

---

*INTELIGENCIA ARTIFICIAL  
APLICADA A DECISIONES  
FINANCIERAS EN EL  
CRIPTOMERCADO*

---

TRABAJO DE FIN DE GRADO

Alejandro Salgado Martín



UNIVERSIDAD COMPLUTENSE  
MADRID

Trabajo de fin de grado de Ingeniería del Software, Facultad de  
Informática, Universidad Complutense de Madrid.

Profesor director: Iván García-Magariño.

Autor: Alejandro Salgado Martín.

Título: *Inteligencia artificial aplicada a decisiones financieras en el  
criptomercado.*

Madrid, 2019–2020

---

# *ARTIFICIAL INTELLIGENCE APPLIED TO FINANCIAL DECISIONS IN THE CRYPTOCURRENCY MARKET*

---

## **PALABRAS CLAVE:**

- Criptomoneda
- Bitcoin
- Decisiones financieras
- Inteligencia Artificial
- Blockchain

## **KEYWORDS:**

- Cryptocurrency
- Bitcoin
- Financial decisions
- Artificial Intelligence
- Blockchain

## **AGRADECIMIENTOS:**

Quiero agradecer a mi familia por darme la posibilidad de estudiar este magnífico grado, a Iván por su valiosa ayuda en este trabajo, a los profesores de la facultad por su profesionalidad, y finalmente, quiero agradecer a mis compañeros y directores de los servicios informáticos de la universidad, con los que he compartido las agradables mañanas de estos dos últimos años, desde el edificio multiusos, el centro de proceso de datos, y el jardín botánico.

Muchas gracias a todos.

# Índice:

<b>Resumen:</b> .....	- 4 -
<b>1) Introducción:</b> .....	- 5 -
1.1) Por qué hemos elegido Bitcoin: .....	- 5 -
1.2) Antecedentes: .....	- 8 -
Trabajos similares de dominio público en nuestra comunidad universitaria:.....	- 8 -
1.3) Motivación: .....	- 10 -
1.4) Objetivos: .....	- 10 -
<b>2) Estado del arte sobre artículos científicos existentes:</b> .....	- 11 -
<b>3) Desarrollo y tecnologías de nuestra aplicación:</b> .....	- 12 -
3.1) Esquema conceptual de la aplicación:.....	- 13 -
3.2) Diagrama de arquitectura: .....	- 14 -
3.3) Casos de uso:.....	- 15 -
3.4) Diagramas de actividades:.....	- 16 -
3.5) Diagramas de secuencia: .....	- 19 -
3.6) Base de datos:.....	- 24 -
3.7) Notas y enlaces a la web: .....	- 25 -
<b>4) Explicación detallada de la aplicación.....</b>	- 26 -
4.1) Las estrategias de inversión propuestas: .....	- 26 -
Los cinco indicadores:.....	- 27 -
Compra a largo plazo: .....	- 32 -
Compra a corto plazo: .....	- 32 -
Venta a corto plazo:.....	- 33 -
Venta rápida: .....	- 33 -
4.2) Explicación detallada de los dos modelos de inteligencia artificial desarrollados..	- 34 -
Preprocesador de datos:.....	- 34 -
Algoritmo de clasificación: K-NN. ....	- 35 -
Algoritmo de predicción: red neuronal. ....	- 40 -
4.3) El simulador de inversión.....	- 43 -
4.4) El análisis técnico y las noticias económicas:.....	- 44 -
<b>5) Conclusión y trabajo futuro:</b> .....	- 45 -
<b>Referencias Bibliográficas:</b> .....	- 47 -

## Índice de figuras:

1. Número de direcciones con valor diferente a 0 bitcoin. . . . .	6
2. Bitcoin/Euro y volumen en Coinbase. . . . .	7
3. Información en Google Trends sobre “bitcoin halving”. . . . .	7
4. Trabajos de nuestra universidad relacionados con la criptomoneda. . . . .	8
5. Información en Google Trends sobre “cryptocurrency”. . . . .	9
6. Indicador de volatilidad mensual y la media de los últimos seis meses. . . . .	27
7. Indicador RSI en base a 9 meses. . . . .	29
8. Indicador de la diferencia porcentual entre precio y media móvil. . . . .	30
9. Indicador de porcentaje de beneficio/perdida no realizado en la red. . . . .	31
10. Código del preprocesador de datos. . . . .	34
11. Datos históricos en el archivo CSV. . . . .	35
12. Diferentes soluciones según el valor de K en el algoritmo K-NN. . . . .	36
13. Código del bucle para deducir el mejor valor de k. . . . .	37
14. Gráfica de la precisión de los modelos de K-NN según el valor de k. . . . .	38
15. Código de la ejecución del modelo K-NN y las funciones de probabilidad. . .	39
16. Estructura de una red neuronal basada en una capa oculta de MLP. . . . .	40
17. Código del bucle que genera diez redes neuronales con 80% de precisión. . .	43
18. Código de la calculadora de beneficios y pérdidas en el mercado. . . . .	44

## Resumen:

*Inteligencia artificial aplicada a decisiones financieras en el criptomercado* es un proyecto que está implementado en forma de página web\*.

Su misión es proporcionar herramientas de inteligencia artificial para ayudar a la toma de decisiones financieras en el mercado de la criptomoneda bitcoin.

Los usuarios de esta página web, además de servirse de estas herramientas de clasificación y predicción del mercado, tienen a su disposición valiosa información sobre el pasado, en cuanto al análisis técnico del precio, y también tienen disponible información de máxima actualidad, como son las consecuencias y el impacto del coronavirus covid-19 al criptomercado.

## **Abstract:**

*Artificial intelligence applied to financials decisions in cryptocurrency market* is a project that is implemented in a web page.

The mission is to give to the user artificial intelligence tools to help his financials decisions in the market of bitcoin.

Users of this web, besides of use this artificial intelligence tools of classification and price prediction, they can to examine usefull information about the TA (Tecnical Analisis) of the price, and the newest information about the covid-19 economic impact in cryptocurrency market.

## **1) Introducción:**

### **1.1) Por qué hemos elegido Bitcoin:**

Hemos escogido a la criptomoneda bitcoin como el elemento financiero sobre el que trabajamos por varias razones que explicamos a continuación.

Lo primero de todo, porque lo consideramos uno de los ejemplos prácticos más representativo que utiliza como base tecnológica el modelo de software de código abierto, y esto es, materia de interés general a cualquier ingeniero y desarrollador de software.

A parte del ámbito digital y tecnológico del proyecto bitcoin, también hemos escogido a esta criptomoneda por ser un tema que, aunque tiene más de diez años de vida, sigue despertando interés a nivel teórico, y cada vez son más las personas que están interesadas en esta red peer-to-peer, pues así lo indica el número creciente de direcciones (carteras) que aumenta progresivamente con el paso del tiempo [1]. También ha crecido recientemente el volumen de compra y de venta, y las búsquedas relacionadas con el halving en google. Al final de este apartado, mostramos estos datos.

Consideramos a bitcoin un elemento financiero que cada vez tiene más popularidad en la sociedad y nos consideramos de **los pioneros** en realizar un trabajo sobre este ámbito en nuestra comunidad universitaria.

Nuestro trabajo puede servir de gran utilidad a ingenieros y desarrolladores de software, empresas y particulares que estén interesados en el mundo de la inversión, y finalmente, a personas y estudiantes relacionados con la economía y finanzas.

En la figura 1, se puede observar como el número de direcciones con un valor diferente de 0 en bitcoin ha aumentado progresivamente desde 2011, representado con la línea amarilla. Ya son más de 25 millones. La línea gris representa el precio en escala logarítmica.

Bitcoin: Addresses with Non-Zero Balance

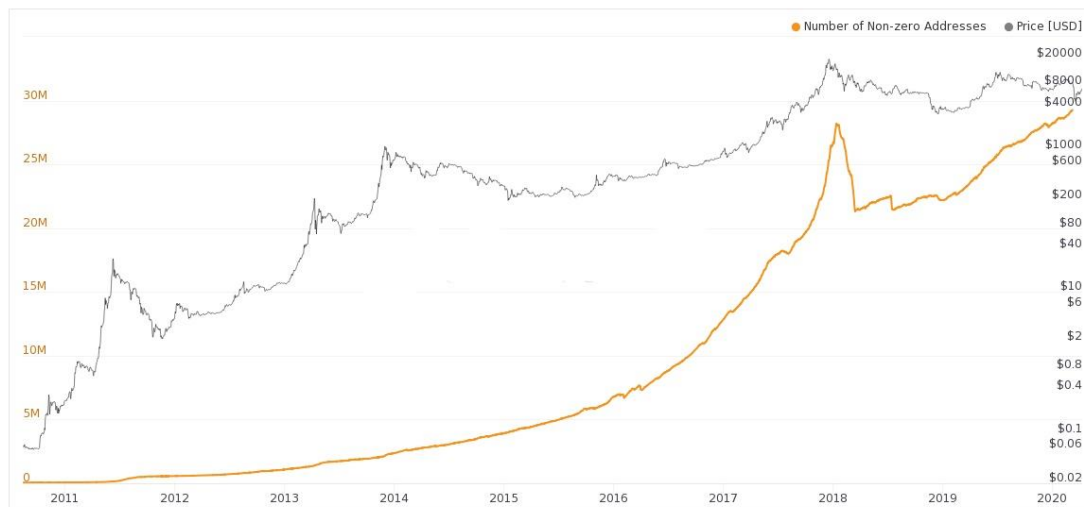


Figura 1: Número de direcciones con valor diferente a 0 bitcoin. Fuente: Glassnode [1]

Hacer este tipo de cálculos es posible gracias a que la blockchain de bitcoin (libro contable con los detalles de las transacciones entre direcciones) es pública y, por lo tanto, se pueden hacer estudios sobre ella [2].

Otro indicador que nos muestra que esta criptomoneda está siendo tendencia en el presente, como comentábamos anteriormente, es el aumento de volumen de operaciones de compra-venta. Esto ha ocurrido recientemente cuando el precio tocó los 5000€ por unidad, después de caer en picado por la crisis del coronavirus covid-19.

La siguiente imagen muestra la paridad Bitcoin/Euro como una línea azul en datos semanales en el mercado de Coinbase. Escogemos este mercado porque según estudios recientes [3], presenta los mayores niveles de liquidez. Las columnas verdes y rojas encima de las fechas, muestran el volumen de operaciones. Estas columnas están atravesadas por una línea amarilla que muestra la media de volumen en las últimas diez semanas.

En la figura 2, se puede ver cómo a finales de marzo de este año 2020, el volumen del mercado ha superado en dos semanas, los máximos previos de volumen de julio de 2019, y han estado muy cerca de superar al volumen máximo semanal que ocurrió a finales de 2017 que impulsaron a los máximos históricos del precio.



Figura 2: Bitcoin/Euro y volumen en Coinbase, imagen obtenida en TradingView [4]

Como comentábamos, cada vez el halving de bitcoin es más conocido en internet. Como podemos ver en la figura 3, queda confirmado que el pasado halving de mayo de 2020 es más conocido que el anterior de 2016:




Figura 3: Información en Google Trends sobre “bitcoin halving”.

## 1.2) Antecedentes:

Trabajos similares de domino público en nuestra comunidad universitaria:

Si hacemos una búsqueda de la palabra criptomoneda sobre los repositorios de los trabajos de fin de grado y trabajos de fin de master de nuestra universidad, observamos lo siguiente (Figura 4):

The screenshot shows the E-Prints Complutense website interface. At the top, the logo for 'SIDAD COMPLUTENSE MADRID' is on the left, and the text 'E-Prints Complutense' and 'El repositorio de la producción académica en abierto de' is on the right. Below this is a navigation bar with 'About', 'Collections', 'Browse', and 'Statistics'. A search bar is present on the right. The main content area displays 'Search results for criptomoneda'. It includes a status bar 'Displaying results 1 to 16 of 16.' with links for 'Refine search' and 'New search'. Below this is a dropdown menu for 'Order the results:' set to 'by relevance match' and a 'Reorder' button. There is also an 'Export' button and options for 'Export 16 results as' (set to 'ASCII Citation') and 'Export'. On the right side of the results area, there are icons for 'RSS 1.0', 'Atom', and 'RSS 2.0'. The search results are listed in a table with 7 entries, each showing a numbered list item, author names, year, title, and type of work (e.g., 'Trabajo Fin de Grado' or 'Trabajo Fin de Máster'). Each entry has a small thumbnail image of a document cover to its right.

Number	Author(s)	Year	Title	Type
1.	Pastor Cobo, Manuel and Torre Barrio, Pablo de	(2019)	Elaboración de un algoritmo predictivo sobre la evolución del precio de las criptomonedas.	[Trabajo Fin de Grado]
2.	Novales López-Medel, Alberto	(2018)	El modelo Bitcoin como fenómeno de destrucción creativa en la sociedad del siglo XXI.	[Trabajo Fin de Grado]
3.	Calvo María, Adrián and Jacynycz García, Viktor	(2015)	Desarrollo de una plataforma de crowdfunding distribuida sobre Ethereum.	[Trabajo Fin de Grado]
4.	Tamames Hergueta, Jaime and Pino Holgado, Sergio	(2019)	Plataforma para el fomento turístico basado en recompensas mediante tecnologías Blockchain.	[Trabajo Fin de Grado]
5.	Blanco Peris, Pablo	(2019)	Interacción de un Smart contract con una app móvil.	[Trabajo Fin de Máster]
6.	Barrios Palacios, Patricia	(2019)	Aplicación Android con integración blockchain en respuesta al acoso en espacios públicos.	[Trabajo Fin de Grado]
7.	Algovia García, Ángel	(2019)	Contratos Inteligentes sobre registros confiables de polución: una propuesta usando dispositivos IoT, entornos de ejecución seguro y oráculos blockchain.	[Trabajo Fin de Máster]

Figura 4: Trabajos de nuestra universidad relacionados con la criptomoneda.

Encontramos varios trabajos más específicos sobre aplicaciones blockchain en la facultad de Informática, un trabajo de la facultad de Economía: *El modelo bitcoin como el fenómeno de destrucción creativa en la sociedad del siglo XXI* y un trabajo del año pasado de nuestra facultad: *Elaboración de un algoritmo predictivo del precio de las criptomonedas*.

