorme cambio de las correlaciones y repercusiones entre los mercados de renta variable y Bitcoin. antes y después de la pandemia (Fondo Monetario Internacional [FMI], 2022).

Ilustración 11: correlaciones de volatilidad y retorno entre criptomonedas y el mercado de renta variable comparando los periodos de análisis prepandemia y postpandemia (Fondo Monetario Internacional)

Figure 3. Rising Crypto-Equity Correlations

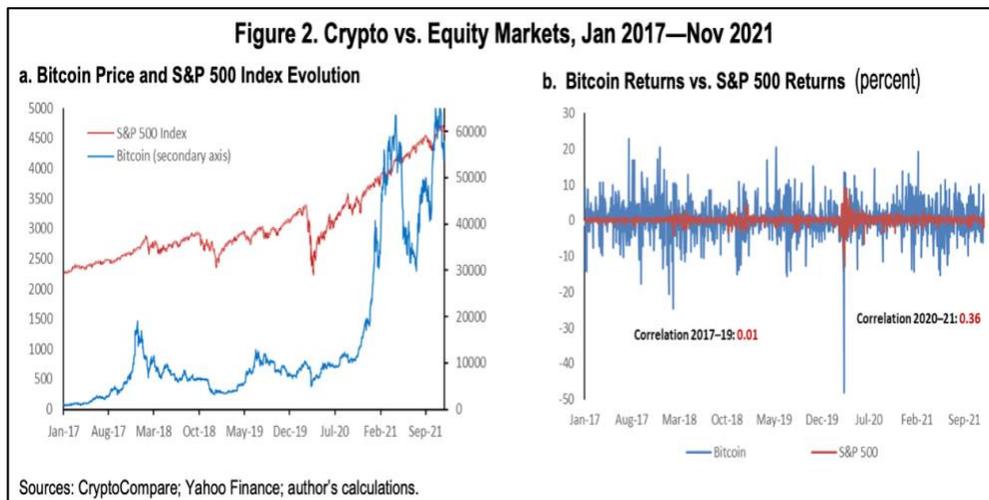
a. Volatility correlations				b. Return correlations					
Crypto	Equity Index	2017–19	2020–21	Crypto	Equity Index	2017–19	2020–21		
BTC	S&P 500	0.11	0.46	BTC	S&P 500	0.01	0.36		
	Nasdaq	0.09	0.46		ETH	Nasdaq	0.02	0.38	
	Russell 2000	0.07	0.48			TTH	Russell 2000	0.03	0.36
	MSCI EM	0.12	0.48				ETH	MSCI EM	0.02
ETH	S&P 500	0.08	0.25	TTH				S&P 500	0.06
	Nasdaq	0.06	0.24		ETH			Nasdaq	0.07
	Russell 2000	0.03	0.25			TTH		Russell 2000	0.07
	MSCI EM	0.08	0.25				TTH	MSCI EM	0.10
TTH	S&P 500	-0.02	0.35	TTH				S&P 500	0.02
	Nasdaq	-0.02	0.34		TTH			Nasdaq	0.02
	Russell 2000	0.01	0.28			TTH		Russell 2000	0.06
	MSCI EM	-0.01	0.31				TTH	MSCI EM	0.02

Sources: CryptoCompare; Yahoo Finance; author's calculations.
 Notes: Correlations of returns and volatility are calculated using daily prices, excluding non-trading days, over the periods Jan 2017–Dec 2019 and Jan 2020–Nov 2021. Returns are defined in log difference terms, and volatility is based on intra-day prices. BTC = Bitcoin, ETH = Ether, TTH = Tether.

Fuente: FMI, 2022

La **correlación entre la volatilidad** del precio de Bitcoin y la volatilidad del índice SP500 después de la pandemia se ha multiplicado por más de cuatro, y el FMI estima que la contribución de Bitcoin a la variación de la volatilidad del índice SP500 ha aumentado en un 16%. En cuanto a sus rendimientos, el patrón es similar (FMI, 2022).

Ilustración 12: evolución 2017 – 2021 de la correlación entre los precios y retornos de Bitcoin y el SP500



Fuente: FMI, 2022

Los resultados del estudio son notables debido al cambio experimentado de un periodo a otro:

- En 2017 la contribución de los criptoactivos a la explicación de las variaciones en el mercado de renta variable de Estados Unidos era aproximadamente de un 1%.
- Después de la pandemia (al menos hasta 2021) la volatilidad de los precios de Bitcoin explica aproximadamente 1/6 de la volatilidad de los índices bursátiles estadounidenses. Los rendimientos explican una décima parte de la variación de los rendimientos de las acciones de Estados Unidos (FMI, 2022).

En definitiva y tomando en consideración el análisis macroeconómico realizado, estas son las variables a considerar en nuestros modelos de predicción del precio de Bitcoin: Headline inflation (CPI), Core Inflation, Money supply, Interest rate, Exchange rate (US/EUR), VIX Index, Effective Federal Funds rate, SP500, NASDAQ y 10-Year US Treasury Rate.

Nuestra **hipótesis inicial** en cuanto al análisis fundamental es que para nuestro periodo de investigación existe una gran correlación entre Bitcoin y el mercado tradicional, de manera que cambios en los índices del mercado, su volatilidad, etc., tendrán gran peso como variables explicativas de Bitcoin en el espacio de tiempo seleccionado, donde un mercado más inquieto ha visto las consecuencias de las políticas expansivas de los bancos centrales post – pandemia y vivimos un escenario inflacionista y de incertidumbre muy superior a las últimas décadas.

3.2 Feature selection

Podríamos definir '*feature selection*' como el proceso de selección de las variables más relevantes o un subconjunto de ellas para una variable objetivo "Y" determinada (Kumar y Minz, 2014). En nuestro caso, dado que estamos estudiando el Bitcoin para operar en el mercado, el proceso de *feature selection* debe de ir enfocado a seleccionar las variables que más influyen en la determinación de su precio (nuestra variable "Y") para obtener su predicción a partir de ellas.

Ya hemos mencionado que existe una cantidad extensa de estudios de investigación acerca de las variables más influyentes en el precio del Bitcoin y los mejores modelos de predicción, pero la mayoría de estos análisis se centran más en características técnicas del Bitcoin como su volumen de negociación o el *hash rate*, y desatienden el marco macroeconómico.

Después de llevar a cabo un análisis económico del mercado en nuestro periodo de investigación, y utilizar el estudio del FMI (2022) como precedente de la mayor correlación entre el mercado de las criptomonedas y el tradicional tras la pandemia, estas son las variables que vamos a someter a *feature selection* y sus respectivas fuentes:

1. Precio de Cierre de Bitcoin día anterior: Yahoo finance
2. Cotización del SP500: Yahoo finance
3. Cotización del NASDAQ: Yahoo finance
4. Volumen de Bitcoin: Yahoo finance
5. Hash Rate de Bitcoin: Nasdaq Data Link

6. Mining difficulty de Bitcoin: Nasdaq Data Link
7. Money supply US (Oferta de dinero M2 en EEUU): Federal Reserve Bank of Sant Louis
8. 10 Year Real Interest Rate (Tipo de interés real a 10 años EEUU): Federal Reserve Bank of Sant Louis
9. Effective Federal Funds Rate (Tasa efectiva de fondos federales EEUU): Federal Reserve Bank of Sant Louis
10. CPI (Inflación general EEUU): US Inflation Calculator
11. Core inflation (Inflación subyacente EEUU): US Inflation Calculator
12. Google trend de “Bitcoin”: Google trends
13. VIX Index (“Índice del Miedo”): Yahoo finance
14. US 10 Year Bond Yield (Rentabilidad del Bono del Tesoro de EEUU a 10 años): Yahoo finance
15. USD / EUR (Tipo de cambio dólar/euro): Yahoo finance

Como podemos comprobar, **3 de las variables** anteriores obedecen a **aspectos más técnicos** del Bitcoin y la tecnología *blockchain* en sí que al mercado: *mining difficulty*, *hash rate* y el volumen.

El **volumen de Bitcoin** es la variable más intuitiva al referirse simplemente a la cantidad de Bitcoin comprada y vendida en un periodo de tiempo, utilizada del mismo modo para el resto de activos de renta variable. Sin embargo, sí que conviene hacer un breve apunte sobre las otras dos variables escogidas.

Tomando en consideración la explicación dada sobre el Bitcoin y cómo funciona la *blockchain*, la *mining difficulty* se podría definir como la complejidad a nivel de computación de resolver el hash de cada nuevo bloque del registro público de transacciones de la red de Bitcoin. Cuanto mayor es la capacidad de procesamiento/computación que participa en el sistema, más aumenta la dificultad, por lo que resulta interesante estudiar si la

dificultad de “minar” un nuevo Bitcoin influye en su precio, hecho demostrado por trabajos de investigación anteriores (Zhang, X. et al., 2018).

Por otro lado, el *hash rate* hace referencia a la cantidad de operaciones matemáticas que una red de *blockchain* es capaz de resolver, en nuestro caso la red de mineros de Bitcoin. Este a su vez es un indicador de potencia y seguridad de la propia red. Durante mucho tiempo se ha considerado que este aspecto técnico está relacionado con el precio del Bitcoin, y por ello resultaba muy útil emplear la variable en los modelos de predicción. Aunque existen estudios que sostienen que esto solo ocurrió en la fase de crecimiento exponencial del Bitcoin de 2017, conviene también tenerlo en cuenta en el panorama actual (Fantazzini y Kolodin, 2020).

Nuestro objetivo en este capítulo es la elección de un modelo para predecir nuestra variable “Y”, el precio de cierre de Bitcoin, a partir de las 6 variables explicativas más relevantes de entre las 15 seleccionadas. Para ello, en esta sección vamos a contrastar los resultados de un proceso de *feature selection* clásico y más avanzado utilizando Jupyter.

Definido el **proceso de *feature selection*** como la búsqueda de las variables o atributos relevantes para construir un clasificador que pueda predecir el objeto a partir de sus características (Cardona, C. y Velásquez, J., 2006), se trata de lograr mejores resultados de predicción al mismo tiempo que se aumentan la rapidez y claridad del proceso (Vergara, J., 2015). Hay dos maneras de realizar este proceso: o bien midiendo la relación entre cada atributo y el objeto, o bien midiendo el desempeño del clasificador utilizando cada variable evaluada (Cardona, C. y Velásquez, J., 2006).