En nuestro trabajo presentamos **estrategias de inversión** que se basan en el análisis técnico del precio del bitcoin, y nos servimos de **modelos de inteligencia artificial** que hemos desarrollado, para clasificar el momento presente del mercado e intentar predecir el futuro. Por ello nos consideramos los pioneros en realizar un trabajo así.

En la siguiente figura 5, observamos en google trends el volumen de búsquedas del término “cryptocurrency”:




Figura 5: Información en Google Trends sobre “cryptocurrency”.

Observamos que el volumen de las búsquedas en general en todo el mundo han aumentado levemente en estos dos últimos años, si lo comparamos con el de antes de 2016.

El volumen máximo de búsquedas se encuentra a primeros de 2018, que coincide con los máximos en el precio del bitcoin, esto es 19000 \$ por unidad.

Pero recientemente, en el verano anterior en junio de 2019, el precio alcanzó los 13800\$ por unidad. Este evento no repercutió significativamente en el volumen de las búsquedas, pero puede que en un futuro vuelvan a producirse muchas más búsquedas, entonces aumentaría el interés en el mundo, y probablemente, el precio vuelva a los niveles de 13000\$-19000\$, si nuevas personas y empresas entran en el mercado.

Pase lo que pase en años futuros, aumente o disminuya el precio, aumente o disminuya el interés en el mundo, nuestras estrategias de inversión pueden generar beneficios en ambos casos.

Esto es posible ya que en los mercados con más volumen del mundo de compra y venta del bitcoin [5], como Binance y Bitfinex [6], se puede especular sobre el futuro precio del bitcoin y apostar en largo o en corto, es decir, abrir operaciones de compra o de venta. En conclusión, una persona dentro de estos mercados puede generar beneficios tanto si el precio llega a los 20000\$ como si cae hasta 0\$.

### 1.3) Motivación:

Vivimos en la era de la información, ahora mismo más de la mitad de todas las personas del mundo disponen de una conexión a internet. Y en un futuro, el crecimiento de usuarios de internet puede significar una mayor adopción de las criptomonedas en todo el mundo [\[7\]](#).

La motivación de la aplicación web y este documento, está en aportar a nuestra comunidad universitaria y a cualquier persona que pueda interactuar por internet con nuestra aplicación, una información muy valiosa orientada a la inversión en el mundo del criptomercado y el bitcoin.

Es un tema que, a día de hoy, afecta a todo nuestro continente y prácticamente a todo el mundo, ya que estamos en una situación, económicamente hablando, similar a la crisis del 2008 [\[8\]](#), consecuencia de la actual crisis sanitaria.

No se sabe a ciencia cierta, pero la anterior crisis global fue probablemente una de las razones que llevaron a la creación de una moneda digital descentralizada como bitcoin [\[9\]](#), que no depende del sistema bancario tradicional.

Desde 2008 hasta ahora, los pioneros en confiar en este nuevo sistema de valor han logrado la independencia financiera. Por ejemplo, personas que ahorraron 50 dólares mensuales en bitcoin desde 2012 hasta el presente, hoy tienen más de medio millón de dólares ahorrados [\[10\]](#). Y gente que hizo lo mismo desde 2016, ha triplicado ya el valor de sus ahorros [\[10\]](#).

En el pasado mes de mayo de 2020 se produjo el tercer halving [\[11\]](#) de la historia de la criptomoneda bitcoin. Ya se ha minado un 85% del total de las 21 millones de criptomonedas que existirán, y quedan 120 años para que se mine el 15% restante [\[12\]](#).

Las criptomonedas aún tienen un largo camino por recorrer, pero ya han representado una alternativa viable para el sistema bancario tradicional en tiempos de crisis como los actuales.

Con este trabajo de investigación, quiero aportar información veraz y contrastada sobre este interesante mercado.

### 1.4) Objetivos:

Como ya hemos comentado en el [resumen](#), nuestro objetivo es proporcionar al usuario de la aplicación herramientas de inteligencia artificial para ayudar a la toma de decisiones financieras en el mercado de la criptomoneda bitcoin.

Estas herramientas se enfocan en la clasificación del mercado en el momento presente y la predicción del precio en el futuro.

Queremos centrarnos en las personas que se están iniciando en el análisis técnico, y en el mundo de las criptomonedas con el fin de proporcionarles este trabajo para servirles de utilidad.

## **2) Estado del arte sobre artículos científicos existentes:**

Existen trabajos que han desarrollado elaborados modelos de predicción del precio futuro del bitcoin, con algoritmos basados en árboles de decisión con hasta 124 indicadores técnicos [\[13\]](#). Somos conscientes de que estos trabajos tienen modelos con más complejidad matemática que el nuestro que utiliza cinco y hasta siete indicadores técnicos como referencia. Nosotros no pretendemos superar en precisión o en innovación a estos modelos que ya están desarrollados.

Nuestra innovación reside en la manera en la que estudiamos el mercado;

Estudiamos el comportamiento del precio dividiendo los datos históricos en periodos de cuatro años, que son los cuatro años en los que los mineros tienen diferente cantidad de recompensa al minar un bloque. A estos 4 años los consideramos eras;

1º era; inicio del bitcoin hasta noviembre de 2012, se recompensaban 50 bitcoin por bloque minado.

2º era; desde noviembre 2012 hasta julio 2016, se recompensaban 25 bitcoin por bloque minado.

3º era; desde julio 2016 hasta mayo de 2020, se recompensaban 12.5 bitcoin por bloque minado.

4º era; desde mayo de 2020 hasta 2024, esta es la era actual, se recompensan 6.25 bitcoin por bloque minado.

Analizando el comportamiento del precio y los indicadores técnicos que hemos estudiado, presentamos un modelo totalmente válido que identifica mercados alcistas y bajistas en cada era. Seguimos el patrón que viene ocurriendo hasta ahora; una era comienza con un mercado alcista que sitúa el precio en un nuevo máximo histórico, después de esto se inicia el mercado bajista que finaliza en un periodo de acumulación y expansión del precio hasta comenzar la siguiente era. Este es el ciclo que se ha cumplido en las tres primeras eras y que explicamos con más detalles en el apartado [4.1](#)).

Es evidente que la mejor estrategia de inversión en las dos primeras eras ha sido la de B&H (Buy and Hold), es decir, comprar y retener, hasta que el precio subiese lo suficiente para posteriormente vender y recoger beneficios. Pero desde que se introdujo la posibilidad de invertir en corto, a principios de 2018, es importante conocer que desde esa fecha, existen inversores que pueden ganar dinero cuando el precio esté disminuyendo, como ocurrió en el famoso ‘crash’ del 2018-2019 en esta criptomoneda.

Existen artículos que afirman que la introducción del mercado de futuros (permitiendo invertir en corto) fue en cierta medida responsable de esto [14]. Entonces cabe la posibilidad de que el mencionado ‘crash’ realmente fuese un mercado bajista que trasladó el precio a una zona más razonable fuera de la sobrevaloración existente como mostraban los indicadores que hemos estudiado, lo que también refuerza la teoría del movimiento cíclico del precio, como hemos comentado anteriormente.

Por ello en nuestro trabajo proponemos estrategias tanto de compra como de venta y esto es una innovación, ya que anteriormente no se podía vender bitcoin si no lo poseías previamente. Esta nueva posibilidad de invertir en corto no ha sido perjudicial para el precio en el año anterior 2019-2020, ya que observamos un beneficio del 100% para los inversores en largo en este periodo de tiempo.

Otra innovación que presentamos, está en la propuesta de tres estrategias de inversión diseñadas para recoger el máximo de beneficio en seis meses o más. Es importante este marco temporal que nosotros planteamos, pues en otros trabajos similares [15], que investigan técnicas de trading con redes neuronales, hemos observado que los autores se encargan de encontrar señales para entrar en el mercado basándose en marcos temporales diarios. Nosotros, en cambio, nos centramos en resumir la información en meses y estudiar el comportamiento del precio en el mediano y largo plazo, pues consideramos que desarrollar modelos algorítmicos con datos del precio diario en una criptomoneda que es tan volátil, puede llevar a decisiones financieras poco concluyentes que se verían afectadas por movimientos bruscos en este volátil mercado. Por ello nosotros nos dedicamos a encontrar decisiones financieras que sean robustas, apoyadas en datos mensuales, indicadores técnicos y tendencias de mercado.

### **3) Desarrollo y tecnologías de nuestra aplicación:**

La aplicación web está íntegramente desarrollada y programada por el autor de este proyecto durante todo el curso 2019-2020. Utiliza el framework Express [16].

La parte del servidor web está implementada con la tecnología de Node.js [17], por lo tanto el lenguaje de programación del servidor es JavaScript.

La parte de los modelos de inteligencia artificial están realizados en Python, y usan un archivo con datos en formato CSV que se cargan con la librería Pandas [18]. Estos algoritmos que implementan la inteligencia artificial usan librerías de Scikit-learn [19].

El servidor web ejecuta el código en Python a través de la librería Python Shell [20].

La aplicación web usa su propia base de datos que está implementada en Mysql [21] y se conecta a ella a través de un pool de conexión.

La aplicación web se conecta a otras Apis de internet a través de la librería de Axios [22], exactamente a estas dos siguientes direcciones;

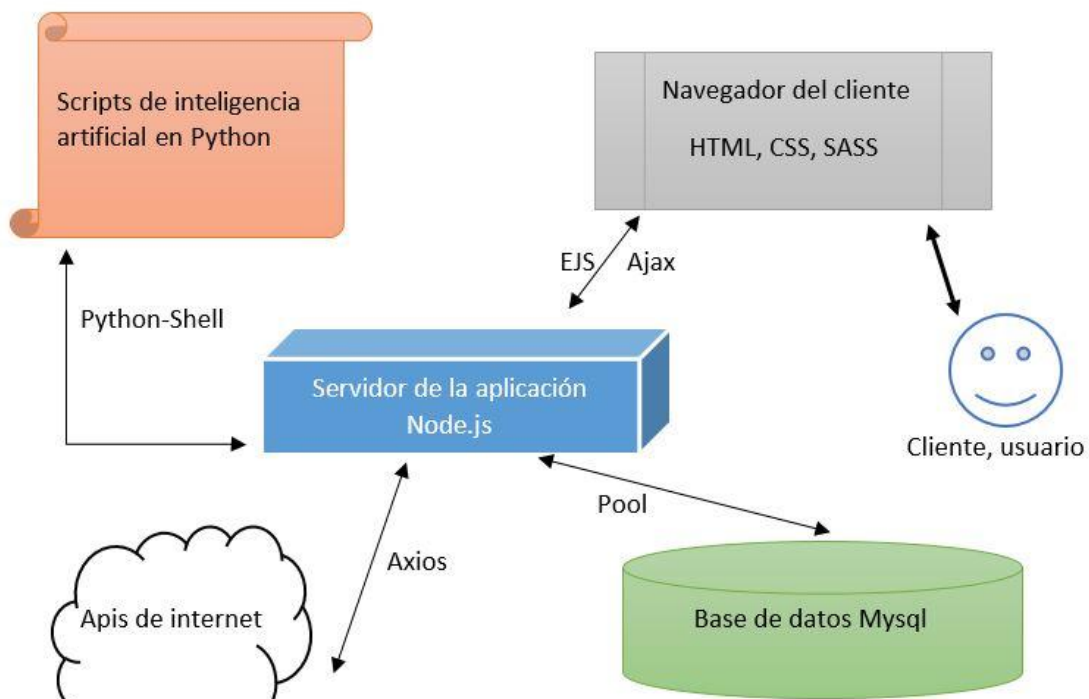
- 1) Para obtener el valor del **indicador beneficio/pérdidas no realizado de la red**:  
[https://api.glassnode.com/v1/metrics/indicators/net\\_unrealized\\_profit\\_loss](https://api.glassnode.com/v1/metrics/indicators/net_unrealized_profit_loss)
- 2) Para obtener en tiempo real el valor del precio del Bitcoin:  
<https://api.coindesk.com/v1/bpi/currentprice/USD.json>

En la parte del **simulador**, el cliente realiza llamadas de tipo AJAX [23] al servidor de la aplicación.

La interfaz web está compuesta de archivos HTML y plantillas de tipo Embedded JavaScript templating (EJS) [24] con su correspondientes diseños en CSS.

Algunas cuestiones de diseño como ciertas animaciones al cargar las páginas, se han incluido con la tecnología Syntactically Awesome Style Sheets (SASS) [25].

### 3.1) Esquema conceptual de la aplicación:



Esquema conceptual de la aplicación.

### 3.2) Diagrama de arquitectura:

La aplicación web se ejecuta sobre un PC con Windows 10 como sistema operativo. La base de datos Mysql se encuentra en el mismo ordenador, e interactúa con la aplicación a través de un pool de conexiones. Como hemos comentado anteriormente, la aplicación obtiene información de internet a través de la librería axios vía https.

Tenemos dos archivos que forman los scripts en python para implementar los modelos de inteligencia artificial; uno para la clasificación del mercado (knnimprove.py) y otro para la predicción (neuralpandas.py).

La interfaz de usuario la forman todos los archivos estáticos HTML y las plantillas EJS que recibe el cliente. Hemos añadido en el diagrama las más importantes. Los archivos de la interfaz de usuario utilizan los recursos convenientes, esto es; imágenes, estilos (css), animaciones (sass) y scripts en JavaScript.