Vamos a estudiar dos técnicas muy populares de *feature selection* utilizadas en los casos de variables de entrada y variable objetivo numéricas. Uno con un enfoque clásico y otro más avanzado para obtener un criterio definitivo en la selección de nuestras variables predictoras: la estadística de correlación (*f_regression*) y de información mutua (*mutual information*).

La correlación en Estadística sirve para evaluar en qué medida una variable se ve alterada si el valor de otra es modificado. La medida más utilizada es el Coeficiente de Correlación de Pearson, la cual asume una distribución normal para cada variable y ofrece resultados en cuanto su relación lineal con la variable dependiente u objetivo (Brownlee, 2020). Para este estudio nosotros implementamos el test *f_regression*, disponible en la biblioteca *stickit-learn* de Python y utilizado para medir la relación lineal entre dos variables.

Su funcionamiento se basa en tomar el conjunto de las variables y su vector objetivo, en base a lo cual devolverá un valor p y puntuación F para cada una de ellas. Estos valores son los utilizados para medir la relevancia individual de cada variable y así ayudar en la identificación de las características más importantes del modelo de predicción, que serán aquellas que arrojen una mayor puntuación (Brownlee, 2020).

La información mutua en Estadística se encuadra dentro de los procesos de selección de variables basados en la medición directa de la relación entre cada atributo y la clase a la que pertenecen los objetos; y su valor esencial frente a otros métodos estadísticos que siguen su misma filosofía radica en que esta es capaz de detectar relaciones lineales y no lineales entre ellos (Cardona, C. y Velásquez, J., 2006).

El *mutual information* funciona como una medida cuantitativa de la información ofrece una variable aleatoria sobre otra variable, o la reducción en la incertidumbre de una variable una vez la otra es conocida. El concepto pertenece por tanto al campo de la Teoría de la Información y es la aplicación del beneficio de la información al *feature selection*, a través de la cuantificación de la dependencia entre dos variables (Brownlee, 2020).

De forma **similar** al test *f_regression*, en el proceso de *feature selection* se utiliza el *mutual information* para evaluar la relación entre cada variable independiente y su variable objetivo. Lo que se trata de conseguir es la selección de las variables o características que más información ofrezcan sobre la variable dependiente, para ignorar las redundantes o

irrelevantes. Cuanto mayor sea el valor ofrecido por el *mutual information*, mayor será la relación entre las dos variables y viceversa (Brownlee, 2020).

Pero la forma de calcular el valor del test *f_regression* o del *mutual information* para cada una de las variables independientes es muy distinto y propiciará conclusiones diferentes en cada proceso. Mientras que el *f_regression* es un método estadístico que asume una correlación lineal entre la variable objetivo y las independientes para calcular sus valores F y p, el *mutual information* es un método teórico que mide la información que cada variable independiente proporciona sobre la objetivo (Brownlee, 2020).

En consecuencia, **la diferencia fundamental entre ambos procesos** radica en que el *f_regression* únicamente capta la dependencia lineal y por tanto, podría considerar no significativa o menos significativa una variable que se relacionara de otra forma, mientras que el *mutual information* puede detectar cualquier tipo de dependencia entre variables. En consecuencia, podrá haber variables muy significativas que *mutual information* capte y el *f_regression* no (Pedregosa et al., 2011).

Estos han sido los resultados arrojados por nuestros métodos de *feature selection*:

Ilustración 14: variables significativas F-test

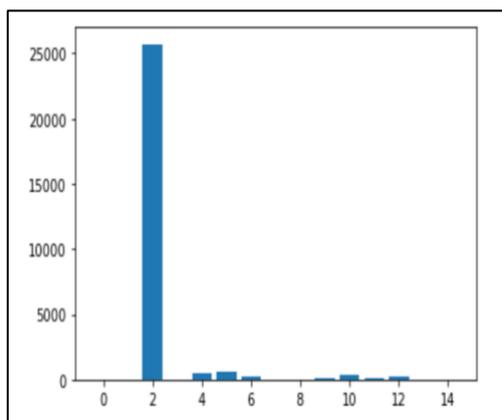
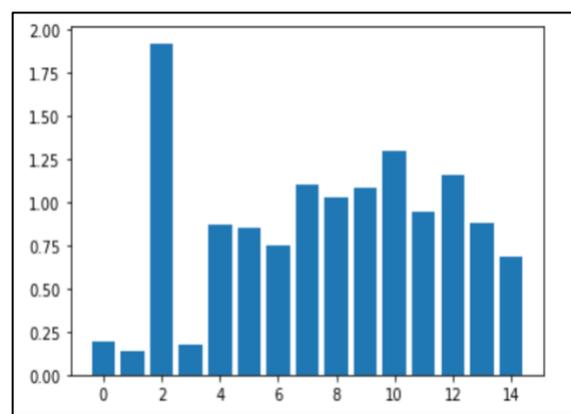


Ilustración 13: variables significativas Mutual Information



Fuente: elaboración propia en Jupyter

Los **resultados del F-test** determinan la variable “Precio de cierre de Bitcoin día anterior” como la más significativa con mucha diferencia respecto a las demás, seguida de la cotización del NASDAQ, del SP500, y los Federal Funds Effective Rate y 10-Year Real Interest Rate.

Por otro lado, el **resultado de *mutual information*** coincide con el F-test en que el precio de Bitcoin el día anterior es la variable más significativa, y los Federal Funds Effective Rate y 10-Year Real Interest Rate como variables más significativas a continuación; pero esta vez seguidas de la inflación general, inflación subyacente y oferta de dinero (M2) de Estados Unidos (y no de la cotización de los mercados tradicionales).

En base a estas observaciones, podemos **concluir** que hay suficiente evidencia empírica de que el “Precio de cierre de Bitcoin el día anterior” (nº 2 en el gráfico) es la variable explicativa más significativa, y sería preciso estudiar el grado de predicción de un modelo que usa solo esta variable.

Queda demostrada nuestra hipótesis inicial de que son las variables macroeconómicas y las representativas del mercado tradicional las que mejor explican los precios de Bitcoin desde marzo de 2022 a marzo de 2023. De hecho, las tres variables de aspectos técnicos (volumen, *mining difficulty* y *hash rate*) son las que han recibido una menor puntuación tanto en el F-test como en *mutual information*. A modo de **ejemplo**, en *mutual information* la variable de inflación general en Estados Unidos (CPI) (nº 7) ha recibido una puntuación de 1.10, comparada con el 0.19, 0.13 y 0.17 del *mining difficulty*, *hash rate* y volumen, respectivamente (nº 0, 1 y 3).

El hecho de que las **variables de inflación y *money supply*** sean muy significativas en *mutual information*, mientras que en F-test destacan con mayor importancia el SP500 y el NASDAQ, puede ser debido a la diferencia entre los dos procesos explicado *supra*.

3.3 Machine Learning

El ‘*Machine Learning*’ o aprendizaje automático es una ramificación de la Inteligencia Artificial que, a partir de una variable objetivo “Y”, se divide en aprendizaje supervisado, aprendizaje no supervisado, y aprendizaje por refuerzo (Chen, 2023).

En esta sección buscamos el mejor modelo – tanto de regresión como de clasificación – para la predicción del precio de Bitcoin con las aplicaciones de ‘*Regression Learner*’ y ‘*Classification Learner*’ de Matlab, por lo que nuestro estudio se encuadra dentro la categoría de ‘aprendizaje supervisado’. En función de los resultados, elegiremos qué modelo debemos implementar en nuestro robot de *trading* basado en *Machine Learning*.

La aplicación ‘*Regression Learner*’ de Matlab es utilizada para entrenar modelos de regresión entre los que se incluyen: modelos de regresión lineal, árboles de regresión, procesos de regresión gaussianos, máquinas de vectores soporte o modelos de regresión de redes neuronales. Una vez elegido el tipo de modelo de regresión para la sesión de entrenamiento, en lugar de seleccionar de forma manual los parámetros internos de cada modelo, podemos automatizar la optimización y selección de los hiperparámetros dentro de la propia aplicación de Matlab conforme a la optimización bayesiana por defecto. Escogemos esta opción en base a que los valores de los distintos hiperparámetros afectan en gran medida el rendimiento de un regresor o clasificador, y su optimización manual es difícil y lenta (Mathworks, 2023).

El **funcionamiento de la optimización de parámetros en Matlab** es el siguiente: para el tipo de modelo escogido (por ejemplo, SVMs), la aplicación prueba distintas combinaciones de valores para los hiperparámetros mediante un esquema de optimización que busca minimizar el error cuadrático medio conforme a una optimización bayesiana por defecto. El propósito de la optimización en general es localizar el conjunto de los valores de los hiperparámetros que minimice la función objetivo, es decir, reduzca el error cuadrático medio lo máximo posible. En este contexto, definimos el punto como el conjunto de los valores de los hiperparámetros y la función objetivo como el error cuadrático medio. La aplicación

devolverá el modelo de regresión óptimo con los hiperparámetros también optimizados junto con las métricas y gráficos que corresponden al modelo entrenado conforme a estos valores de hiperparámetros fijos (Mathworks, 2023).

La *optimización bayesiana* se sirve de los siguientes elementos para la minimización de su función objetivo (x): un modelo de regresión de un proceso gaussiano en función de ' x ', un procedimiento bayesiano de actualización que modifica el modelo anterior en cada evaluación de ' x ', y una función de adquisición en función de ' x ' que se maximiza para seleccionar el siguiente punto ' x ' de evaluación. Partiendo de un conjunto de datos de prueba que modulan la función objetivo inicial, la optimización bayesiana actualiza internamente el modelo de regresión de la función objetivo y utiliza las predicciones de la función para entrenar el modelo. Para seleccionar el siguiente punto de evaluación del modelo, se sirve de la función de adquisición pues es capaz de evaluar la selección de puntos donde la función objetivo ya ha ofrecido valores bajos y donde todavía no se ha modelado de forma adecuada; buscando un equilibrio entre las dos estrategias (Mathworks, 2023).

La métrica utilizada para la comparación de los tipos de modelos de regresión obtenidos tras la sesión de entrenamiento en '*Regression Learner*' de Matlab es el resultado **RMSE** (raíz del error cuadrático medio en español) conforme a la **técnica de validación cruzada de 10 pliegues** (*10 – fold cross validation*) (Mathworks, 2023):

- A. Un **10 – fold cross validation** o validación cruzada de 10 pliegues implica que el conjunto de datos de entrenamiento se divide en 10 subconjuntos distintos ("pliegues"), donde 9 de ellos se utilizan para entrenar al modelo conforme a la optimización bayesiana, mientras que el restante se usa para probar su rendimiento. Este proceso se repite 10 veces de manera que cada subconjunto de datos es usado 1 vez como pliegue de prueba.