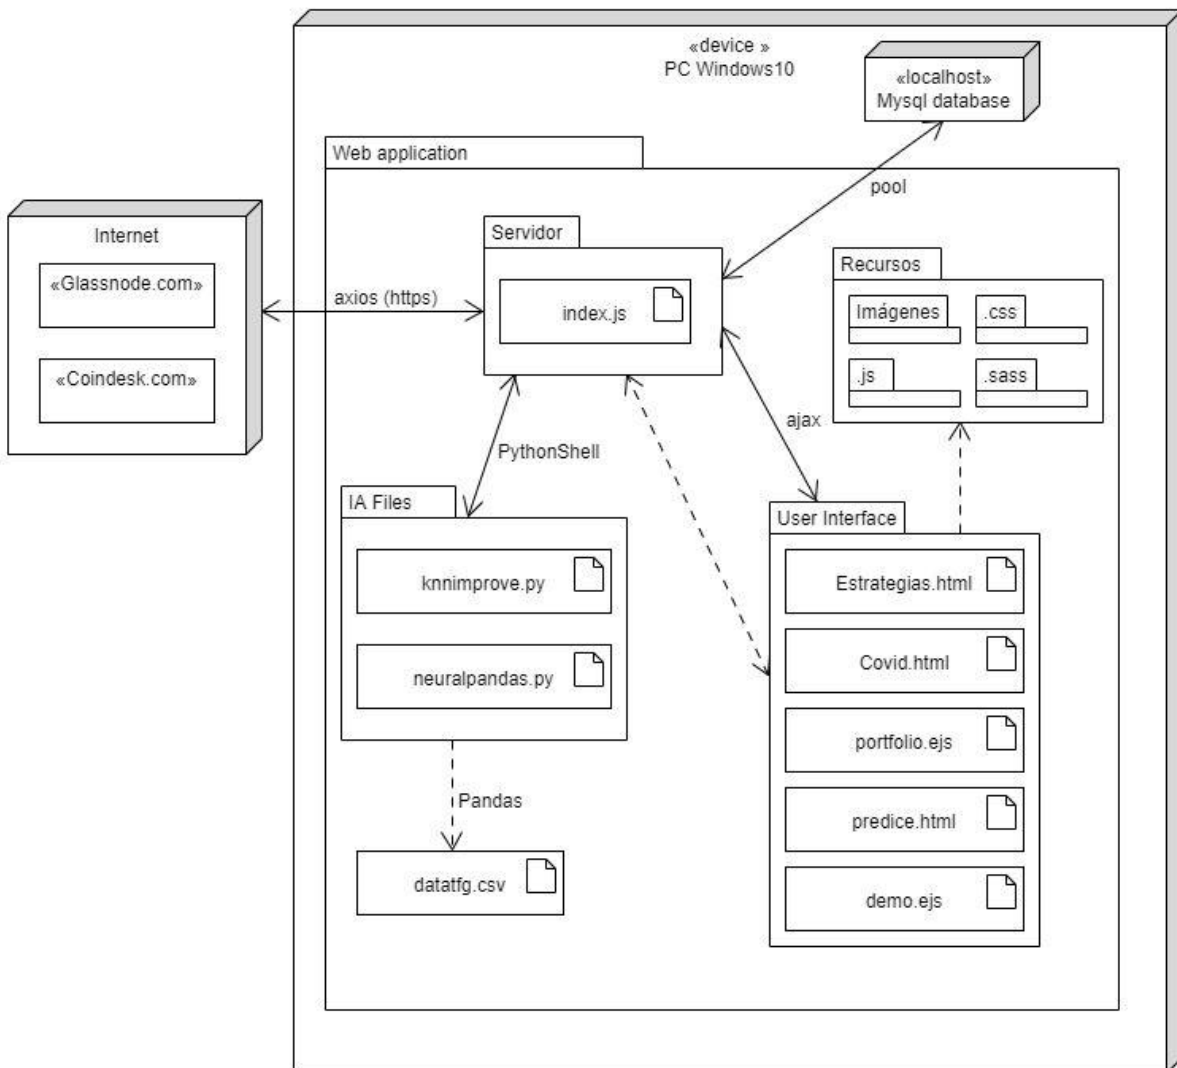
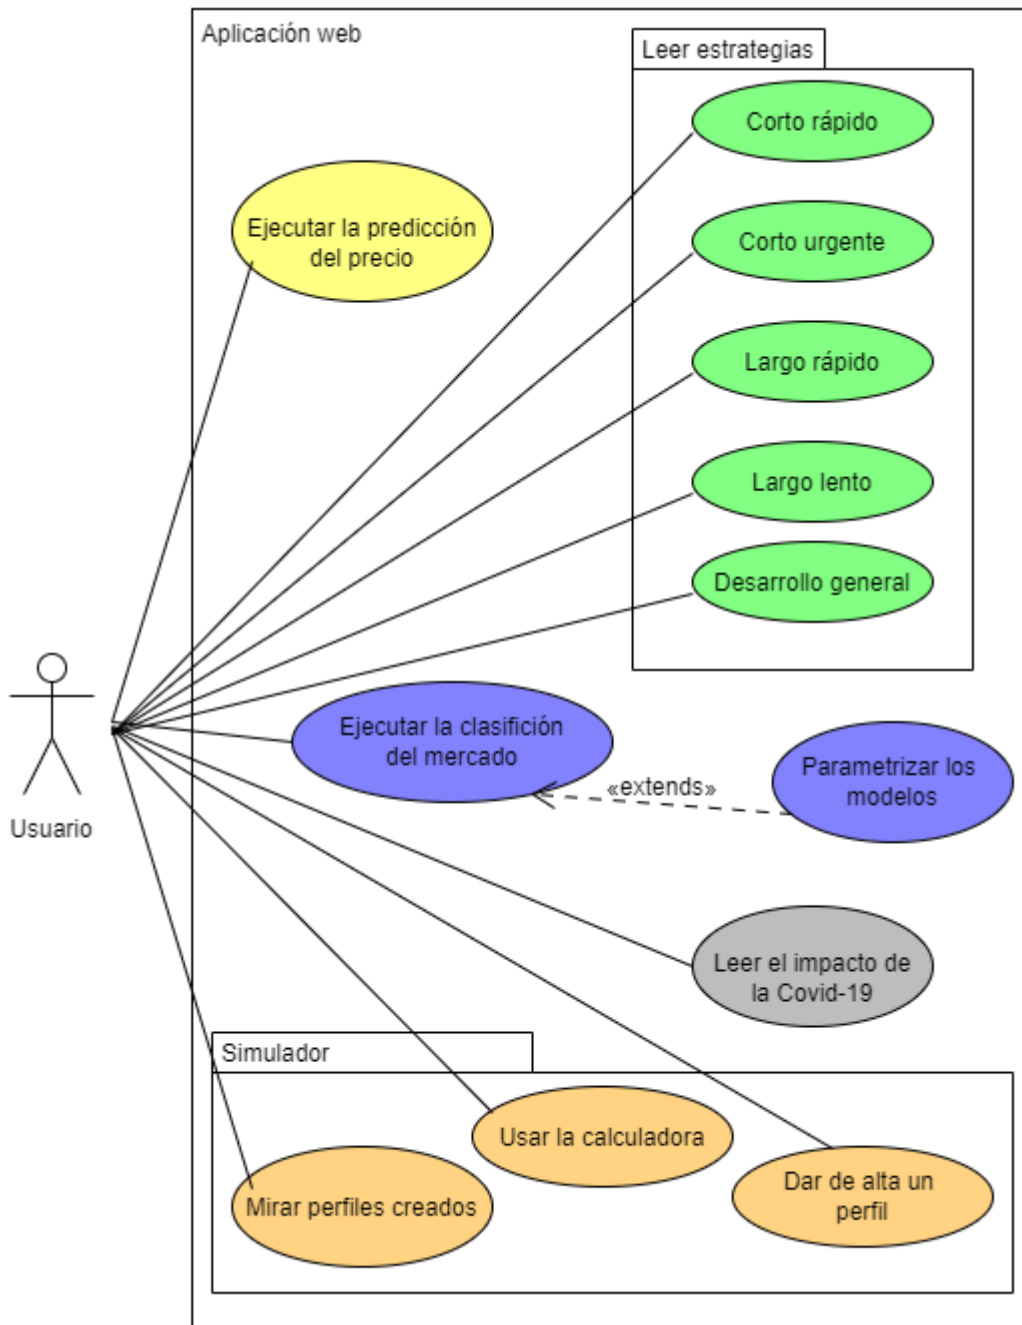


Diagrama de arquitectura.

### 3.3) Casos de uso:

En total distinguimos cinco tipos de casos de uso, cada uno lo marcamos con un color. El único actor es el usuario de la aplicación web.



Casos de uso del usuario (actor) con la aplicación web.

1. Ejecutar la predicción del precio: el usuario de la aplicación ejecuta el modelo de inteligencia artificial basado en redes neuronales para obtener una predicción del precio a menos de dos años. Realmente se calcula el porcentaje de variación máxima desde el presente en el que se ejecuta la predicción.
2. Leer estrategias; este tipo de casos de uso se basan en que el usuario obtiene información de los cuatro tipos de estrategias. Por lo tanto el usuario accederá a las páginas explicativas de cada una de las estrategias; compra a largo plazo (largo lento), compra a corto plazo (largo rápido), venta a corto plazo (corto rápido) y venta rápida (corto urgente). Además el usuario también podrá consultar las explicaciones del desarrollo general de todas estas estrategias.
3. Ejecutar la clasificación de mercado; el usuario ejecuta el modelo de inteligencia artificial basado en el algoritmo K-NN para clasificar el momento presente del mercado en la mejor situación para escoger la estrategia de inversión adecuada basándose en situaciones similares del pasado. El usuario después de ejecutar la clasificación, opcionalmente puede parametrizar el algoritmo manualmente.
4. Leer el impacto de la covid-19; en este caso de uso, el usuario consulta información acerca del impacto económico en el criptomercado ocasionado por la pandemia.
5. Usar el simulador de inversión; el usuario puede dar de alta perfiles de inversión para ver sus ganancias o pérdidas con el paso del tiempo, usar la calculadora para estudiar entradas y salidas del mercado, y mirar perfiles que ya estaban creados en la aplicación.

### 3.4) Diagramas de actividades:

Comenzamos mostrando el primer diagrama de actividades que describe el caso de uso de: ejecutar la clasificación del mercado. Tanto en este caso de uso como en el siguiente que se muestra: ejecutar la predicción del mercado, ambos utilizan conceptos que se explican más detalladamente sobre el preprocesador de datos y se incluyen imágenes del código en el apartado [4.2](#))

Los casos de uso en los que no hemos incluido diagrama de actividades son sencillos. En estos casos de uso el usuario pulsa sobre el enlace que directamente le lleva a la página (archivo HTML que le muestra la información). Son casos de uso que sirven al usuario de modo informativo para conocer el contexto de la aplicación, para saber cómo se han desarrollado las estrategias y observar los cambios que ha producido la crisis económica de la covid-19.

Damos el color verde a los datos históricos que son los datos que sirven de base al modelo. Son los datos del pasado y por lo tanto siempre son los mismos. Los datos del presente, que serán variables en cada momento en el que se ejecutará el algoritmo, están marcados en color amarillo. Una vez que se obtienen ambos datos, se procede a la normalización, creación del modelo y ejecución.

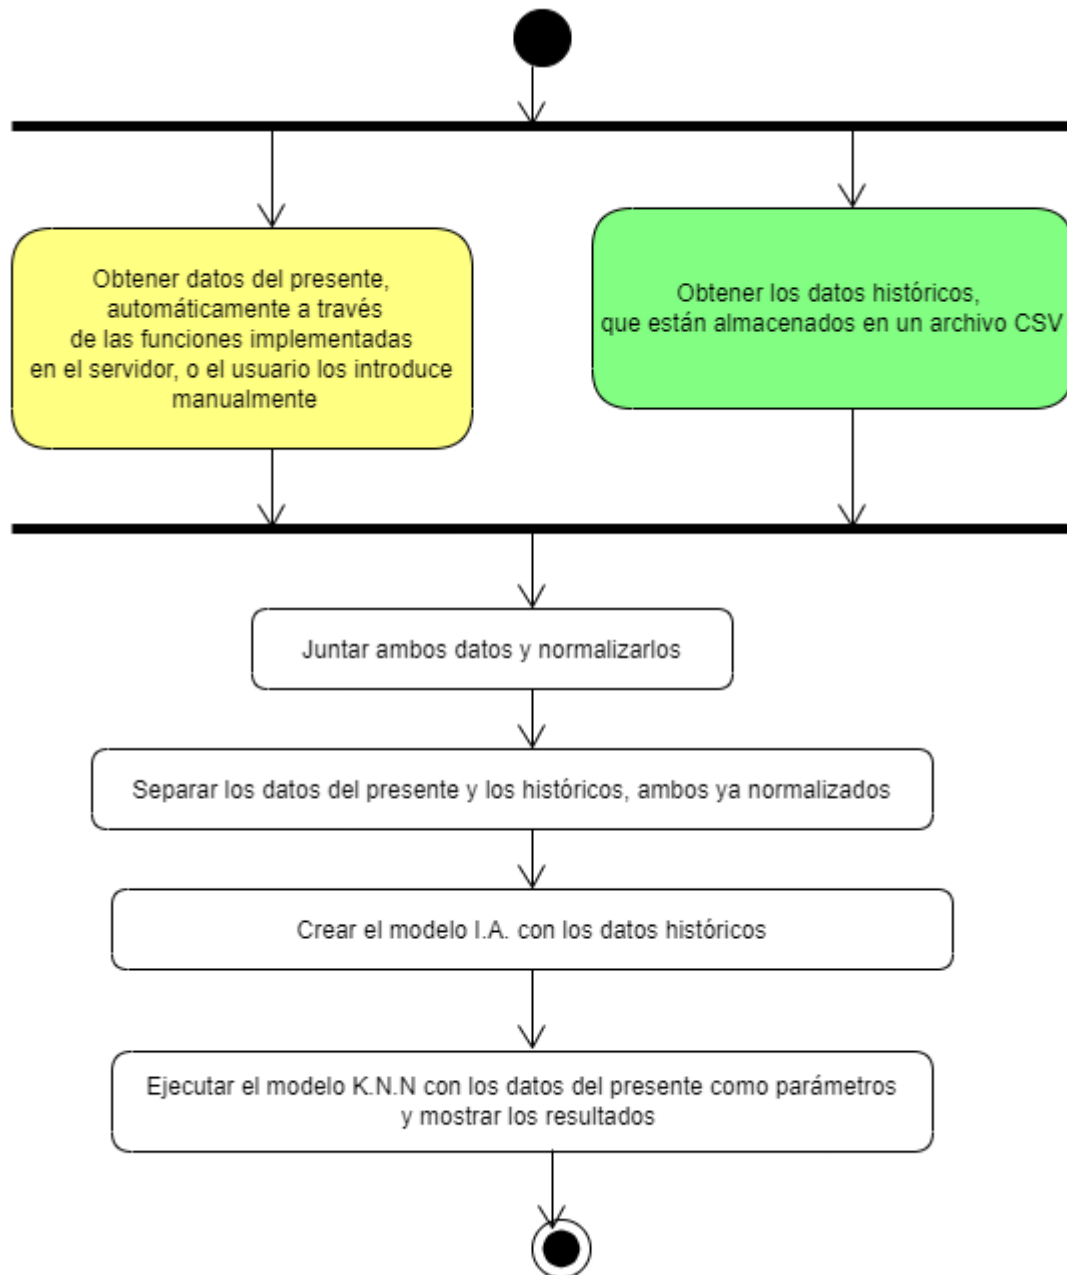


Diagrama de actividades: Ejecutar la clasificación del mercado.