En nuestro caso, el **funcionamiento de la validación cruzada de 10 pliegues** escogida sería el siguiente: se divide el conjunto de datos en 10 subgrupos (cada

subconjunto representa 1/10 de los datos) y se entrenan los modelos con las variables escogidas y la variable objetivo (precio de Bitcoin) excluyendo los primeros 1/10 datos; dando lugar a un primer modelo entrenado. A continuación, para el entrenamiento del segundo modelo, prescindimos del 1/10 del segundo subgrupo de datos, y así sucesivamente hasta que se hayan entrenado los 10 pliegues. Debido al empleo de esta técnica, no es necesario dividir los datos en un *training set* y un *test set* ya que el riesgo de sobre – optimización del modelo es menor, pues los pliegues de entrenamiento actúan como *training sets*, y el pliegue de prueba como el *test set* (repitiéndose el proceso 10 veces).

- B.** El **RMSE del modelo** se obtiene a través de la media de la raíz del error cuadrático medio de los 10 pliegues de prueba, y se calcula como la diferencia media entre las predicciones y los valores actuales de Y de todos los pliegues de validación. De esta forma, la media de los valores RMSE de los pliegues entrenados sirve como medida general del rendimiento del modelo: cuanto menor sea su valor, mejor predicción arroja.

Para llevar a cabo la tarea de optimización de modelos de regresión y sus hiperparámetros descrita, entrenamos en Matlab nuestro conjunto de datos mediante todas las combinaciones a nuestro alcance:

- Con las 6 variables de mayor valor obtenidas conforme al proceso de *mutual information* descrito en la sección anterior
- Con todo el conjunto de datos y variables sin hacer uso del *feature selection*
- Con las variables más significativas conforme al proceso de *feature selection* realizado en la propia aplicación de ‘*Regression Learner*’ (el MRMR o *Minimum Redundancy Maximum Relevance*).

El **algoritmo de Mínima Redundancia o Máxima Relevancia (MRMR)** también es un proceso de selección de las variables más relevantes sobre una variable de respuesta (*feature selection*), pero utiliza la información mutua entre pares de variables para medir la redundancia entre ellas, y entre cada variable y la variable objetivo para medir la relevancia de esta conforme a la variable dependiente. El objetivo es utilizar procesos de *mutual information* para encontrar un conjunto de variables que maximice su relevancia para la predicción de la variable Y, al mismo tiempo que se minimiza su redundancia para que sean lo más disímiles posible y así aumente el rendimiento del modelo (Mathworks, 2023).

En la sesión de entrenamiento empleamos los 24 modelos distintos que ofrece la aplicación de ‘Regression Learner’ con el fin de obtener los mejores modelos de regresión para la predicción del precio de Bitcoin, dada la combinación de hiperparámetros observada tras el proceso de optimización bayesiana descrito.

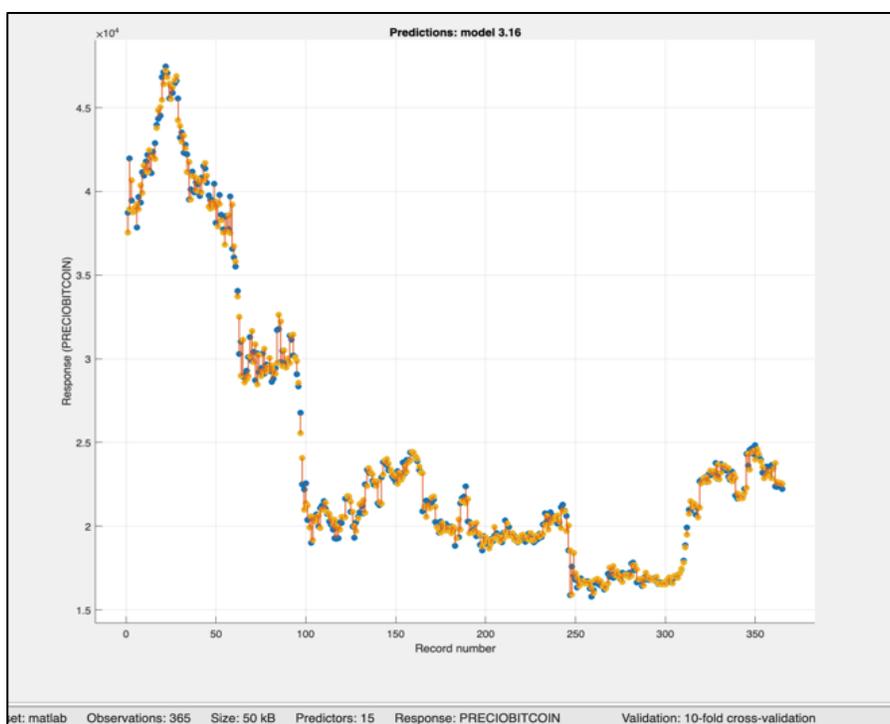
Llegamos a la **conclusión** de que los **mejores modelos**, medidos en función del mínimo error RMSE, fueron los siguientes:

- 1. Proceso de Regresión Gaussiana (PRG)** con las 6 variables más significativas de acuerdo a *mutual information* descrito en la sección anterior (Precio de Bitcoin el día anterior, Federal Funds Effective Rate, 10-Year Real Interest, inflación general, inflación subyacente y money supply (M2)). El error RMSE fue de 794.19.
- 2. Máquina de vector de soporte (SVM)** utilizando todas las variables del conjunto de datos (es decir, sin hacer *feature selection*). El error RMSE fue de 781.72.
- 3. Proceso de Regresión Gaussiana (PRG)** con las 6 variables más significativas de acuerdo al *feature selection* de Matlab (algoritmo MRMR). Las variables más significativas fueron el Precio de Bitcoin el día anterior, US 10 Year Bond Yield, USD/EUR, Money Supply, NASDAQ y VIX Index. El error RMSE fue de 765.74.

Todos registraron un R cuadrado del 99%.

En conclusión, el **modelo ganador** de entre todos los entrenamientos realizados, en términos del mínimo RMSE, fue el **Proceso de Regresión Gaussiana que empleó las 6 variables más significativas de acuerdo al algoritmo de Mínima Redundancia o Máxima Relevancia (MRMR).**

Ilustración 15: resultados del mejor modelo de regresión, Proceso de Regresión Gaussiana



Fuente: elaboración propia en Matlab

Los puntos azules representan las observaciones reales de los precios de Bitcoin y los amarillos las observaciones del modelo. Las líneas entre los puntos miden el error de las predicciones.

A continuación, ejecutamos el proceso anterior con la aplicación '*Classification Learner*' de Matlab para encontrar el mejor modelo de clasificación capaz de predecir a partir de nuestras variables de estudio si el precio de Bitcoin va a ser mayor o menor en el siguiente intervalo en comparación con el actual. No obstante, anticipamos que los resultados no fueron tan exitosos como para los modelos de regresión.

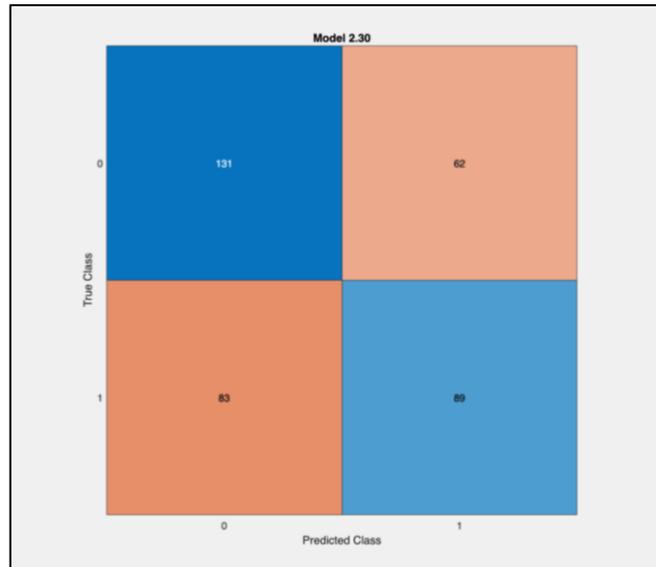
En '*Classification Learner*', de forma similar a la aplicación de '*Regression Learner*', podemos llevar a cabo un proceso de aprendizaje supervisado para entrenar modelos de los siguientes métodos clasificadores: árboles de decisión, análisis discriminante, máquinas de vectores de soporte, redes neuronales, etc. (Mathworks, 2023).

La **función objetivo** se define en función de las etiquetas de "Y" (el precio de Bitcoin sube/baja en el siguiente intervalo) y el modelo de clasificación asigna una de las etiquetas al conjunto de variables "X". Una vez entrenado, puede emplearse para la predicción de la siguiente etiqueta dados los valores del conjunto "X" (Uzonyi, N., 2021).

El mejor modelo de clasificación obtenido fue una red neuronal que utilizaba las 6 variables más significativas del *mutual information* y registró un índice de precisión del 60%.

En este caso, la **métrica de comparación** utilizada para los modelos entrenados fue la **matriz de confusión**. El eje X de la matriz se corresponde con la etiqueta "y" predicha y el eje Y con la etiqueta "y" esperada. Este indicador actúa como medida del rendimiento del modelo en tanto en cuanto la diagonal principal (cuadrados azules) representa a las etiquetas "y" correctamente predichas por el modelo de clasificación, y los cuadrados naranjas las predicciones incorrectas. Cuanto mejor sea la predicción, más casos se situarán en la diagonal principal y menos en el resto (Mathworks, 2023).

Ilustración 16: matriz de confusión del mejor modelo de clasificación, red neuronal



Fuente: elaboración propia en Matlab

Los resultados empíricos de esta sección también demuestran que para nuestro periodo de análisis **las variables más importantes para la predicción del precio de Bitcoin son un reflejo del mercado tradicional y no obedecen a aspectos técnicos de la criptomoneda.**

Debido a que el 1º y 3º modelo de regresión – ordenados por magnitud de precisión en la predicción – han sido **Procesos de Regresión Gaussiana, nuestro robot de trading** incorporará dicho modelo utilizando la predicción del precio del día siguiente como señal de compra o de venta en el mercado.

Este será su **funcionamiento**:

- Si la predicción del precio del día siguiente es superior al precio actual, el robot ejecutará una señal de compra, y viceversa. Así, compra el precio más barato y lo vende más caro.
- Si el robot está en posición de compra y la predicción del precio del día siguiente es inferior al precio actual, ejecuta una señal de *stopcompra* (y viceversa).

Realizamos un breve apunte sobre el funcionamiento de los mejores modelos de regresión y clasificación tras las sesiones de entrenamiento de Matlab:

3.3.1 Proceso de Regresión Gaussiana (PGR)

El Proceso de Regresión Gaussiana ('GPR' en inglés) es un “modelo probabilístico no paramétrico basado en *kernel*” utilizado en la regresión para modelar la relación entre las variables de entrada y salida (Mathworks, 2023). A partir de un conjunto de datos de entrenamiento, el modelo predice el valor de salida de “Y”.

Un “*procesos gaussiano*” es una sucesión de variables aleatorias (proceso estocástico) de la cual se asume que cualquier subconjunto sigue una distribución normal. Por tanto, se define como la presunción de que un vector de variables infinitas sigue una distribución gaussiana, de manera que la inferencia estadística es en cuanto a las funciones y no a los parámetros (García, I., Trigo, L., Costanzo, S. et al, 2017).

El “*kernel*” es la función matemática que se emplea en el modelo para medir la similitud – covarianza – entre los puntos de datos de entrenamiento, donde se considera que las variables predictoras con alta similitud tendrán valores de respuesta “Y” similares. A partir del *kernel*, se crea una función de densidad de probabilidad que modela la relación entre las variable de entrada y salida (las predictoras y la respuesta), dando lugar a una función gaussiana que se ajusta a los datos (como la que vimos en la sección de *curve – fitting supra*)(Mathworks).

En definitiva, la función matemática *kernel* mide la similitud entre las variables predictoras, y a partir de esta, se generan funciones que expresan la relación entre las variables “X” e “Y” que permiten al modelo generar las predicciones.

El hecho de que existan varios tipos de ‘*kernel*’ lo convierte en un modelo muy versátil, pero su característica esencial es que **su predicción es probabilística (gaussiana)**. Esto implica que se pueden calcular intervalos de confianza a partir de las predicciones que permitirán

localizar el “ruido” de las observaciones y si es preciso ajustar la predicción en ciertas regiones de interés. Son más efectivos en espacios de menor dimensión, lo cual es relevante a efectos de la programación del robot (*Unipython*).

3.3.2 *Redes Neuronales Artificiales*

Las Redes Neuronales Artificiales son un modelo de clasificación que adopta su nombre del similar funcionamiento a nuestro sistema nervioso biológico. Cada “**neurona**” funciona como un elemento de procesamiento interconectado que coopera con el resto de elementos o “neuronas” para generar la función de salida (Uzonyi, N., 2021).

Para ello utiliza un **nodo de agregación y una función de activación** (Uzonyi, N., 2021)

$$f(x) = (\sum_{i=1} w_i * x_i) + b$$

Donde:

- La **x** representa al conjunto de variables independientes, de forma que ***x_i*** se refiere a cada una de ellas de forma individual.
- La **b** representa el parámetro del sesgo
- La ***w_i*** representa el peso de ***x_i*** y es el que debe “aprender” el modelo

Las unidades de procesamiento del modelo están conectadas entre sí mediante el valor numérico de ***w_i*** y su **funcionamiento** es el siguiente: cuando la neurona artificial recibe del exterior o de sus conexiones un peso (***w_i***) para los valores de los *inputs* (variables ***x_i***), compara la suma de estos valores con la variable de salida dada por el usuario (Mercado, D., Pedraza, L. y Martínez, E., 2015). Si la iguala o supera, envía el *output* generado (***w_i*** de ***x_i***) al resto de neuronas conectadas, generando una variable de salida que alimenta al resto de neuronas artificiales (UNIR Revista, 2021).

Una red neuronal básica tiene 3 capas de neuronas: la capa de entrada, la capa de procesamiento, y la capa de salida. Cuanto más compleja sea la red neuronal, tendrá más capas de procesamiento ocultas y neuronas artificiales en cada una. La capa de entrada es la que recibe la información del exterior, y la capa de salida es la encargada de generar la respuesta del modelo (Manjarrez, 2014). Las neuronas situadas en las capas ocultas utilizan la información recibida de las neuronas de la capa de entrada para generar el *output* que se envía a las neuronas artificiales de la capa de salida (Sotaquirá, 2018).

Durante el entrenamiento, la red neuronal se dedica a ajustar el peso de conexión entre las capas neuronales para mejorar su rendimiento, modificando o ajustando su estructura y el peso de las variables de entrada (w_i), para minimizar el error en la salida (Uzonyi, 2021). Su alto rendimiento como modelo de clasificación predictivo se basa en su capacidad para identificar patrones complejos entre los datos y generalizar a partir de ellos, además de mejorar su precisión a medida que recibe nueva información (Pérez, 2002).

CAPÍTULO 4. COMPARACIÓN DE ROBOTS

En este capítulo llevaremos a cabo la **exposición de los resultados empíricos de nuestros robots de trading en Python** tomando como referencia los precios históricos de Bitcoin en nuestro periodo de análisis: 8 de marzo de 2022 – 8 de marzo de 2023 . Primero mostraremos los gráficos representativos de las señales de compra y venta (representadas por rombos verdes y rojos) de cada uno de los robots, para comparar a continuación el rendimiento según las métricas financieras elegidas.

El **capital inicial** en todos los robots es de 10.000 y el rendimiento de Bitcoin en nuestro periodo de investigación es del -47% aproximadamente. Todos los cripto – robots están programados para poder realizar **shorts** en el mercado, fundamental para entender las rentabilidades arrojadas en el año bajista del activo. Las funciones de compra y venta operan con todo el capital y las acciones del robot, de forma que en cada operación se arriesga la totalidad de la cartera.

4.1 Robot de análisis técnico

Una vez definidos en el Capítulo 2 los indicadores técnicos a emplear en nuestro robot más tradicional, conviene exponer en esta sección la **estrategia de inversión programada**. Para nuestras señales de compra y venta tomaremos los siguientes indicadores:

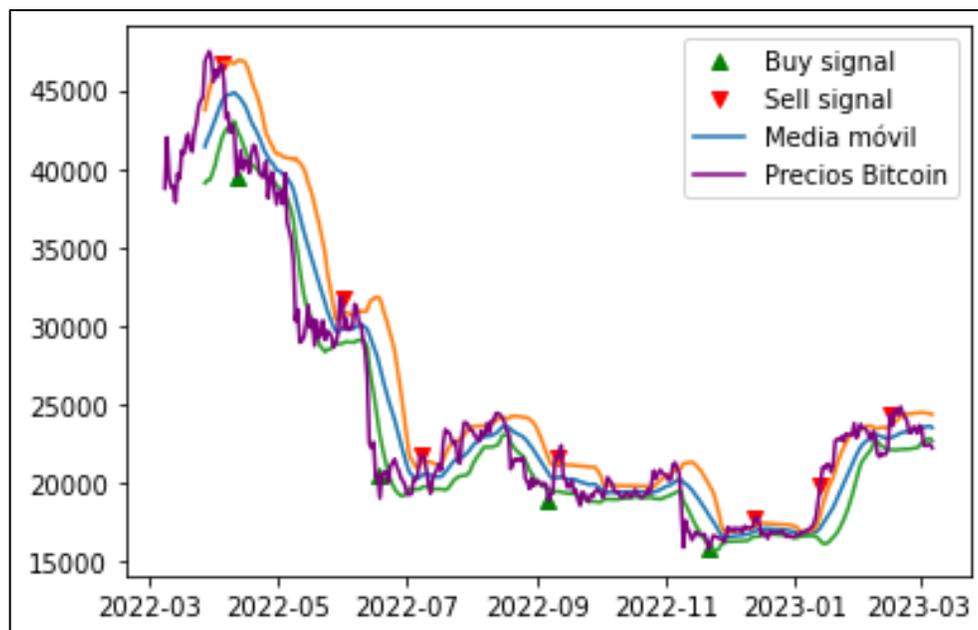
1. Media móvil de los últimos 10 periodos
2. Línea ADX y su valor de 25 como referencia de la tendencia
3. Índice de Fuerza Relativa (IFR) y su valor de 50 como referencia de señales de compra y venta
4. Oscilador estocástico y el cruce de sus líneas %D y %K de 14 periodos como referencia de señales de compra y de venta

Con esta combinación nunca ignoramos la tendencia– regla fundamental del análisis técnico – porque el ADX deberá registrar un valor mínimo de 25, y empleamos la media móvil de

los precios los últimos 10 días. Tomamos los valores de los osciladores para evaluar los momentos de entrada y salida del mercado.

Nuestro objetivo es que el robot de *trading* opere de forma óptima tanto si nos encontramos en momentos de tendencia alcista o bajista clara – donde los indicadores de tendencia tendrán más peso – como si asistimos a movimientos laterales del mercado.

Ilustración 17: señales de compra y venta cripto – robot de análisis técnico



Fuente: elaboración propia en Python

La línea morada representa los precios de Bitcoin en el periodo, la línea azul muestra la media móvil de los últimos 10 días y las líneas naranja y verde las bandas de Bollinger, que funcionan como funciones de stopcompra y stopventa.

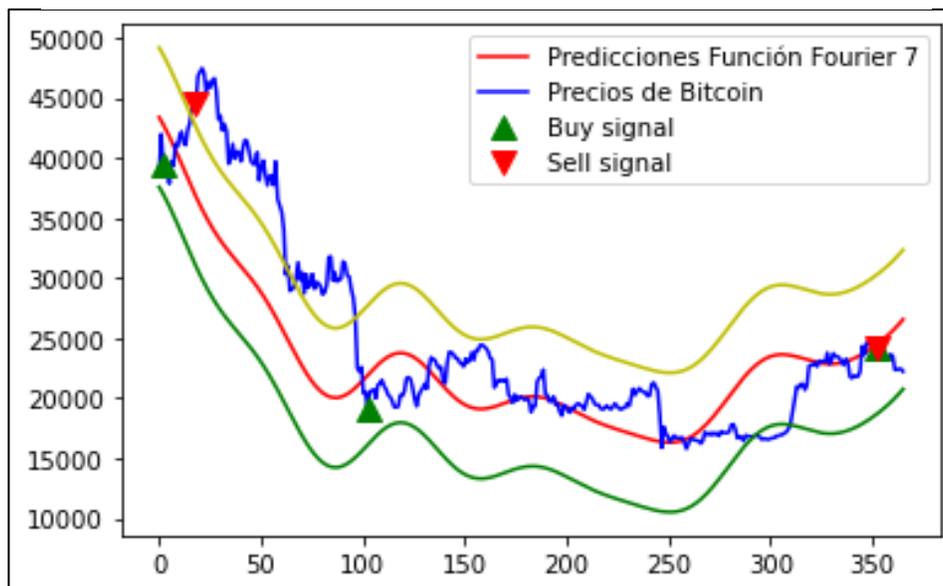
El capital final obtenido fue de 16.696,69: rentabilidad del 66,96%.