Siguiendo una estructura similar al diagrama anterior, a continuación mostramos el diagrama de actividades de: ejecutar la predicción del mercado. Tenemos los datos del presente en amarillo y datos históricos en verde. Una vez que se obtienen ambos datos, se procede a la normalización, creación del modelo y ejecución únicamente cuando el modelo presenta una precisión de más del 80%.

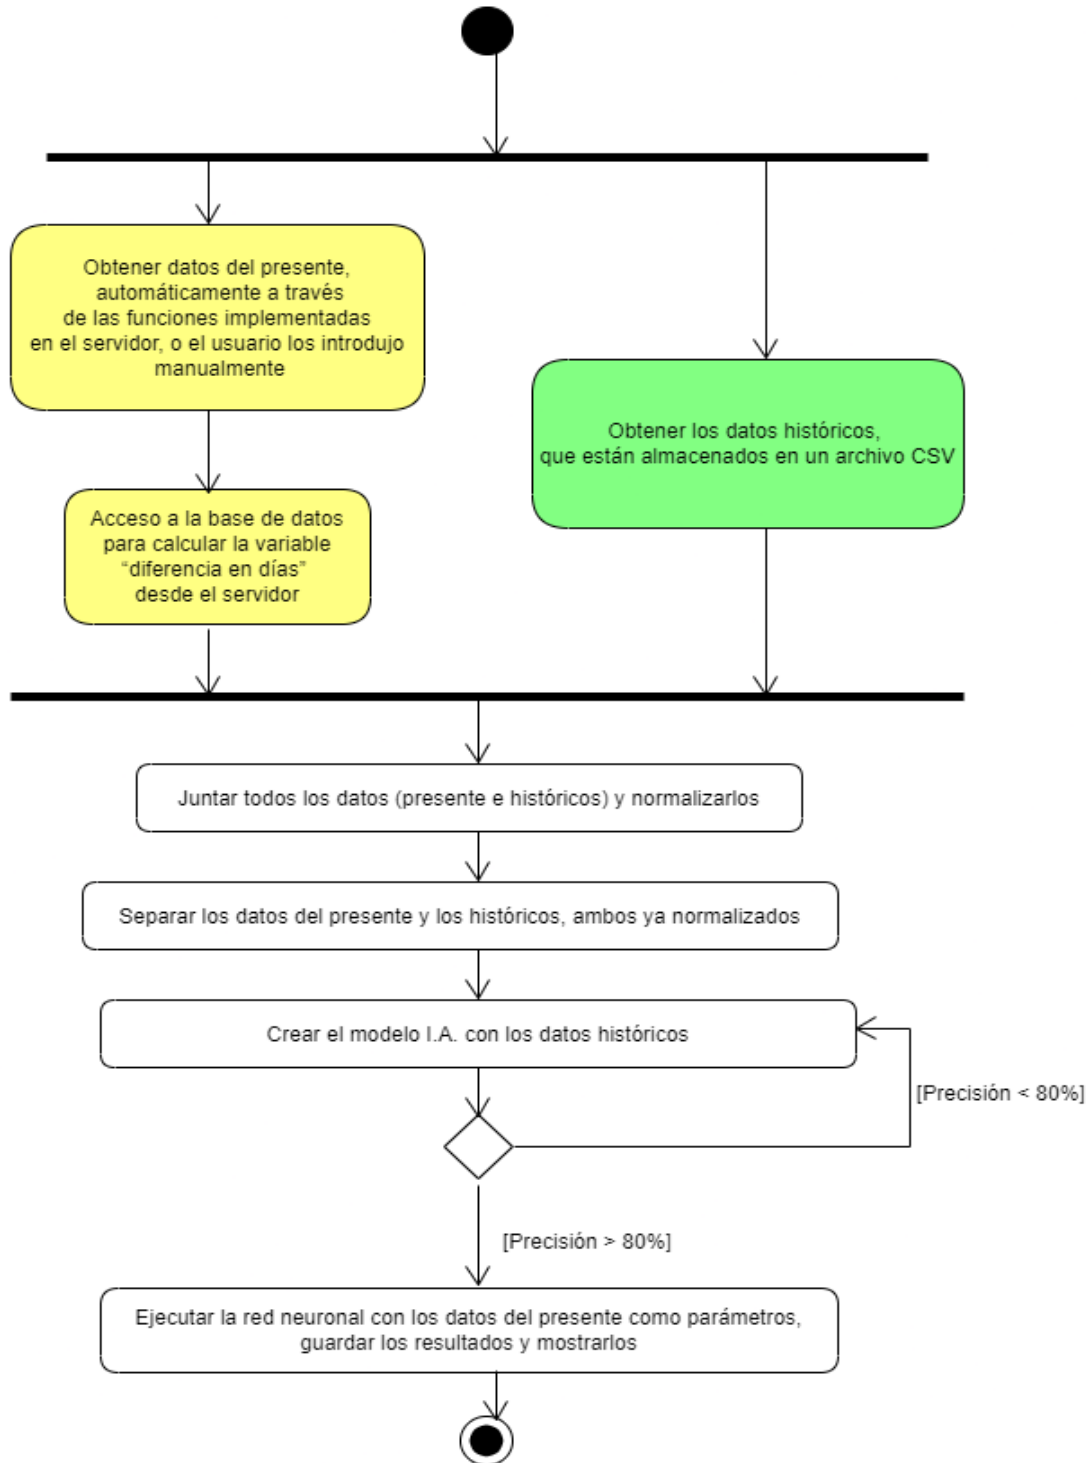


Diagrama de actividades: Ejecutar la predicción del mercado.

A continuación mostramos dos diagramas de actividades relacionados con el uso del simulador; a la izquierda el diagrama del caso de uso de mirar perfiles creados, y a la derecha, el de dar de alta un perfil.

Usando la calculadora del simulador, el usuario introduce unos parámetros de entrada (capital y tipo de estrategia) y recibe por pantalla el resultado después de ser procesado por la calculadora, por ello no hemos desarrollado el diagrama de actividad.

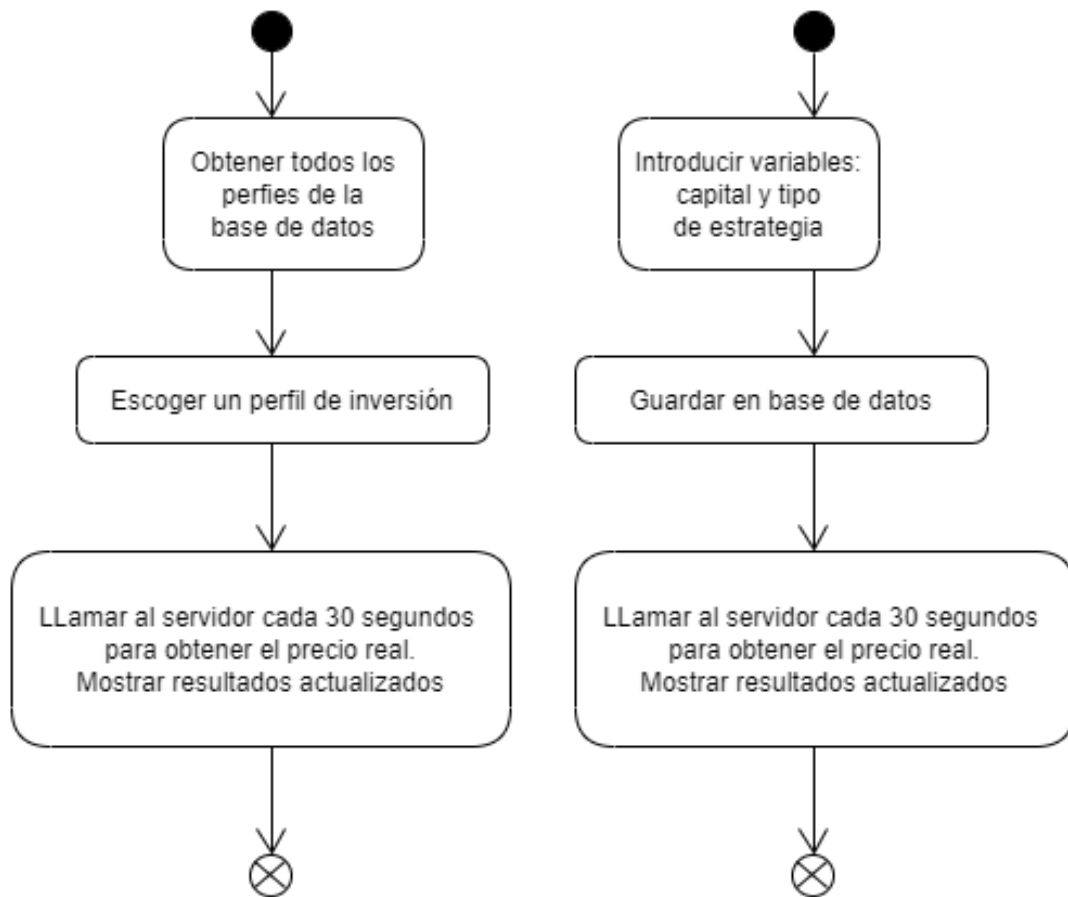


Diagrama de actividades: mirar perfiles creados (izquierda) y dar de alta un perfil (derecha).

### 3.5) Diagramas de secuencia:

El siguiente diagrama de secuencia, muestra el caso de uso de ejecutar la clasificación del mercado.

El cliente (usuario de la aplicación web), desde cualquier parte de la aplicación dentro del apartado Estrategias, puede pulsar el botón de ejecutar el modelo de inteligencia artificial. Esto activará la ruta /knn en el servidor, encargada de ejecutar el script en python knnimprove.py, donde reside el código fuente para realizar la clasificación del mercado en el momento actual. Si el script de python se ejecutó favorablemente o no, será notificado con la función callback(), y desde la ruta /knn el servidor decidirá si mostrar al cliente el resultado de la clasificación del mercado (redirigir al archivo mas.ejs) o si existió un error, por ejemplo si no encontrase el script de python, notificar el error.

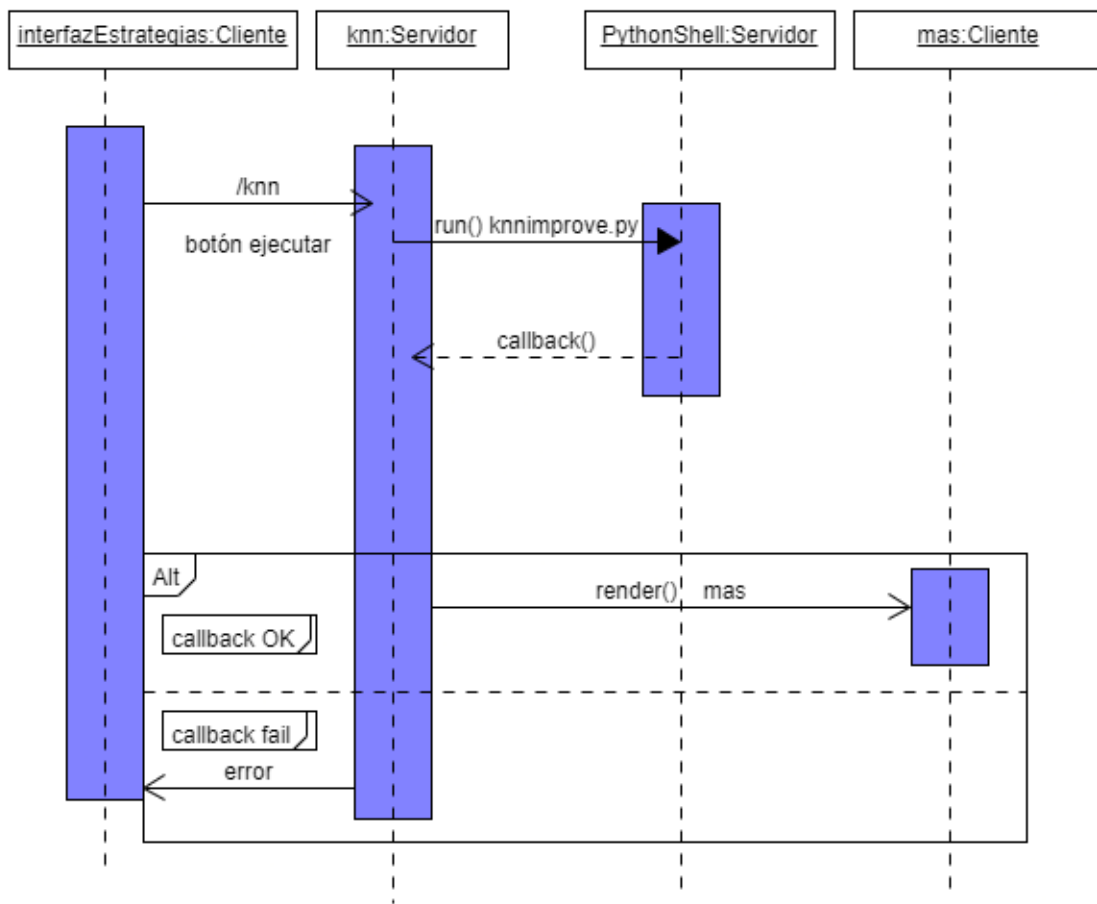


Diagrama de secuencia: ejecutar la clasificación del mercado.