4.2 Robot de *curve – fitting*

En este cripto – robot basado en las predicciones obtenidas a partir de la **función Fourier de grado 7** explicada en el Capítulo 2, primero **definimos la función en Python** conforme a los coeficientes obtenidos en Matlab. Utilizamos la predicción de los precios y su desviación típica para simular lo que serían unas bandas de Bollinger, donde la banda inferior se corresponde con las predicciones de la función menos su desviación típica y viceversa.

Para nuestra **señal de compra** analizamos si el precio hoy es menor que el precio de mañana en función de nuestra predicción, y en caso afirmativo, ejecutamos la acción de compra. De este modo, nos aseguramos comprar hoy a un precio más barato. Para nuestra **señal de venta** queremos que el precio hoy sea más alto que la predicción de mañana más su desviación típica. Es decir, más alto que la banda de precios superior definida. Por último, ejecutaremos una función de **stopcompra** cuando en posición de compra el precio de hoy sea más alto que el previsto en la banda superior del día siguiente, y una **stopventa** cuando el precio de hoy sea más alto que el predicho para el día siguiente.

Ilustración 18: señales de compra y venta cripto – robot de curve - fitting



Fuente: elaboración propia en Python

La línea azul representa los precios de Bitcoin en el periodo, la línea roja las predicciones de la función y las líneas amarilla y verde las predicciones más y menos su desviación típica, simulando la actuación de unas bandas de Bollinger.

El capital final del robot fue de 19.254,02: rentabilidad del 92,54%.

4.3 Robot Machine Learning

Este robot de *trading* emplea las **predicciones obtenidas a partir del Proceso de Regresión Gaussiana** de *Machine Learning* descrito en el Capítulo 3. Las señales de compra y venta siguen el mismo razonamiento que en el cripto – robot de *curve – fitting*, de forma que la predicción del siguiente intervalo es la que determina la decisión. A diferencia del anterior, las señales de stopcompra y stopventa solo utilizan la predicción y no la desviación típica.

Ilustración 19: señales de compra y venta cripto – robot de Machine Learning



Fuente: elaboración propia en Python

La línea naranja representa los precios de Bitcoin en el periodo y la línea azul las predicciones del modelo (no visible por su alta precisión).

El capital final del robot fue de 22,427.76: rentabilidad del 124%.

4.4 Robot de inteligencia artificial y análisis técnico

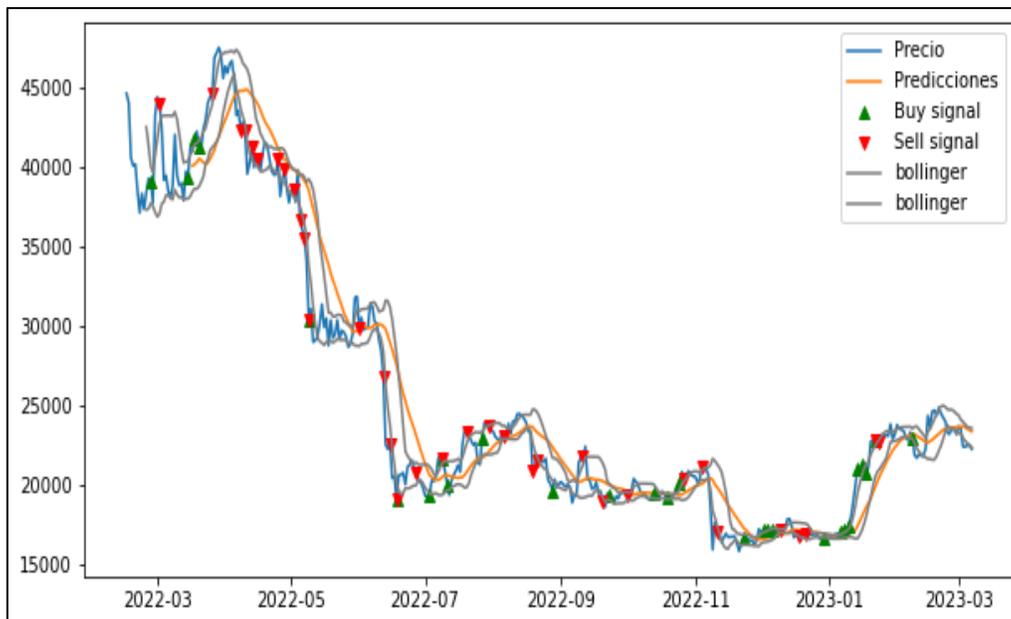
En este último cripto – robot radica **el valor añadido de nuestro trabajo de investigación**: conseguir un robot de *trading* que funcione con datos que tenga accesibles en todo momento de forma realista. Para ello, combinamos los indicadores técnicos tradicionales de la Bolsa (bandas de Bollinger, IFR, ADX...), con predicciones realizadas por la inteligencia artificial.

El **inconveniente del robot de *Machine Learning* anterior** es que al realizar la predicción el modelo ya tiene todos los datos de precios futuros del periodo de análisis, lo cual reduce el valor de su precisión. Asimismo, recordamos que el modelo de regresión ‘PRG’ empleó variables macroeconómicas como la inflación o el *money supply* (M2) de EEUU para sus predicciones, lo cual es poco operativo si quisiéramos trabajar con él de forma real en el mercado. Aunque estos datos sean públicos, para la efectividad del robot es preferible trabajar con los que puede acceder en el momento.

Este **robot de conjugación avanzada y tradicional** tomará las funciones y señales de compra y venta de nuestro robot de análisis técnico (explicado *supra*), así como la predicción del precio del día siguiente a través de un Proceso de Regresión Gaussiana. **El modelo de regresión solo toma en consideración los precios de cierre de Bitcoin de los 20 días anteriores**. Por tanto, nos dará una predicción cada día en base a los últimos 20 datos registrados, dato accesible de forma inmediata para un robot operando en la Bolsa.

De esta forma, combinamos las ventajas de un *trader* profesional con los modelos de inteligencia artificial avanzados del mercado. Estos fueron los resultados:

Ilustración 20: señales de compra y venta cripto – robot de inteligencia artificial y análisis técnico



Fuente: elaboración propia en Python

La línea azul representa el precio de Bitcoin en el periodo, la línea naranja cada una de las predicciones y las líneas grises representan las bandas de Bollinger que se utilizan como señales de stopcompra y stopventa. Observamos que la primera predicción no puede empezar en el día uno porque el robot necesita los datos de los últimos 20 días para generar la predicción del día siguiente.

El capital final del robot fue de 2.483.690,09: rentabilidad del 24.836%

4.5 Métricas de comparación

ROBOTS	Análisis técnico	Curve - fitting	Machine Learning	Combinación avanzada
Beneficio	66,96%	92,54%	124%	24.836%
Rendimiento medio de cada operación	6,08%	30,85%	0,8%	400%
Número de operaciones	11	3	155	62
Ratio de Sharpe	20,39	28,55	38,67	7.686,44

El **Ratio de Sharpe** mide la rentabilidad de la inversión ajustada según su riesgo. Para su cálculo, tomamos la rentabilidad de la inversión y restamos la rentabilidad del activo libre de riesgo (en EEUU, el rendimiento del Bono del Tesoro a 10 años), y dividimos por el riesgo del activo. Un ratio de Sharpe por encima de 1 significa que la inversión ofrece más rentabilidad que la volatilidad de su activo. Cuanto más arriesgada sea la inversión, mayor será la rentabilidad requerida, por lo que la ratio resulta especialmente útil a la hora de comparar las inversiones con distintos niveles de riesgo (Sevilla Arias, 2023). En nuestro caso, con esta métrica podemos comprobar cuánta rentabilidad adicional ha logrado cada cripto – robot por unidad de riesgo. Para calcular el **riesgo de Bitcoin** en el periodo tomamos la desviación típica de su rentabilidad diaria media, registrando un resultado del 3,14%.

CAPÍTULO 5. CONCLUSIONES Y PRÓXIMAS LÍNEAS DE INVESTIGACIÓN

Existe una cantidad extensa de trabajos de investigación dedicados a la **selección de las variables** más significativas de los precios de Bitcoin. El Bitcoin es un valor especulativo muy atractivo debido a su alta volatilidad y la pandemia marcó un antes y un después en el mercado, siendo este punto de partida fundamental para nuestro estudio. El informe del Fondo Monetario Internacional de enero de 2022 demostró que la correlación entre la Bolsa tradicional de Estados Unidos y el Bitcoin había aumentado de un 0,01 a un 0,36 entre el periodo previo a la pandemia y los años 2020-2021. Gestoras de fondos, inversores minoristas e instituciones públicas comenzaron a invertir en la criptomoneda y han convertido el análisis de su precio en una materia fundamental para salvaguardar la estabilidad financiera global. Nuestra hipótesis inicial era que la correlación entre Bitcoin y los mercados financieros había aumentado respecto a los resultados del FMI debido al cuadro macroeconómico sin precedentes que hemos experimentado de 2022 a 2023, y los resultados obtenidos demuestran que era cierta. Variables significativas de estudios anteriores como el *hash rate* o la *mining difficulty* han cedido el paso a la inflación general, la oferta de dinero o los bonos del Tesoro de Estados Unidos. Operadores privados y públicos del mercado financiero deberán tomar en cuenta nuestras conclusiones para la gestión de las carteras de activos y la regulación del mercado.

La **literatura previa** relativa a los modelos de predicción del precio de Bitcoin y su empleo en robots de *trading* cuantitativo tiene un enfoque comparativo. Los autores demuestran las diferencias entre distintos modelos de regresión, de clasificación, o entre modelos estadísticos y modelos de inteligencia artificial. Sin embargo, no hemos encontrado ningún estudio que combine en el mismo *robot* de trading el análisis técnico tradicional con la predicción del precio Bitcoin de acuerdo a un modelo de *Machine Learning*. Después de programar en Python tres cripto – robots con distintas aproximaciones (análisis técnico, ajuste de curvas, e inteligencia artificial), hemos creado un cripto – robot apto para operaciones reales en el mercado que combina las dos direcciones anteriores.

El entrenamiento de 24 modelos de regresión con optimización bayesiana de hiperparámetros en *Machine Learning* concluyó que el **Proceso de Regresión Gaussiana** era el óptimo para la predicción de los precios de Bitcoin y nuestro robot de *trading*. En vez de seleccionar las variables más relevantes de acuerdo al *feature selection* realizado – enfoque que tomamos en el “robot de *Machine Learning*” – ejecutamos el modelo a partir de los **últimos 20 precios de cierre del mercado**. Las predicciones para este intervalo son extraordinarias y se calculan de forma diaria conforme a los 20 precios anteriores. Las señales de compra y venta vienen determinadas por la predicción del modelo para el precio del día siguiente y la estrategia de inversión conforme a los indicadores técnicos explicada. Los sistemas de *trading* automático se han convertido en la alternativa más importante respecto a la inversión tradicional debido a su automatización, rapidez y ausencia de sentimiento. Esta es la razón por la que incorporamos a nuestro último robot una sola variable que es accesible de forma inmediata para la predicción; los precios históricos.

Para la búsqueda de los mejores modelos de regresión y clasificación se tuvieron en cuenta las variables más significativas de acuerdo a nuestro proceso de *feature selection* (*f_regression* y *mutual information*). No obstante, también decidimos entrenar los modelos sin una previa selección de variables para comprobar su relevancia en el análisis cuantitativo del proceso y obedecer al proceso de feature selection de Matlab. Destacó el algoritmo de Mínima Redundancia y Máxima Relevancia (MRMR) y sus 6 variables más significativas para el mejor modelo de regresión, el Proceso de Regresión Gaussiana (PRG).

El cripto – robot que combinó la inteligencia artificial con el análisis técnico fue el que mejor se comportó en nuestro estudio. Alcanzó una rentabilidad del 24.800% y un rendimiento medio por operación del 400% para nuestro periodo de análisis (8 de marzo de 2022 – 8 de marzo de 2023). Los resultados vienen motivados por la precisión del modelo ‘PRG’ combinada con el análisis técnico del mercado. En la sección de *Machine Learning* (Capítulo 3), el Proceso de Regresión Gaussiana registró un nivel de predicción del 99% y obtuvo el menor error RMSE (765,74) de entre todos los modelos de regresión de Matlab.

El **cripto – robot basado solo en las predicciones del Proceso de Regresión Gaussiana** registró una rentabilidad del 124%. Empleó las 6 variables más significativas de acuerdo al algoritmo MRMR: el Precio de Bitcoin el día anterior, *US 10 Year Bond Yield*, USD/EUR, *Money Supply*, NASDAQ y *VIX Index*. La limitación de este modelo es su riesgo de sobre – optimización. Esto implica que su precisión del 99% y la rentabilidad del robot pueden no replicarse si fueran trasladados a otro momento del mercado.

El **cripto – robot de *curve – fitting*** logró una rentabilidad del 92,54% operando con las predicciones de una función Fourier de grado 7. La función obtuvo un R cuadrado ajustado de 0,9703 y un RMSE de 1434. Fue escogida por su óptimo ajuste y el comportamiento transversal en los extremos. Las señales del robot fueron programadas de acuerdo a la predicción del siguiente intervalo y el uso de bandas de fluctuación alrededor del precio con la desviación típica de las predicciones; simulando el empleo de unas bandas de Bollinger. Como inconveniente del robot señalar que existe un riesgo de sobre – ajuste que daría lugar a predicciones deficientes en otro periodo de estudio.

El **cripto – robot de análisis técnico** operó conforme a una estrategia de inversión en Bolsa tradicional. Empleó una media móvil de 10 periodos, el valor 25 de la línea ADX, el valor 50 del IFR, y el oscilador estocástico junto con el cruce de las líneas D y K de 14 periodos. Fue el robot de menor rentabilidad (66,96%) pero tiene menor riesgo de *overfitting* que los dos anteriores. Sería preciso analizar su rentabilidad en otro periodo con el fin de evaluar la fiabilidad de su estrategia.

Los **modelos de clasificación** entrenados en *Machine Learning* no ofrecieron grandes resultados de predicción y decidimos no incorporarlos a nuestros robots de *trading*. El mejor modelo de clasificación fue una Red Neuronal Artificial que obtuvo un índice de precisión del 60%. Empleó las 6 variables más significativas del *mutual information*, todas ellas representativas de las variables económicas discutidas en el Capítulo 3.

En definitiva, las **limitaciones** de este estudio se basan en el riesgo de sobre – optimización en nuestro periodo de análisis y el riesgo de inversión/desinversión total en cada operación del robot de *trading*. Debemos ejecutar nuestros cripto – robots en los próximos meses para observar su comportamiento en intervalos de tiempo futuros y clasificar las señales de entrada y salida del mercado de acuerdo a la fiabilidad de la operación.

Nuestra próxima línea de investigación se divide en dos direcciones: en primer lugar, la creación de un robot de *trading* basado en aprendizaje por refuerzo que incorpore como señal de entrada nuestro modelo tradicional y de inteligencia artificial. Por último, el análisis cuantitativo de Bitcoin en relación con otras clases de activos (renta variable, fija y divisas) para la gestión de una cartera.

Bibliografía

Admirals. (24 de febrero, 2023). ¿Conoces el índice VIX? Qué es y cómo operar con él en 2023. *Admiral Markets*. <https://admiralmarkets.com/es/education/articles/trading-instruments/indice-vix-1>

Abul Basher, S. y Sadorsky P. (2022). Forecasting Bitcoin price direction with random forests: How important are interest rates, inflation, and market volatility?. *Machine Learning with Applications*, 9, 1-19. <https://linkinghub.elsevier.com/retrieve/pii/S266682702200055X>

Aysel, Ü. y Santur, Y. (2022). A new moving average approach to predict the direction of stock movements in algorithmic trading. *Journal of New Results in Science*, 11(1), 13-25. <https://doi.org/10.54187/jnrs.979836>

Bahrammirzaee, A. (2010). A Comparative Survey of Artificial Intelligence Applications in Finance: Artificial Neural Networks, Expert System and Hybrid Intelligent Systems. *International Journal of Neural Computing and Application*, 19, 1165-1195. https://www.researchgate.net/publication/201829144_A_Comparative_Survey_of_Artificial_Intelligence_Applications_in_Finance_Artificial_Neural_Networks_Expert_System_and_Hybrid_Intelligent_Systems

Board of Governors of the Federal Reserve System (US). (s.f.). Federal Funds Effective Rate [FEDFUNDS] [Dataset]. <https://fred.stlouisfed.org/series/FEDFUNDS>

Board of Governors of the Federal Reserve System (US). (s.f.). M2 [M2SL][Dataset]. <https://fred.stlouisfed.org/series/M2SL>

Brownlee, J. (2020). How to Perform Feature Selection for Regression Data. *Data Preparation*. <https://machinelearningmastery.com/feature-selection-for-regression-data/>

Carbó Valverde, S. y Rodríguez Fernández, F. (2022). The financial risks posed by inflation. *SEFO, Spanish and International Economic & Financial Outlook*, 11, 4. <https://www.funcas.es/articulos/the-financial-risks-posed-by-inflation/>

Cardona, C. y Velásquez, J. (2006). Selección de características relevantes usando información mutua. *Dyna*, 73, 149. Universidad Nacional de Colombia Sede Medellín. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0012-73532006000200013

Celasun, O., Milesi – Ferretti, G.M., Obstfeld, M. (28 de diciembre, 2018). Cinco gráficos que explican la economía mundial en 2018. IMF. Blog. <https://www.imf.org/es/Blogs/Articles/2018/12/20/blog122018-5-charts-that-explain-the-global-economy-in-2018>

Deane, S. y Fines, O. (2023). Cryptoassets: Beyond the Hype. An Investment Management Perspective on the Development of Digital Finance. *CFA Institute*. <https://www.cfainstitute.org/en/research/industry-research/cryptoassets-beyond-the-hype>

Cadenas, J.F. (2023). Las claves de la quiebra del Silicon Valley Bank y por qué todo empezó con la subida de tipos. *Newtral*. <https://www.newtral.es/silicon-valley-bank/20230313/>

Caro Mora, C. (2023). ¿Qué es FOMC? ¿Qué pasa cuando la Fed sube los tipos? *Admiral Markets*. <https://admiralmarkets.com/es/education/articles/forex-strategy/fed-tipos>

Chen, J. (2023). Analysis of Bitcoin Price Prediction Using Machine Learning. *Journal of Risk and Financial Management*, 16-51. <https://doi.org/10.3390/jrfm16010051>

Cortés, J., & Hernández, J. (2021). *Eficiencia del Mercado de Criptomonedas y Planteamiento de Estrategias de Trading basadas en Arbitraje y Machine Learning* [Trabajo Fin de Grado, Universidad de los Andes]. Repositorio Uniandes. <https://repositorio.uniandes.edu.co/handle/1992/57722>.

Cota, I. (2022). La caída del bitcoin representa un ‘golpe mortal’ para El Salvador. *El País*. <https://elpais.com/mexico/2022-11-13/caida-de-bitcoin-es-golpe-mortal-para-el-salvador.html>

De la Cruz, I. (7 de octubre, 2021). Cómo afectan los tipos de interés a los mercados. *Ismael de la Cruz*. <https://www.ismaeldelacruzfinanzas.com/como-afectan-los-tipos-de-interes-a-los-mercados/>

Enciclopedia Jurídica. (s.f.). Tracto Sucesivo. En *Enciclopedia Jurídica*. Recuperado el 29 de marzo de 2023, de <http://www.encyclopedia-juridica.com/d/tracto-sucesivo/tracto-sucesivo.htm>

Expansión. (s.f.). Estados Unidos - Tipos de interés. Recuperado el 29 de marzo de 2023, de <https://datosmacro.expansion.com/tipo-interes/usa>

Faghih Mohammadi Jalali, M., Heidari, H. (2020). Predicting changes in Bitcoin price using grey system theory. *Financial Innovation* 6, 13. <https://doi.org/10.1186/s40854-020-0174-9>

Fang, F., Ventre, C., Basios, M. et al. (2022). Cryptocurrency trading: a comprehensive survey. *Financial Innovation*, 8, 13. <https://doi.org/10.1186/s40854-021-00321-6>

Farràs, C. y García-Arenas, J. (2018). Expectations, inflation and financial markets: an exciting trinomial full of surprises”. *CaixaBank Research*.