El siguiente diagrama de secuencia, muestra el caso de uso de ejecutar la predicción del precio. Estructuralmente es muy similar al anterior. El cliente desde la ruta /predice.html, pulsará el botón de ejecutar modelo predictivo. Esto activará la ruta /neural

en el servidor, encargada de ejecutar el script de python neuralpandas.py donde se encuentra el código fuente de la red neuronal. Cuando se ejecute el script mediante PythonShell, se lanzará la función callback(), y desde la ruta /neural el servidor preparará el resultado para mostrarlo al cliente a través de la plantilla predice2.ejs, o bien, notificará de los errores en el trámite.

Como se indica en la nota del diagrama, se ha suprimido que antes de usar PythonShell, se accede a base de datos para conseguir la variable de “diferencia en días”. No lo hemos incluido en el diagrama para no sobrecargarlo.

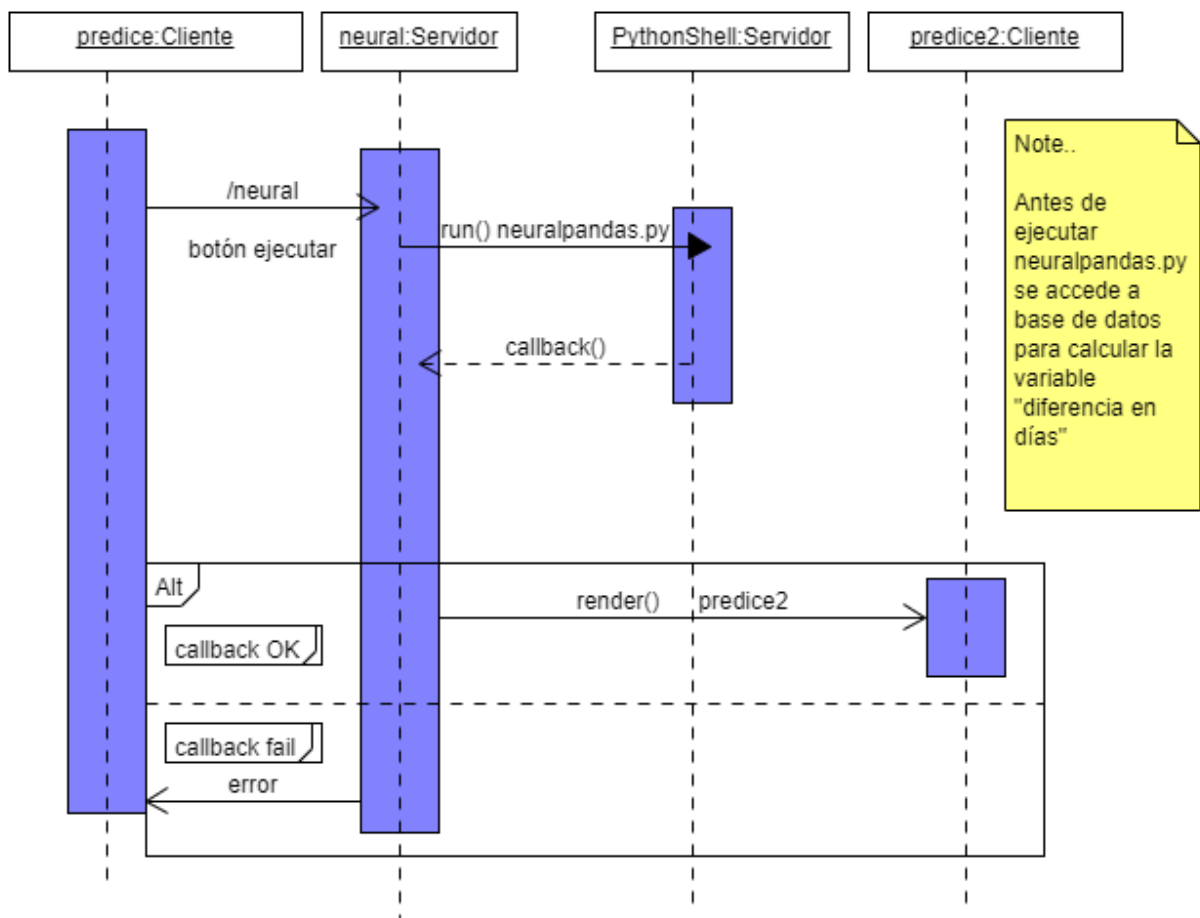


Diagrama de secuencia: ejecutar la predicción del precio.

El siguiente diagrama de secuencia muestra el caso de uso de mirar perfiles creados. El objetivo del cliente es observar los cambios en el portfolio de un perfil de inversión. Para llegar hasta esa vista (/portfolio.ejs) deberá solicitarlo a través del formulario VerInversion, que realmente es un botón con la fecha de apertura del perfil de

inversión y su tipo. Cuando el servidor reciba la petición, se activará la ruta /renderizaInversión, la cual llevará al cliente a ver el portfolio correspondiente. Una vez aquí, desde /portfolio.ejs cada treinta segundos se realizarán llamadas AJAX al servidor para obtener el precio actual del mercado y así actualizar la información. El servidor consigue esto vía /p estableciendo una llamada con axios a la api de CoinDesk y devolviendo el precio en formato JSON.

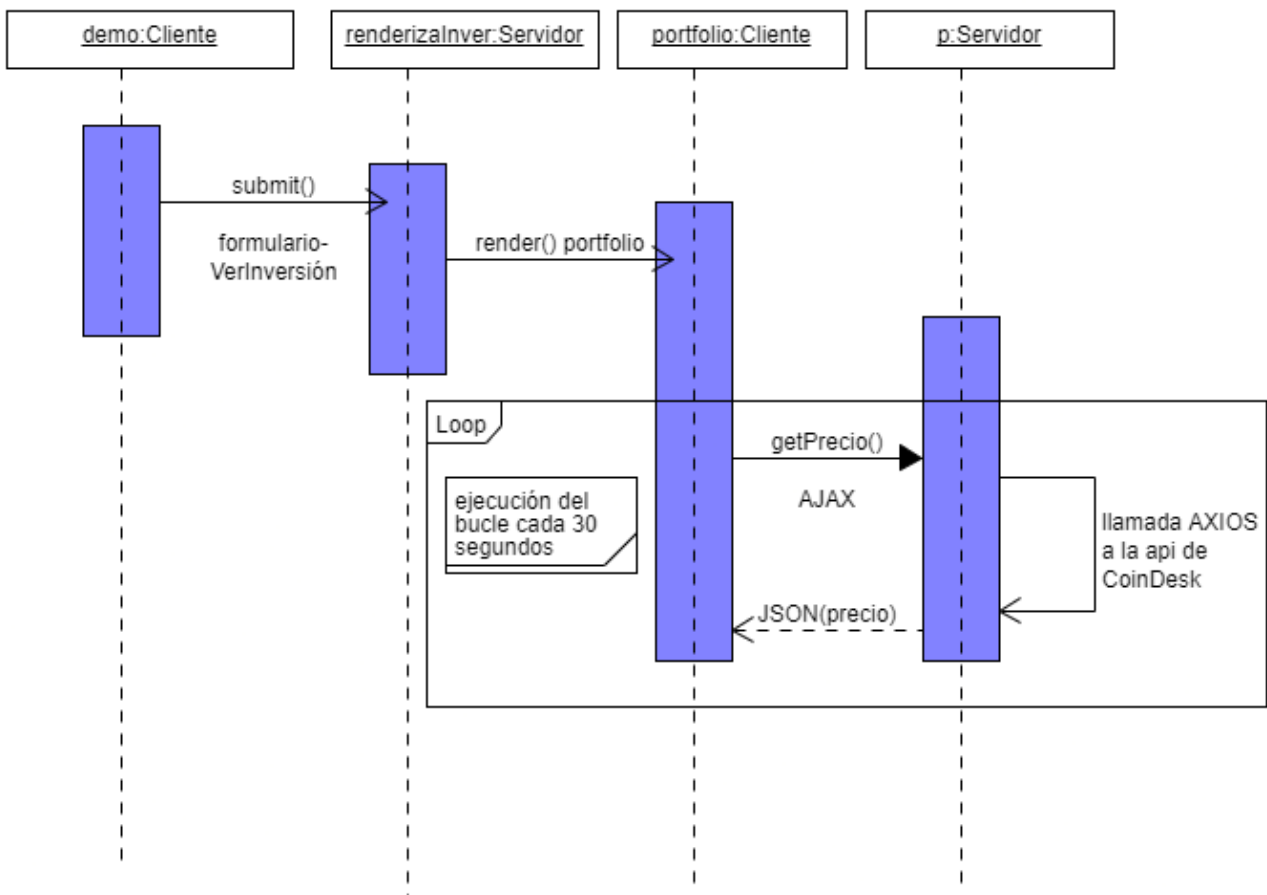


Diagrama de secuencia: mirar perfiles creados.

El siguiente diagrama de secuencia muestra el caso de uso de dar de alta un perfil de inversión.

Una vez rellenado el formulario por el cliente, el servidor le llevará a la vista de su portfolio, o será notificado de un error en el trámite.

De esto se encarga la ruta /insertarNuevaInversionEnBBDD, que al lanzar la query de inserción correspondiente a base de datos, recibe de la función callback() el resultado. Si el proceso fue correcto se redirige al cliente a la vista del porfolio, que seguirá el mismo procedimiento de actualizar su información cada treinta segundos como aparece en el anterior diagrama.

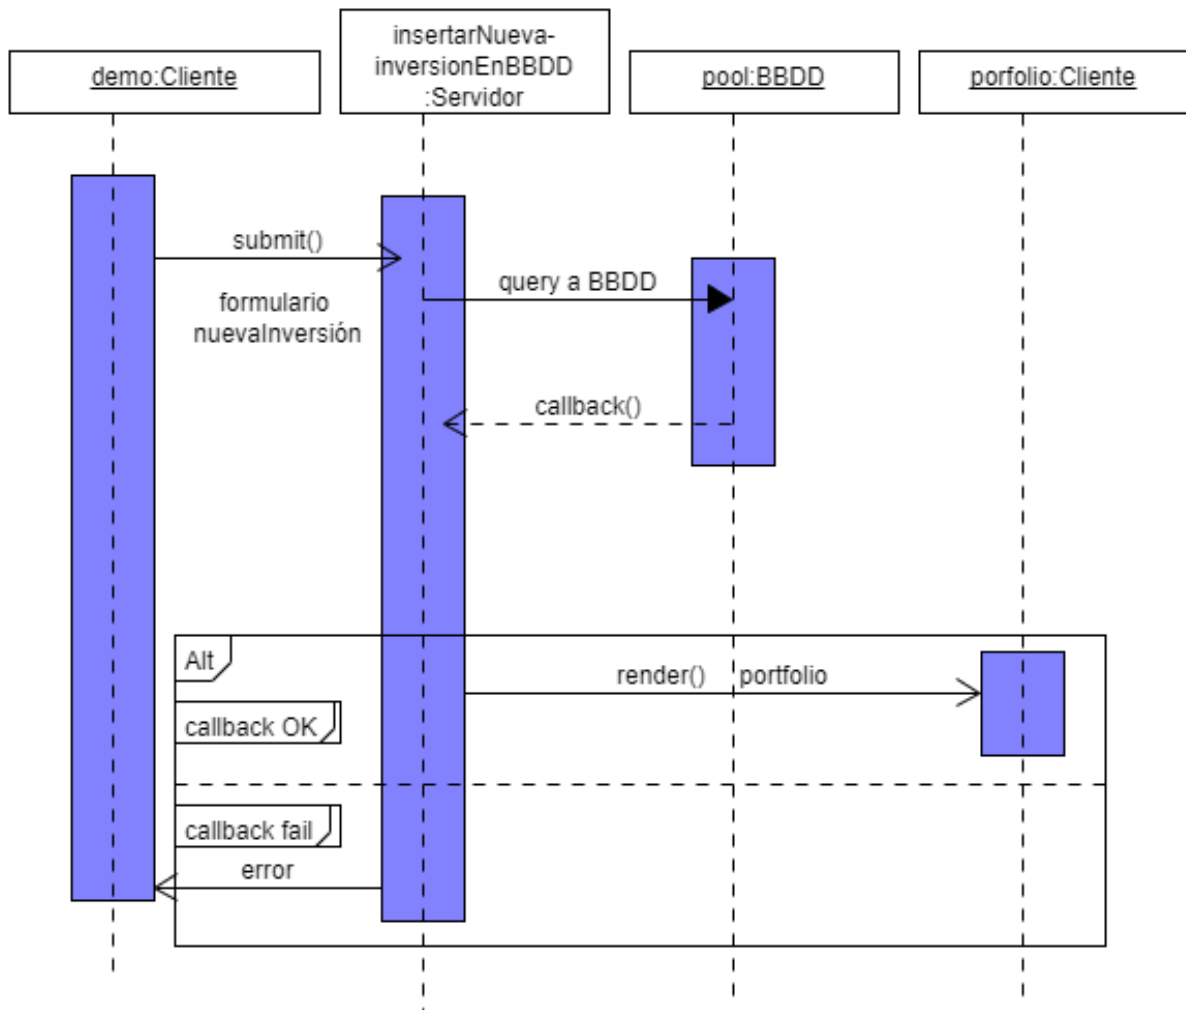


Diagrama de secuencia: dar de alta un perfil de inversión.

### 3.6) Base de datos:

La siguiente imagen muestra el esquema de las tablas de la base de datos. Las tablas no tienen relaciones foráneas, únicamente almacenan datos útiles para la aplicación:

The image shows three database tables from a schema named 'tfg1.0'. Each table is displayed in a separate window with its columns and data types.

Table Name	Column Name	Data Type
inversiones	ID	int(11)
	FECHA	date
	CAPINICIAL	float
	CANTIDADBTC	float
	ESTRATEGIA	int(11)
	PENTRADA	float
datatfg	ID	int(2)
	TIPO	int(1)
	DESC	varchar(60)
	FECHA	varchar(10)
	RSI	float
	DIFFPERMA9	float
	MONTHSTILHALVING	int(2)
	LOSSRSI2MONTHS	float
	MAXBENEFICIOPER	int(5)
	NETUPL	float
RCOINS	varchar(5)	
data	ID	int(11)
	FECHA	date
	CLOSEM	float
	RSIM	float
	MA9M	float

Esquema de las 3 tablas existentes en base de datos.