Fantazzini, D. y Kolodin, N. (2020) Does the Hashrate Affect the Bitcoin Price? *J. Risk Financial Manag*, 13, 263. <https://doi.org/10.3390/jrfm13110263>

Federal Reserve Bank of Cleveland. (s.f.). 10-Year Real Interest Rate [REAINTRATREARAT10Y] [Dataset].
<https://fred.stlouisfed.org/series/REAINTRATREARAT10Y>.

Fondo Monetario Internacional. (2022). *Cryptic Connections: Spillovers between Crypto and Equity Markets*. <https://www.imf.org/en/Publications/global-financial-stability-notes/Issues/2022/01/10/Cryptic-Connections-511776>

Gabin, L. (2021). Del "paciente cero" hasta la caída del gigante que marcó a Wall Street. *El Economista*. <https://eleconomista.com.ar/aniversario-70/del-paciente-cero-caida-gigante-marco-wall-street-n44682>

García, I., Trigo, L., Costanzo, S. y Horst, E. (2017). Procesos gaussianos en la predicción de las fluctuaciones de la economía mexicana. *El trimestre económico*, 77, n° 307, 585-602. <https://doi.org/10.20430/ete.v77i307.447>

Gerritsen, D., Bouri, E., Ramezanifar, E., Roubaud, D. (2020). The profitability of technical trading rules in the Bitcoin market. *Finance Research Letters*, 34, 1-10. <https://www.sciencedirect.com/science/article/pii/S1544612319303770>

Goczek, L. y Skliarov, I. (2019). What drives the Bitcoin price? A factor augmented error correction mechanism investigation, *Applied Economics*, 51(1), 1-18. https://www.researchgate.net/publication/333301750_What_drives_the_Bitcoin_price_A_factor_augmented_error_correction_mechanism_investigation

Google Trends. (2023). *Bitcoin*. <https://trends.google.com/trends/explore?q=bitcoin>

Gradojevic, N., Kukulj, D., Adcock, R. y Djakovic, V. (2023). Forecasting Bitcoin with technical analysis: A not-so-random forest?. *International Journal of Forecasting*, 39, 1, 1-17. <https://doi.org/10.1016/j.ijforecast.2021.08.001>

Gualtero Espitia, L. (2022). Diseño de un robot de trading que involucra técnicas de machine learning aplicadas al mercado de las criptomonedas. Universidad de los Andes. Repositorio Uniandes. <https://repositorio.uniandes.edu.co/handle/1992/63682>

Guruswami, V. & Zuckerman, D. (2016). Robust Fourier and Polynomial Curve Fitting. *2016 IEEE 57th Annual Symposium on Foundations of Computer Science (FOCS)*, 751-759. https://ieeexplore.ieee.org/abstract/document/7782990?casa_token=JPYx2F8ZgRcAAAAA:9ujAsiPcB1J_YQPEyNsT2cjfPH2KXr6diGm4pZG3LEfxp4XunxxrzV3_vCPLRfu7V8-2LYjf-A

Koranyi, B. (2023). Sticky inflation fuels some of ECB's worst fears. *Investing*. <https://www.investing.com/news/economy/euro-zone-inflation-eases-in-february-but-core-prices-surge-3019925>

Johnson, S., Jin, A., & Keil, F. (2014). Simplicity and goodness-of-fit in explanation: The case of intuitive curve-fitting. *Proceedings of the Annual Meeting of the Cognitive Science Society*, 36, n° 36. <https://escholarship.org/content/qt4xg79414/qt4xg79414.pdf>

Kobiela, D., Krefta, D., Król, W. y Weichbrot, P. (2022). ARIMA vs LSTM on NASDAQ stock exchange data. *Procedia Computer Science*, 207, 3836-3845. <https://doi.org/10.1016/j.procs.2022.09.445>.

Kumar, V. y Minz, S. (2014). Feature Selection: A literature Review. *Smart Computing Review*, 4, n° 3. <https://faculty.cc.gatech.edu/~hic/CS7616/Papers/Kumar-Minz-2014.pdf>

Kumer Sarker, P. y Wang, L. (2022). Co-movement and Granger causality between Bitcoin and M2, inflation and economic policy uncertainty: Evidence from the U.K. and Japan. *Heliyon*, 8, 1-10. <https://doi.org/10.1016/j.heliyon.2022.e11178>

López, C. (24 de enero, 2023). ¿Qué es la inflación de segunda ronda? ¿Debería preocuparnos? *Euríbor*. <https://www.euribor.com.es/2023/01/24/que-es-la-inflacion-de-segunda-ronda-deberia-preocuparnos/>

Malafeyev, O., Al Manai, S., Zaitseva, I., Rubtsova, E., Bogolyubova, I., y Vysotsky, D. (2022). Comparative Analysis of Two Trading Robots. *2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*, pp. 188-192. <https://dergipark.org.tr/en/download/article-file/1912987>

Manjarrez, L. (2014). *Relaciones Neuronales Para Determinar la Atenuación del Valor de la Aceleración Máxima en Superficie de Sitios en Roca Para Zonas de Subducción* [Tesis doctoral, The University of Arizona]. ResearchGate. https://www.researchgate.net/publication/315762548_Relaciones_Neuronales_Para_Determinar_la_Atenuacion_del_Valor_de_la_Aceleracion_Maxima_en_Superficie_de_Sitios_en_Roca_Para_Zonas_de_Subduccion

Marmora, P. (2022). Does monetary policy fuel bitcoin demand? Event-study evidence from emerging market. *Journal of International Financial Markets, Institutions & Money*, 77, 1-16. <https://doi.org/10.1016/j.intfin.2021.101489>

Martín Meneses, A. (2021). *BLOCKCHAIN: Aplicación en el Registro de la Propiedad e implicaciones en materia probatoria* [Trabajo Fin de Grado, Universidad de la Laguna]. Riull.ull. <https://riull.ull.es/xmlui/bitstream/handle/915/24220/Blockchain%20aplicacion%20en%20el%20Registro%20de%20la%20Propiedad%20e%20implicaciones%20en%20materia%20probatoria.%20.pdf?sequence=1&isAllowed=y>

Mathworks. (2023). *App Regression Learner*. <https://es.mathworks.com/help/stats/regression-learner-app.html>

Mathworks. (2023). *Visualize and Assess Model Performance in Regression Learner*. <https://es.mathworks.com/help/stats/assess-model-performance-in-regression-learner.html>

Mathworks. (2023). *Bayesian Optimization Algorithm*.
<https://es.mathworks.com/help/stats/bayesian-optimization-algorithm.html>

Mathworks. (2023). *Desarrollo y evaluación de modelos*.
<https://es.mathworks.com/help/stats/classification-model-building-and-assessment.html>

Mathworks. (2023). *Classification Learner*.
<https://es.mathworks.com/help/stats/classificationlearner-app.html>

Mathworks. (2023). *Root-mean-square error between arrays*.
<https://es.mathworks.com/help/matlab/ref/rmse.html>

Mathworks. (2023). *Partition data for cross-validation*.
<https://es.mathworks.com/help/stats/cvpartition.html>

Mathworks. (2023). *Rank features for regression using minimum redundancy maximum relevance (MRMR) algorithm*. <https://es.mathworks.com/help/stats/fsrmrmr.html>

Mathworks. (2023). *Matriz de confusión de clasificación*.
https://es.mathworks.com/help/deeplearning/ref/confusion_es.html

Mathworks. (2023). *Regresión de procesos gaussianos*.
<https://es.mathworks.com/help/stats/gaussian-process-regression.html>

Mercado, D. Pedraza, L., Martínez, E. (2015). Comparison of Neural Network applied to prediction of times Series. *Prospect*, 13, n° 2, 88-95.
<http://www.scielo.org.co/pdf/prosp/v13n2/v13n2a11.pdf>

Merkaš, Z. y Roška, V. (2021). The Impact of Unsystematic Factors on Bitcoin Value, *Journal of Risk and Financial Management*, 14(11), 546. <https://doi.org/10.3390/jrfm14110546>

Misael, A. (2015). La Serie de Fourier: estimación de observaciones económicas inexistentes. *Economía Informa*, 394, 100-105. <https://www.elsevier.es/es-revista-economia-informa-114-articulo-la-serie-fourier-estimacion-observaciones-S0185084915000389>

Murphy, J.J. (1999). *Technical Analysis of the Financial Markets*. New York Institute of Finance.

Nasdaq Data Link. (2023). *Bitcoin Hash Rate* [Dataset]. <https://data.nasdaq.com/data/BCHAIN/HRATE-bitcoin-hash-rate>

Nasdaq Data Link. (2023). *Bitcoin Mining Difficulty* [Dataset]. <https://data.nasdaq.com/data/BCHAIN/DIFF-bitcoin-difficulty>

Pandey, S., Chavan, A., Paraskar, D., Deore, S. (2021). Bitcoin Price Prediction using Machine Learning. *International Research Journal of Engineering and Technology (IRJET)*, 8, 5. <https://www.irjet.net/archives/V8/i5/IRJET-V8I5381.pdf>

Pedregosa et al. (2011). Scikit-learn: Machine Learning in Python. *JMLR* 12, 2825-2830. https://scikit-learn.org/stable/auto_examples/feature_selection/plot_f_test_vs_mi.html#sphx-glr-auto-examples-feature-selection-plot-f-test-vs-mi-py

Pérez Ortiz, J.A. (2002). *Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto* [Tesis doctoral, Universidad de Alicante]. RUA. <https://rua.ua.es/dspace/bitstream/10045/3826/1/Perez-Ortiz-Juan-Antonio.pdf>

Pérez, S. (31 de diciembre, 2018). La Bolsa decepciona en 2018. *Expansión*. <https://www.expansion.com/mercados/2018/12/31/5c29fa84468aebd8108b4617.html>

Pinchuk, M. (2021). *Bitcoin Does Not Hedge Inflation*. <https://doi.org/10.48550/arXiv.2301.10117>

Reserva Federal de Estados Unidos. (2022). *Central Bank Digital Currency (CBDC)*. <https://www.federalreserve.gov/central-bank-digital-currency.htm>

Ruiz Dotras, E. (2022). ¿Qué tiene que ver la inflación con el desplome de las criptomonedas? *The Conversation*. <https://theconversation.com/que-tiene-que-ver-la-inflacion-con-el-desplome-de-las-criptomonedas-184021>