Vamos a explicar el significado de cada variable:

Tabla inversiones, guarda los datos del [simulador de inversión](#):

- FECHA: fecha en la que se abrió la operación.
- CAPINICIAL: cantidad de capital de la operación en euros.
- CANTIDADBTC: capital convertido de euro a bitcoin.
- ESTRATEGIA: guarda el tipo de la estrategia de la operación.
- PENTRADA: el precio del bitcoin en euros con el que se abrió la operación.

Tabla datatfg; guarda la [información](#) que usan [los algoritmos de inteligencia artificial](#):

- TIPO: guarda el tipo de la estrategia de la operación.
- DESC: breve descripción del tipo de la estrategia.
- FECHA: fecha que se considera de estudio.
- RSI: valor que recibe el indicador de RSI (9 meses) basado en la EMA.
- DIFFPERMA9: porcentaje de diferencia entre el precio y la media móvil de los últimos 9 meses.
- MONTHSTILHALVING: número de meses desde la fecha que se considera hasta el siguiente halving.

- LOSSRSI2MONTHS: este valor indica las pérdidas entre el RSI actual en comparación con el valor de RSI dos meses atrás en el tiempo. Si este valor es negativo quiere decir que existen ganancias de RSI.
- MAXBENEFICIOPER: máximo beneficio de media que se obtuvo en el pasado al ejecutar una de las estrategias de inversión en su periodo de tiempo determinado y en la fechas en las que se basan las estrategias. Esta variable sirve para predecir el precio futuro del bitcoin con el algoritmo de red neuronal y está expresado en porcentaje.
- NETUPL: valor porcentual que toma el indicador de net unrealised profit/loss.
- RCOINS: número de monedas de bitcoin que se otorgan a los mineros como recompensa que se obtiene al minar un bloque, esta variable se usa para conseguir más precisión en las predicciones.

Tabla data; en esta tabla se guardan los datos para calcular las nuevas variables de RSI y media móvil mensual de 9 meses correspondientes al momento presente:

- FECHA: fecha que se considera de estudio.
- CLOSEM: precio de cierre del mes de la fecha que se está considerando.
- RSIM: valor que recibe el indicador de RSI (9 meses) basado en la EMA.
- MA9M: valor que recibe la media móvil de los últimos 9 meses.

### 3.7) Notas y enlaces a la web:

Cada vez que se escribe RSI en este documento estamos haciendo referencia al RSI (Índice de fuerza relativo) calculado en el periodo de tiempo de 9 meses basado en la EMA (media móvil exponencial).

Las imágenes que muestran el precio del bitcoin a continuación están expresadas en escala logarítmica.

Consideremos el largo plazo como más de un año y el corto plazo como el periodo de tiempo comprendido entre seis y doce meses.

El código del proyecto se encuentra en el siguiente repositorio de Github:

<https://github.com/SalgadoWare/I.A.-Aplicada-a-decisiones-financieras>

El enlace a la web es el siguiente: <https://salgadoware.github.io/>

## 4) Explicación detallada de la aplicación.

### 4.1) Las estrategias de inversión propuestas:

Proponemos cuatro tipos de inversión basándonos en los mejores datos históricos: dos tipos de compras; entonces tomaríamos posiciones en largo para comprar, y dos tipos de ventas; entonces tomaríamos posiciones en corto para vender.

Cuando hacemos referencia a los mejores datos históricos es preciso detallar que hemos hecho el estudio de la siguiente manera:

- Tratamos los datos de manera mensual para simplificar el estudio y tener una visión más clara y uniforme.
- Consideramos que las fechas cuando el precio alcanzó los máximos dentro de un periodo halving (*era*) como el mejor momento para apostar en corto, es decir, comenzar con una estrategia de **venta a corto plazo**, la cual deberíamos cerrar pasado aproximadamente menos de un año, para recoger el máximo de beneficios.
- Seguidamente a esas fechas, que hemos comentado antes, están las fechas idóneas para abrir una operación de **venta rápida**, es decir, apostar en corto para recoger beneficios en menos de seis meses. En esta estrategia y la anterior, estamos aprovechando el mercado bajista.
- Después del periodo de venta rápida, consideramos que aproximadamente 18 meses antes del siguiente halving, según nuestro estudio, empieza el periodo para abrir operaciones en largo, es decir, hacer **compras a largo plazo**, con vistas a recoger beneficios pasado más de un año, vendiendo en los máximos de precio de la siguiente era.

Entonces empezaría el patrón que se repitió en las dos primeras eras, es decir, llegando a los nuevos máximos de precio, comienza otra vez el mercado bajista, y aumentan las apuestas en corto.

- Por último, después del periodo de compras a largo plazo, tendríamos también fechas para abrir posiciones en largo como aproximadamente un semestre antes de la fecha del halving, efectuando estrategias de **compra a corto plazo**, con vistas a vender en los futuros máximos de la próxima era, que serían en menos de un año, aproximadamente.

Estas estrategias han proporcionado grandes beneficios en el pasado.

También consideramos acertado decidir que las estrategias están pensadas para desarrollarse en periodos de tiempo de entre seis a doce meses, (a excepción de la venta rápida), pues como podemos apreciar en la figura 6; la media de la volatilidad absoluta (porcentaje de variación entre el precio de inicio y fin de mes) de los últimos seis meses desde el año 2015, puede alcanzar fácilmente el 20%. En la figura 6, esta media está dibujada con una línea amarilla que cruza las columnas, donde cada columna indica la volatilidad absoluta de cada mes. Al existir una volatilidad tan grande, es muy complicado

desarrollar estrategias de inversión en periodos de tiempo más reducidos como un trimestre o estrategias de mes a mes.



Figura 6: Volatilidad mensual y la media de los últimos 6 meses. Fuente; TradingView [26]

## Los cinco indicadores:

Hemos estudiado los siguientes cinco indicadores técnicos. Son el núcleo de la información que tratan los algoritmos de inteligencia artificial, a continuación vamos a explicarlos:

### 1) RSI (Relative Strength Index) Índice de fuerza relativo:

Es un indicador que mide la magnitud de los cambios recientes en los precios de una acción u otro activo financiero, para evaluar las condiciones de sobrecompra o sobreventa. El RSI se muestra como un oscilador, es un gráfico lineal que se mueve entre dos extremos y tiene un rango de entre 0 a 100 puntos. El indicador fue desarrollado originalmente por J. Welles Wilder Jr. E introducido en su libro *Concepts in Technical Trading Systems*.

Tradicionalmente, cuando se lee el valor del RSI, indica que los valores de 70 puntos o más, muestran que un activo está sobrecomprado o sobrevalorado y puede que se esté preparando para una tendencia bajista en el precio. Por otro lado, una lectura del RSI de 30 puntos o menos, indica una condición de sobreventa o infravaloración.

Existen varias formas de calcular el RSI, nosotros hemos utilizado la siguiente: [\[27\]](#)

$$RSI = 100 - \left( \frac{100}{1 + RS} \right)$$

$$RS = \textit{Average gain} / \textit{Average loss}$$

Donde:

Average Gain = [(previous Average Gain) x 8 + current Gain] / 9.

Average Loss = [(previous Average Loss) x 8 + current Loss] / 9.

Y:

previous Average Gain = Sum of Gains over the past 9 periods / 9.

Previous Average Loss = Sum of Losses over the past 9 periods / 9

Hemos parametrizado esta variable para que el usuario de la aplicación pueda introducir manualmente los valores que considere oportunos de RSI, porque somos conscientes de que estos valores pueden cambiar según el tipo de medición, ya sea a través de la media móvil o a través de la media móvil exponencial u otro tipo de medición. Lo más importante es que comprenda que los cálculos se hacen en base a nueve meses.

## 2) Pérdidas de RSI en 2 meses: [\[28\]](#)

Este indicador ha sido desarrollado por nosotros mismos en la página web de TradingView. El indicador nos muestra cuantos puntos ha perdido el RSI actual respecto al valor del RSI que marcaba hace 2 meses.

El indicador se obtiene con la siguiente fórmula:

Pérdidas de RSI en 2 meses = (RSI de hace 2 meses – RSI actual).

Si este indicador nos marca, por ejemplo, 20 puntos, quiere decir que el RSI actual ha perdido 20 puntos respecto al de hace dos meses, y por el contrario si el valor es negativo (-20), estaríamos observando un aumento de 20 puntos en el RSI en los dos últimos meses.

Consideramos que este indicador nos proporciona información útil, pues puede marcar cambios de tendencias a periodos de tiempo de seis meses o más. Durante el desarrollo, nos dimos cuenta que así era, sobre todo, a la hora de identificar compras a corto plazo y ventas rápidas.

En la figura 7 mostramos el indicador del RSI sobre 9 meses, marcado en morado el rango [30-70], para facilitar la comprensión gráfica de este indicador:



Figura 7: RSI en base a 9 meses. Fuente; TradingView

### 3) Porcentaje de diferencia entre el precio y la media móvil:

Este indicador se basa en el concepto de media móvil; la media móvil (moving average) es la media aritmética de los 'n' datos anteriores del precio. Nosotros utilizamos la media móvil con  $n=9$ , sobre los valores del precio de cierre de cada mes. Es decir, la media móvil nos indica el valor del precio que se obtiene si se toman los anteriores 9 valores del precio a cierre mensual, se suman y se dividen entre 9.

En la media móvil, cuanto más grande sea 'n', mayor será la influencia de los datos antiguos. En contrapartida, si se selecciona una 'n' menor, se tendrán en cuenta datos más recientes para el cálculo.  $N = 9$ , es comúnmente utilizada para este tipo de cálculos.

A continuación en la figura 8, mostramos estos conceptos para facilitar la comprensión:

En la figura 8 aparece la media móvil como una línea azul sobre el gráfico del precio que representado en velas, y el porcentaje de diferencia entre el precio y la media móvil aparece en la parte de debajo de la imagen, como una línea morada.



Figura 8: Indicador de la diferencia porcentual entre precio y media móvil. [29]

Con este indicador, el porcentaje de diferencia entre el precio y la media móvil, conseguimos visualizar y medir de una manera fácil, dónde se encuentra el precio respecto a la media. Si el porcentaje es positivo, quiere decir que el precio se sitúa por encima de la media, en cambio, si es negativo, el precio se encuentra por debajo de la media. Esto es información útil a la hora de detectar tendencias y cambios en el comportamiento del precio.

Por ejemplo, cuando el precio rondaba los 3600\$ a principios de 2019, este porcentaje de diferencia marcaba un -70%, es decir, el precio estaba un 70% por debajo que la media en los últimos 9 meses. En cambio, cuando el precio alcanzó los máximos históricos, este porcentaje marcó un 60%.

Desde que se comercializa el bitcoin hasta abril de 2019, siempre que este indicador ha marcado valores por debajo de 0%, han sido buenos momentos para efectuar operaciones en largo.

#### 4) Meses hasta el siguiente halving:

Conociendo la estructura cíclica del modelo del bitcoin que cada cuatro años actualiza su protocolo de minado mediante los halving o reducciones progresivas de la recompensa que se otorga a los mineros, es importante conocer a cuantos meses del halving se sitúa el momento del mercado que se está estudiando, pues en toda la historia del precio, este ha sido un indicador

muy importante [30] Posteriormente a los dos primeros halving hasta ahora, el precio ha crecido bruscamente.

A esta variable la damos valores positivos desde 0, si la fecha de estudio corresponde al mismo mes del halving, hasta 48 (12 meses \*4 años).

Por ejemplo si esta variable equivale a 10, estaremos estudiando una fecha que está situada a 10 meses del siguiente halving.

##### 5) Porcentaje de beneficio/perdida no realizado en la red:

Este es un indicador que hemos tomado de la página web de Glassnode Studio [31].

Se trata de la diferencia entre la ganancia relativa no realizada y la pérdida relativa no realizada. Los datos se muestran en el rango [-1.5, 1]

Mostramos este indicador en la figura 9. Desde 2011 ha acertado marcando los máximos y mínimos del precio. Máximos por encima de 0.5, color verde y azul, y los mínimos en color rojo con valores negativos:

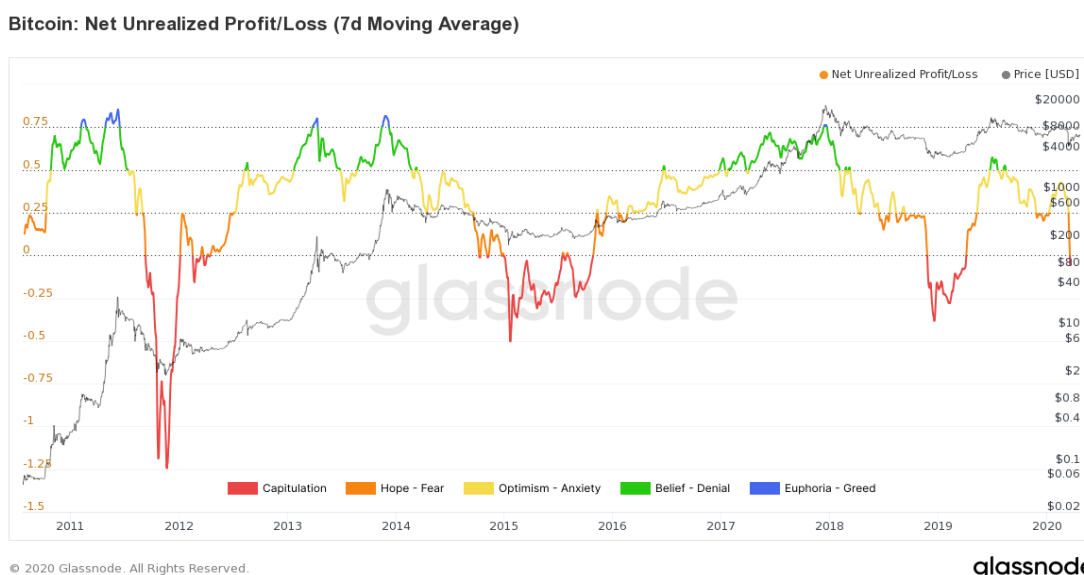


Figura 9: Indicador de porcentaje de beneficio/perdida no realizado en la red.

A continuación, vamos a exponer las características comunes que tuvieron estos cinco indicadores en cada tipo de estrategia en el pasado. Hemos desarrollado cada tipo de inversión basándonos en datos del pasado, lo cual no quiere decir que vayan a seguir este comportamiento en el futuro. Son los datos que manejan los algoritmos de inteligencia artificial, no son principios que se deban cumplir estrictamente. Entonces analizando el comportamiento del precio en el pasado y recogiendo datos de los

indicadores de la actualidad, se pretende clasificar el momento presente para llevar a cabo estrategias de inversión que se completarán en el futuro, con el objetivo de recoger beneficios. Además de realizar la predicción del precio en el futuro.

### Compra a largo plazo:

Como se analiza en profundidad en el apartado de Estrategias – Compra a largo plazo en la aplicación, se ha llegado a la conclusión de que en el pasado, resultaron exitosas estrategias de compras a largo plazo cuando los indicadores marcaron los siguientes valores:

- Niveles bajos de RSI en el rango de [20-50] puntos.
- Pérdidas de RSI en 2 meses: el indicador muestra una línea estable o una línea decreciente, es decir, el RSI gana puntos progresivamente respecto al pasado.
- Media móvil de 9 meses por encima del precio, es decir, el porcentaje de diferencia entre precio y media móvil es negativo.
- El porcentaje de ganancias/pérdidas no ejecutadas de la red también marca valores negativos, es decir por debajo de 0.
- Estas estrategias empezaron unos 18 meses antes del halving.

Nos basamos en finales de 2011 – principios de 2012, el año 2015/2016, y finales de 2018 – principios de 2019.

### Compra a corto plazo:

Como se analiza en profundidad en el apartado de Estrategias – Compra a corto plazo en la aplicación, se ha llegado a la conclusión de que en el pasado, resultaron exitosas estrategias de compras a corto plazo con los siguientes indicadores:

- El RSI marca valores crecientes en el rango de [60-88] puntos.
- El indicador de pérdidas de RSI en 2 meses no muestra pérdidas.
- La media móvil de 9 meses está por debajo del precio, esto es, el porcentaje de diferencia entre precio y media móvil indica valores positivos pero no más grandes del 45%.
- El porcentaje de ganancias/pérdidas no ejecutadas de la red muestra valores entre un 25% y 50%
- Estos periodos de compras a corto plazo exitosas se produjeron justo antes del halving, o un semestre antes como mucho.

Nos basamos desde junio a noviembre de 2012, y desde noviembre de 2015 hasta julio de 2016.

## Venta a corto plazo:

Como se analiza en profundidad en el apartado de Estrategias – Venta a corto plazo en la aplicación, se ha llegado a la conclusión de que en el pasado, resultaron exitosas estrategias de venta a corto plazo con los siguientes indicadores:

- RSI en niveles extraordinariamente altos, en el rango de [90-100]
- El indicador de pérdidas de RSI en 2 meses no muestra pérdidas, al contrario, este indicador muestra ganancias en el RSI hasta que finaliza la sobrecompra para dar lugar a la venta.
- La media móvil de 9 meses se sitúa por debajo del precio desde un 50% hasta un 100%. Es normal que este valor disminuya con el paso del tiempo pues, cada vez, es más difícil que el precio varíe tanto respecto a la media de 9 meses.
- El porcentaje de ganancias/perdidas no realizadas de la red marca valores muy altos [65-80]%
- Estos periodos han empezado unos 28 meses antes del halving.

Nos basamos en el final de mayo y junio de 2011, el final de noviembre de 2013, y en el último trimestre de 2017.

## Venta rápida:

Como se analiza en profundidad en el apartado de Estrategias – Venta a rápida en la aplicación, se ha llegado a la conclusión de que en el pasado, resultaron exitosas estrategias de venta a corto plazo con los siguientes indicadores:

- Niveles altos de RSI (9 meses) que disminuyen en el rango de [70-45] aproximadamente.
- Pérdidas de RSI en 2 meses marcando altas pérdidas, niveles entre 10 y 26 puntos. La nueva tendencia es la venta.
- La media móvil de 9 meses se sitúa por debajo del precio pero se va aproximando hacia él, es decir, el porcentaje de diferencia precio/media cae desde el 60% y el 30% hasta valores más bajos. Es normal que este valor haya disminuido con el paso del tiempo, es decir, será muy complicado en el futuro ver este porcentaje caer desde el 60%, pues indicaría que ha existido una extraordinariamente fuerte subida previa.
- Estos periodos han empezado unos dos años antes del halving, más o menos por la mitad del ciclo.

Nos basamos en julio y agosto de 2011, desde diciembre de 2013 hasta marzo 2014, y el primer cuatrimestre de 2018.

## 4.2) Explicación detallada de los dos modelos de inteligencia artificial desarrollados.

### Preprocesador de datos:

Hemos utilizado el preprocesador de datos de la librería de Scikit-learn [31] para tratar los datos que usan los algoritmos de inteligencia artificial. Exactamente es un normalizador de datos que aplica la desviación típica o desviación estándar a todo el conjunto de datos. De esta manera conseguimos mejores resultados. Fue necesaria esta implementación ya que, por ejemplo, en la variable de **máximo beneficio en porcentaje obtenido**, tenemos un rango muy amplio de [-80,36000] y cuando no usamos el preprocesador de datos, observábamos resultados más dispares.

A continuación, mostramos en la figura 10 cómo está realizado este proceso en código Python:

```
#añadimos la nueva fila que viene de parámetro para normalizarla de acuerdo a todos los datos,
# la nueva fila es una tupla que contiene la información del presente
new_row = pd.DataFrame(json.loads(sys.argv[1]),index =[0])

#se añade al final, entonces tenemos un nuevo data frame completo
df = pd.concat([df,new_row]).reset_index(drop = True)

#usando el Normalizador de sklearn aplicamos el preprocesado de datos a todo el data frame
from sklearn import preprocessing
scaler=preprocessing.Normalizer()
df[['RSI','DIFFPERMA9','MONTHSTILHALVING','LOSSRSI2MONTHS','NETUPL']]=scaler.fit_transform(df[['RSI','DIFFPERMA9','MONTHSTILHALVING','LOSSRSI2MONTHS','NETUPL']])

#guardamos nuestro elemento normalizado ( tupla con los datos del presente que queremos clasificar )
elementNormal = df.iloc[56]

#y lo eliminamos de todos los datos
df=df[:-1]

#para finalmente tener todas las muestras ya normalizadas en la variable samples
samples=df[['RSI','DIFFPERMA9','MONTHSTILHALVING','LOSSRSI2MONTHS','NETUPL']]
```

Figura 10: Código del preprocesador de datos.

Los dos algoritmos de inteligencia artificial utilizan la librería Pandas para obtener los datos correspondientes a los indicadores, estos datos se guardan un fichero de tipo csv. A continuación mostramos cómo es el fichero csv en la figura 11.

Exactamente contiene 56 filas de datos, correspondientes a 56 meses con el valor de los indicadores estudiados, que sirven como la base de información del pasado a las estrategias de inversión. Es importante destacar que aunque sean pocas filas (56), hacen referencia a más de cuatro años y medio que se han resumido en meses, es decir, consideramos que en este tipo particular de sistema, es más valiosa la calidad de los datos que la cantidad.

	A	B	C	D	E	F	G	H	I	J	K	L
1	ID	TIPO	DESC	FECHA	RSI	DIFFPERMA9	MONTHSTILF	LOSSRSI2MO	MAXBENEFIC	NETUPL	RCOINS	
2	0		0 corto, venta	30/05/2011	99.44	80.65		18 -1.91		-65 78.66		-50
3	1		0 corto, venta	30/06/2011	99.76	78.52		17 -1.91		-80 59.76		-50
4	2		0 corto, venta	30/11/2013	98.53	79.18		32 -13.5		-80 81.08		-25
5	3		0 corto, venta	30/10/2017	92.18	53.89		31 5.14		-48 65.32		-12.5
6	4		0 corto, venta	30/11/2017	96.08	60.3		30 -8.86		-67 69.84		-12.5
7	5		0 corto, venta	30/12/2017	97.7	61.36		29 -5.15		-75 75.88		-12.5
8	6		1 largo, compr	30/09/2011	42.32	-23.33		14 10.97		26000 -18.48		-50
9	7		1 largo, compr	30/10/2011	36.67	-105.4		13 14.07		35000	-87	-50
10	8		1 largo, compr	30/11/2011	35.83	-132.8		12 5.63		36000 -87.55		-50
11	9		1 largo, compr	30/12/2011	45.94	-55.07		11 -4.67		23900 -20.39		-50
12	10		1 largo, compr	30/01/2015	25.66	-103.45		18 8.42		6295 -23.03		-25
13	11		1 largo, compr	28/02/2015	33.38	-55.89		17 2.22		5600 -25.16		-25
14	12		1 largo, compr	30/03/2015	32.15	-45.31		16 -2.34		5600 -20.17		-25
15	13		1 largo, compr	30/04/2015	31.02	-34.7		15 1.24		5800 -28.88		-25
16	14		1 largo, compr	30/05/2015	30.49	-25.04		14 0.83		5900	-22	-25
17	15		3 largo, compr	30/06/2012	64.45	28.54		5 -7.34		17600 24.3		-50
18	16		3 largo, compr	30/07/2012	78.28	41.51		4 -14.76		12500 41.09		-50
19	17		3 largo, compr	30/08/2012	81.17	38.44		3 -10.77		11500 44.48		-50
20	18		3 largo, compr	30/09/2012	86.98	42.67		2 -7.45		8900 46.33		-50
21	19		3 largo, compr	28/02/2016	69.5	25.44		5 1.21		3100 28.7		-25
22	20		3 largo, compr	30/03/2016	62.19	16.78		4 -3.09		3000 25.88		-25
23	21		3 largo, compr	30/04/2016	67.74	18.89		3 0.14		3100 30.89		-25

Figura 11: Datos históricos en el archivo CSV.

Además este sistema de recolección y acceso a datos es totalmente extensible, pues a medida que pase el tiempo y se vayan confirmando estrategias de inversión, simplemente se debe añadir al archivo csv la información relativa a los meses pasados, y los algoritmos de inteligencia artificial tendrán más casos base, es decir, más información útil y más casuística a la hora de ejecutarse.

## Algoritmo de clasificación: K-NN.

Gracias a la librería de Scikit-learn [33], hemos desarrollado el siguiente algoritmo de inteligencia artificial que vamos a detallar a continuación:

Utilizamos el método de clasificación supervisada llamado “k vecinos más cercanos” (en inglés, k-nearest neighbors, abreviado: k-nn).

Con este método pretendemos clasificar el momento presente del mercado en una de las cuatro categorías. Cada categoría o clase corresponde a una de las [estrategias de inversión](#) que proponemos.

Cada clase o categoría comparte valores similares de los indicadores que hemos estudiado, es decir, cada clase tiene una serie de valores que la proporcionan identidad y la diferencian del resto. Estas diferencias las hemos explicado en el punto [4.1](#))

El algoritmo estima el valor de la probabilidad de que un elemento nuevo pertenezca a una de las clases que ya están definidas gracias al conjunto de datos que dispone. El elemento nuevo que pretendemos clasificar es el presente, por lo tanto, pasamos como argumento los valores de los indicadores del presente y el algoritmo nos da como resultado la probabilidad de pertenencia a cada una de las clases.

En este algoritmo es fundamental el valor de la  $k$ , pues se pueden ver diferentes resultados dependiendo de su valor.  $K$  es el número de casos más cercanos que se van consultar,  $k$  es el número de “vecinos”. A continuación en la figura 12, se comprende fácilmente este hecho.




Figura 12: Diferentes soluciones según el valor de  $K$  en el algoritmo  $K$ -NN.

Con  $k=3$  tenemos que el punto que estamos estudiando (color verde) pertenecería con más probabilidad ( $2/3$ ) a la clase de tipo triángulo, en cambio, con  $k=5$ , la clase del punto estudiado pertenecería con una probabilidad de  $3/5$  a la clase del cuadrado.

Para dar solución a este problema, nosotros hemos desarrollado el algoritmo de manera fácilmente parametrizable por el usuario, para que vea la variación de los resultados, es decir, que vea claramente cómo varía el valor de la probabilidad de pertenencia a cada clase o estrategia de inversión, cambiando manualmente el valor de  $k$ . También explicamos a continuación por qué consideramos que en nuestro sistema el [mejor valor de  \$k\$](#)  es  $k=6$ .

*Parámetros que usa el algoritmo:*

Entrada; cada dato contiene estos cinco valores:

- 1) RSI
- 2) Diferencia en porcentaje del precio y la media móvil
- 3) Meses hasta el siguiente halving
- 4) Pérdidas de RSI en 2 meses
- 5) Porcentaje de beneficio/pérdidas no ejecutado de la red

Salida:

El valor que se pretende averiguar es el tipo de la estrategia. Es representado como un número:

0: Venta a corto plazo. También llamada “Corto rápido”.

1: Compra a largo plazo. También llamada “Largo lento”.

2: Venta rápida. También llamada “Corto urgente”.

3: Compra a corto plazo. También llamada “Largo rápido”.

*Deduciendo el mejor valor de k:*

La variable k suele fijarse tras un proceso de pruebas con varias instancias del modelo. Nosotros hemos desarrollado el proceso de pruebas y el entrenamiento del modelo del siguiente modo:

Realizamos un bucle y en cada iteración probamos el modelo con un valor diferente de k; desde k=1 hasta k=15. También en cada iteración calculamos la precisión del modelo con las funciones que nos ofrece la librería de `KNeighborsClassifier` [33]. La función `score`, nos devuelve la precisión media entre los datos que se pasan como argumentos y sus etiquetas, en nuestro caso, los datos son los valores de los indicadores, y las etiquetas son la estrategia o clase a la que pertenecen esos datos.