Sánchez, Á. (2023). Credit Suisse pedirá prestados hasta 50.000 millones al Banco Nacional de Suiza para fortalecer su liquidez. *El País*. <https://elpais.com/economia/2023-03-16/credit-suisse-pedira-prestados-hasta-50000-millones-al-banco-nacional-de-suiza-para-fortalecer-su-liquidez.html>

Sevilla Arias, A. (24 de febrero, 2023). Ratio de Sharpe. *Economipedia*. https://economipedia.com/definiciones/ratio-de-sharpe.html?nab=1&utm_referrer=https%3A%2F%2Fwww.google.com%2F

Siami-Namini, S., y Namin, A. S. (2018). Forecasting economics and financial time series: ARIMA vs. LSTM. *arXiv preprint arXiv:1803.06386*. <https://doi.org/10.48550/arXiv.1803.06386>

Smales, L.A. (2022). *Cryptocurrency as an alternative inflation hedge?*. <https://dx.doi.org/10.2139/ssrn.3883123>

Sotaquirá, M. (3 de septiembre, 2018). ¿Qué es una Red Neuronal?. *Codificandobits*.
<https://www.codificandobits.com/blog/que-es-una-red-neuronal/>

The Economist. (2022). 2022 has been a year of brutal inflation. *The Economist*.
<https://www.economist.com/finance-and-economics/2022/12/21/2022-has-been-a-year-of-brutal-inflation>

The Economist (2023). Inflation will be harder to bring down than markets think. *The Economist*.
<https://www.economist.com/leaders/2023/02/16/inflation-will-be-harder-to-bring-down-than-markets-think>

The Economist (2023). Lots of investors think inflation is under control. Not so fast. *The Economist*.
<https://www.economist.com/briefing/2023/02/16/lots-of-investors-think-inflation-is-under-control-not-so-fast>

UNIR Revista. (2021). ¿Qué son las redes neuronales? Concepto y usos principales. *Área de Ingeniería y Tecnología*.
<https://www.unir.net/ingenieria/revista/redes-neuronales-artificiales/>

Unipython. (7 de septiembre, 2021). Procesos gaussianos. *Unipython*.
<https://unipython.com/procesos-gaussianos/>

US Inflation Calculator. (2023). *Historical Inflation Rates: 1914-2023* [Dataset].
<https://www.usinflationcalculator.com/inflation/historical-inflation-rates/>

US Inflation Calculator. (2023). *United States Core Inflation Rates (1957-2023)* [Dataset].
<https://www.usinflationcalculator.com/inflation/united-states-core-inflation-rates/>

Uzonyi, N. (2021). *Predicción del precio de criptomonedas mediante Machine Learning y Redes Neuronales Profundas* [Trabajo fin de Máster, Universitat Politècnica de València]. Etsit.upv. <http://hdl.handle.net/10251/174491>

Yahoo Finance. (2023). *Bitcoin USD (BTC-USD)* [Dataset]. <https://es.finance.yahoo.com/quote/BTC-USD/history?p=BTC-USD>

Yahoo Finance. (2023). *S&P500 (^GSPC)* [Dataset]. <https://es.finance.yahoo.com/quote/%5Egspc/>

Yahoo Finance. (2023). *NASDAQ 100 (^NDX)* [Dataset]. <https://es.finance.yahoo.com/quote/^NDX?p=^NDX&.tsrc=fin-srch>

Yahoo Finance. (2023). *CBOE Volatility Index (^VIX)* [Dataset]. <https://es.finance.yahoo.com/quote/^VIX?p=^VIX&.tsrc=fin-srch>

Yahoo Finance. (2023). *Treasury Yield 10 Years (^TNX)* [Dataset]. <https://finance.yahoo.com/quote/%5ETNX?p=%5ETNX>

Yahoo Finance. (2023). *USD/EUR (EUR=X)* [Dataset]. <https://finance.yahoo.com/quote/EUR=X?p=EUR=X&.tsrc=fin-srch>

Zhang, W., Wang, L., Xie, L., Feng, K., Liu, X. (2022). Bandit learning for hyper-parameters optimization of high frequency trading strategy. *Pattern Recognition*, 124. <https://www.sciencedirect.com/science/article/pii/S003132032100666X>

Zhang, X., Quin, R., Yuan, Y., Wang, F-Y. (2018). An Analysis of Blockchain-based Bitcoin Mining Difficulty: Techniques and Principles. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8623140&tag=1>

Zhi, J., Huang, W., & Ni, J. (2019). Predicting bitcoin returns using high-dimensional technical indicators. *The Journal of Finance and Data Science*, 5, 140-155. <https://doi.org/10.1016/j.jfds.2018.10.001>.

Índice de Ilustraciones

ILUSTRACIÓN 1: CRUCE DE MEDIAS MÓVILES EN UN INTERVALO DE 4 HORAS EN BITCOIN.....	25
ILUSTRACIÓN 1: CRUCE DE MEDIAS MÓVILES EN UN INTERVALO DE 4 HORAS EN BITCOIN.....	23
ILUSTRACIÓN 2: BANDAS DE BOLLINGER EN UN INTERVALO DE 4 HORAS EN BITCOIN.....	26
ILUSTRACIÓN 2: BANDAS DE BOLLINGER EN UN INTERVALO DE 4 HORAS EN BITCOIN.....	24
ILUSTRACIÓN 3: IFR DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN	30
ILUSTRACIÓN 3: IFR DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN	28
ILUSTRACIÓN 4: COMPARACIÓN IFR Y OSCILADOR ESTOCÁSTICO DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN.....	32
ILUSTRACIÓN 4: COMPARACIÓN IFR Y OSCILADOR ESTOCÁSTICO DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN.....	30
ILUSTRACIÓN 5: COMPARACIÓN SEÑAL 10 DE FEBRERO DE 2023 OSCILADOR ESTOCÁSTICO E IFR DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN.....	32
ILUSTRACIÓN 5: COMPARACIÓN SEÑAL 10 DE FEBRERO DE 2023 OSCILADOR ESTOCÁSTICO E IFR DE 14 DÍAS EN GRÁFICO DIARIO DE BITCOIN.....	30
ILUSTRACIÓN 6: INDICADORES ADX Y DMI DE 14 PERIODOS EN GRÁFICO DIARIO DE BITCOIN.....	34
ILUSTRACIÓN 6: INDICADORES ADX Y DMI DE 14 PERIODOS EN GRÁFICO DIARIO DE BITCOIN.....	32
ILUSTRACIÓN 7: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN POLINÓMICA DE GRADO 2.....	38
ILUSTRACIÓN 7: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN POLINÓMICA DE GRADO 2.....	38
ILUSTRACIÓN 8: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN GAUSSIANA DE GRADO 8.....	39
ILUSTRACIÓN 8: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN GAUSSIANA DE GRADO 8.....	39
ILUSTRACIÓN 9: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN FOURIER DE GRADO 7.....	40
ILUSTRACIÓN 9: CURVE – FITTING EN NUESTRO PERIODO DE ANÁLISIS CON UNA FUNCIÓN FOURIER DE GRADO 7.....	40
ILUSTRACIÓN 10: PRECIOS SP500 2022 Y FECHAS EN LOS QUE LA FED ANUNCIÓ LA SUBIDA DE TIPOS DE INTERÉS.....	42
ILUSTRACIÓN 10: PRECIOS SP500 2022 Y FECHAS EN LOS QUE LA FED ANUNCIÓ LA SUBIDA DE TIPOS DE INTERÉS.....	43
ILUSTRACIÓN 11: CORRELACIONES DE VOLATILIDAD Y RETORNO ENTRE CRIPTOMONEDAS Y EL MERCADO DE RENTA VARIABLE COMPARANDO LOS PERIODOS DE ANÁLISIS PREPANDEMIA Y POSTPANDEMIA (FONDO MONETARIO INTERNACIONAL)	45
ILUSTRACIÓN 11: CORRELACIONES DE VOLATILIDAD Y RETORNO ENTRE CRIPTOMONEDAS Y EL MERCADO DE RENTA VARIABLE COMPARANDO LOS PERIODOS DE ANÁLISIS PREPANDEMIA Y POSTPANDEMIA (FONDO MONETARIO INTERNACIONAL)	46
ILUSTRACIÓN 12: EVOLUCIÓN 2017 – 2021 DE LA CORRELACIÓN ENTRE LOS PRECIOS Y RETORNOS DE BITCOIN Y EL SP500.....	46
ILUSTRACIÓN 12: EVOLUCIÓN 2017 – 2021 DE LA CORRELACIÓN ENTRE LOS PRECIOS Y RETORNOS DE BITCOIN Y EL SP500.....	47
ILUSTRACIÓN 13: VARIABLES SIGNIFICATIVAS MUTUAL INFORMATION.....	51
ILUSTRACIÓN 13: VARIABLES SIGNIFICATIVAS MUTUAL INFORMATION.....	52
ILUSTRACIÓN 14: VARIABLES SIGNIFICATIVAS F-TEST	51
ILUSTRACIÓN 14: VARIABLES SIGNIFICATIVAS F-TEST	52
ILUSTRACIÓN 15: RESULTADOS DEL MEJOR MODELO DE REGRESIÓN, PROCESO DE REGRESIÓN GAUSSIANA	57
ILUSTRACIÓN 15: RESULTADOS DEL MEJOR MODELO DE REGRESIÓN, PROCESO DE REGRESIÓN GAUSSIANA	58
ILUSTRACIÓN 16: MATRIZ DE CONFUSIÓN DEL MEJOR MODELO DE CLASIFICACIÓN, RED NEURONAL.....	59
ILUSTRACIÓN 16: MATRIZ DE CONFUSIÓN DEL MEJOR MODELO DE CLASIFICACIÓN, RED NEURONAL.....	60
ILUSTRACIÓN 17: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE ANÁLISIS TÉCNICO	64
ILUSTRACIÓN 17: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE ANÁLISIS TÉCNICO	64
ILUSTRACIÓN 18: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE CURVE - FITTING	65
ILUSTRACIÓN 18: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE CURVE - FITTING	65
ILUSTRACIÓN 19: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE MACHINE LEARNING	66
ILUSTRACIÓN 19: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT DE MACHINE LEARNING	66
ILUSTRACIÓN 20: SEÑALES DE COMPRA Y VENTA CRIPTO - ROBOT BASADO EN LA PREDICCIÓN DE MACHINE LEARNING Y ANÁLISIS TÉCNICO	68