A continuación mostramos este código en la figura 13:

```
47 #separamos datos de validacion/test y datos de entrenamiento,
48 # de una manera aleatoria pero siempre el mismo tipo de aleatoriedad en tiempo de ejecucion
49 from sklearn.model_selection import train_test_split
50 X_train, X_test, y_train, y_test = train_test_split(samples, target, test_size=0.33, random_state=42)
51
52 """from sklearn.neighbors import KNeighborsClassifier
53 import numpy as np
54 #vamos probando para diferentes valores de k , la precision del modelo
55 vecinos=np.arange(1,16) #enumerado
56
57 #arrays donde guardamos la información para la posterior representacion grafica
58 accTrain=np.empty(len(vecinos))
59 accTest=np.empty(len(vecinos))
60
61 #bucle
62 for i,k in enumerate(vecinos):
63     neigh = KNeighborsClassifier(n_neighbors=k) #creamos el modelo , cada vez con una k diferente
64     neigh.fit(X_train, y_train) #entrenamos el modelo
65     accTrain[i]=neigh.score(X_train,y_train) #calculamos la precision
66     accTest[i]=neigh.score(X_test,y_test) #calculamos la precision
67
68
69
```

Figura 13: Código del bucle para deducir el mejor valor de k.

La gráfica que conseguimos a través de Matplotlib [34], la mostramos en la figura 14:

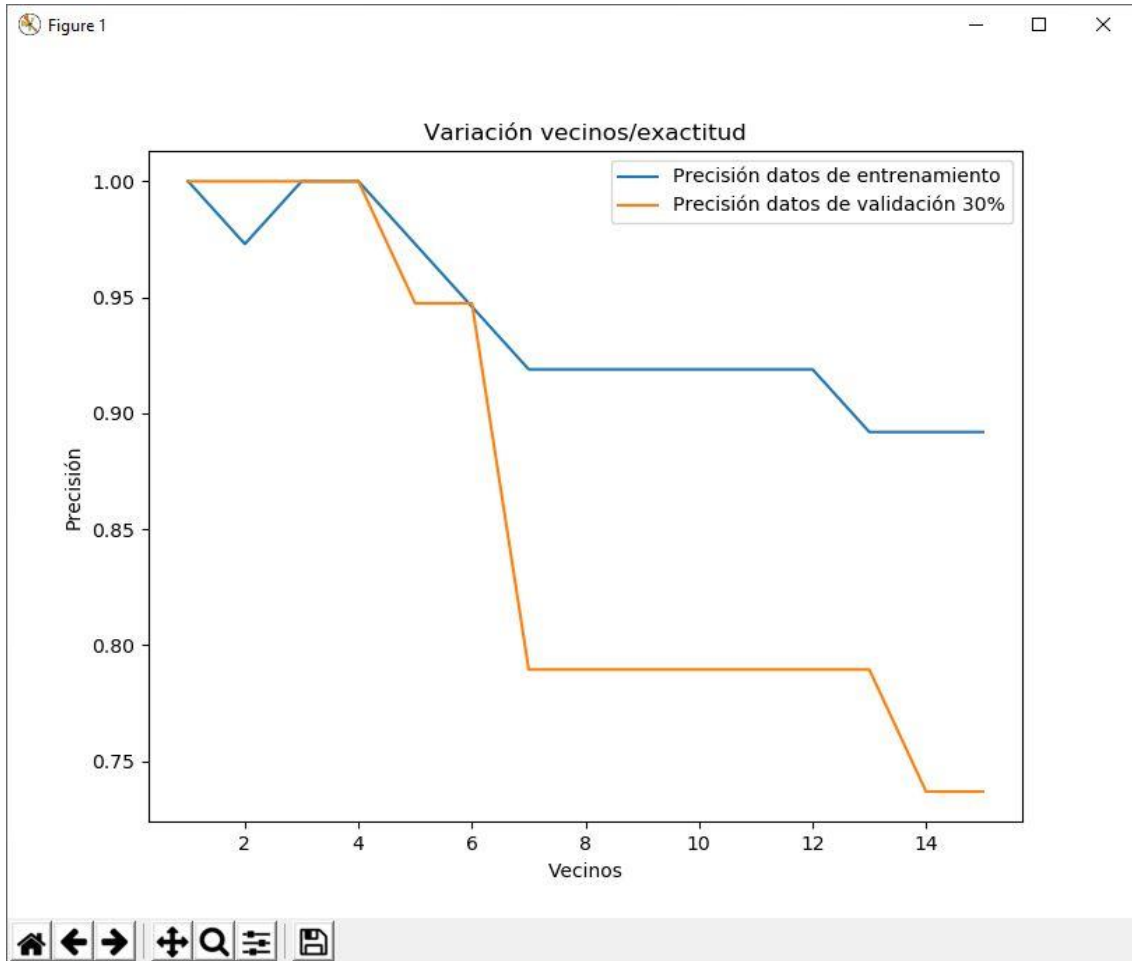


Figura 14: Gráfica de la precisión de los modelos de K-NN según el valor de k.

En el eje horizontal de las X, tenemos el valor de k con el que se ejecutó el modelo, con k en el rango [1,15]. En el eje vertical de las Y, tenemos la precisión del modelo, en rango de [0-1], siendo 1 el 100%, y 0 el 0%.

La gráfica muestra dos líneas decrecientes, porque gracias a la función `train_test_split` de la librería `model_selection` [35], hemos separado los datos base (valores de los indicadores de cada mes), en aleatoriamente dos tipos de datos, los datos de entrenamiento y los datos de validación. Los datos de validación son un 33% del total de todos los datos, por ello muestran una menor precisión, y los datos de entrenamiento el 67% restante. Lo importante de esta separación es mostrar de una manera más clara las variaciones que existen en los resultados y que explicamos a continuación.

Consideramos cuatro zonas de interés en la gráfica, observando los resultados que se obtienen en los siguientes rangos del eje de la X, es decir, de los valores de la k:

- 1) Rango de k entre [1,3]: es importante observar que nuestro modelo tiene cuatro clases o estrategias de inversión, por lo tanto, valores de k menores de cuatro,

ofrecen una alta precisión pero que no es útil ya que se consideran muy pocos casos similares (vecinos) en relación a las cuatro clases que existen, existe poca holgura o amplitud a la hora de examinar los vecinos cercanos.

- 2) Rango de k entre [4,7]: Este es el rango más importante con mayores valores de precisión (90-95%), y consideramos k=6 como el mejor valor de k, pues la gráfica muestra k=6 como un muy buen valor tanto en la parte de entrenamiento como en la parte de validación. También son buenos valores de k, k=4 y k=5, pero k=6 nos da la posibilidad de encontrar más holgura, es decir, más puntos vecinos que resultan interesantes para analizar la probabilidad de la predicción para cada clase en particular, sin renunciar a una alta precisión en el modelo.
- 3) Rango de k entre [8,12]: Aunque en este rango vamos perdiendo precisión, resulta interesante estudiarlo y ver las diferencias con el rango anterior, ya que cada vez obtenemos más amplitud u holgura a la hora de examinar los vecinos cercanos.
- 4) Rango de k entre [12,15]: La precisión empieza a disminuir, por lo tanto es un rango poco interesante.

Conclusión: cómo el usuario puede parametrizar el valor de k, le recomendamos una primera ejecución del modelo con k=6 y posteriormente que realice pruebas para que observe la variación de los resultados siendo consciente de la precisión/holgura según los valores de k.

*Código en la figura 15:*

```
99 #pasamos como argumento el valor de la K (por defecto k=6)
100 lak=sys.argv[2]
101
102 from sklearn.neighbors import KNeighborsClassifier
103 ##creamos el modelo
104 _neigh = KNeighborsClassifier(n_neighbors=int(lak))
105
106 #donde target=df['TIPO']
107 #entrenamos el modelo con las muestras y sus valores objetivo
108 _neigh.fit(samples, target)
109
110 #precisión del modelo
111 print(_neigh.score(samples,target))
112
113 #predecimos a qué clase pertenece el elemento (presente del mercado)
114 print(_neigh.predict([elementNormal]))
115
116 #calculamos la probabilidad de pertenencia del elemento presente
117 #a todas las clases de inversión
118 print(_neigh.predict_proba([elementNormal]))
119
```

Figura 15: Código de la ejecución del modelo K-NN y las funciones de probabilidad.

## Algoritmo de predicción: red neuronal.

Para implementar el modelo de inteligencia artificial en forma de red neuronal, que nos sirve para predecir el precio en el futuro, hemos utilizado el método Multi-layer Perceptron [36] (MLP) que nos ofrece Scikit-learn.

Es un algoritmo de aprendizaje supervisado que aprende una función

$f(\cdot): R^m \rightarrow R^o$ , gracias al entrenamiento de un conjunto de datos, donde ‘m’ es el número de dimensiones de entrada, en este caso son los siete parámetros que usa el algoritmo y ‘o’, es el número de dimensiones de la salida, en este caso es una dimensión que corresponde al máximo porcentaje de variación del precio del bitcoin.

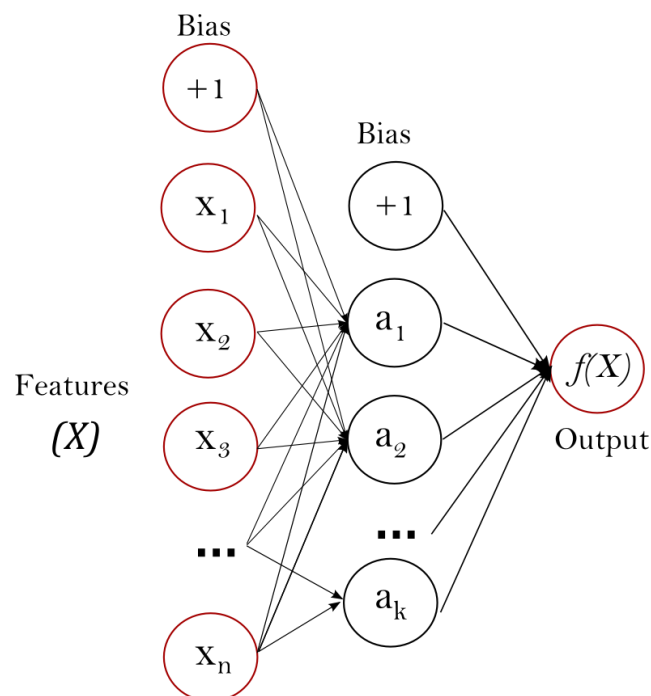


Figura 16: Esquema de la estructura de una red neuronal basada en una capa oculta de MLP.

En figura 16 se muestra la estructura de la red neuronal basada en una capa oculta de MLP. En nuestro sistema, las features serían los siete parámetros del algoritmo, y el output  $f(x)$ ; la predicción como máximo porcentaje de variación del precio.

En nuestro caso hemos usado el algoritmo de MLPRegressor [37], apoyándonos en la regresión para efectuar la predicción, modificando una serie de parámetros que no nos convencían en su configuración por defecto y explicamos a continuación:

Por defecto este algoritmo propone el tipo de solucionador ‘adam’ el cual está pensado para procesar cantidades de datos relativamente altas, cercanos a los miles de datos, y plantea una única capa oculta de neuronas con 100 unidades.

Nosotros implementamos el tipo de solucionador como ‘lbfgs’, diseñado para conjuntos menores de datos como el nuestro. Además, observamos que después de varias pruebas, reduciendo el número de neuronas de 100 a 20, el algoritmo proporcionaba

resultados más razonables y más similares en cada ejecución, pues es importante hacer referencia a que en cada ejecución del algoritmo, la predicción es diferente ya que usa una semilla distinta para crear la aleatoriedad en el tratamiento de datos. Esto se define en su parámetro de `random_state` y lo dejamos por defecto. Seguimos haciendo pruebas y observamos que añadiendo una nueva capa oculta de neuronas de otras 20 unidades seguíamos mejorando los resultados.

*Parámetros que usa el algoritmo:*

Entrada; cada dato contiene estos siete valores: (los cinco mismos que en K-NN)

- 1) RSI.
- 2) Diferencia en porcentaje del precio y la media móvil.
- 3) Meses hasta el siguiente halving.
- 4) Pérdidas de RSI en 2 meses.
- 5) Porcentaje de beneficio/pérdidas no ejecutado de la red.

Más dos parámetros auxiliares para reducir el [problema de la gran variación en el precio para hacer predicciones razonables](#):

- 6) Número de días que han pasado desde el presente.
- 7) Número de monedas recompensadas al minar un bloque.

Salida; porcentaje máximo de variación del precio.

*El problema de la gran variación en el precio para hacer predicciones racionales*

Nuestro objetivo (target) es averiguar qué valor tendría el porcentaje de variación máximo en los próximos dos años como mucho, respecto a los datos del presente. Es decir, pasados dos años o menos, predecir a qué precio se comercializaría el bitcoin en su máxima variación desde el momento presente. Esto es, en caso de que el valor aumente, cuanto porcentaje máximo cambiaría desde ahora, o en el caso contrario, cuanto porcentaje máximo disminuirá si el precio desciende.

Es importante observar que los datos que manejamos de este valor, recogidos en la variable `MAXBENEFICIOPER` tienen un rango muy amplio de  $[-80,36000]$  %. El hecho de que el rango de estos datos sea tan amplio es porque cuando el bitcoin estaba minándose antes del primer halving, su precio se situaba sobre los 10\$ y ocurrieron los siguientes eventos:

- Los máximos de junio de 2011 provocaron una caída del 80% del precio en seis meses (de 30\$ a 2\$ aproximadamente)
- Después de esta caída, el precio aumento en un 36000% desde finales de 2011 y principios de 2012 hasta finales de 2013 y principios de 2014 (de 2\$ hasta 1100\$)

En el momento presente un aumento de más del 2000% situaría en un futuro el precio del bitcoin en más de un millón de dólares, esto son cifras poco racionales, por ello ya partimos de la premisa de que los resultados en el rango de [2000-36000] no son válidos. Para ello pensamos en proporcionar al algoritmo dos variables nuevas que solucionases este desfase en los datos. Estas dos variables son las siguientes:

- 1) Número de días desde la fecha de estudio hasta el presente; así conseguimos proporcionar información útil al algoritmo, pues cuando esté procesando datos como los anteriormente mencionados, tendrá esta variable reguladora, que le indique, por ejemplo, que la anterior subida de más del 150% producida a principios de 2019 es más común y racional que una subida de más del 2000%. Entonces en los datos relativos ambas subidas de precio, tendremos una variable diferente; la de junio de 2011 tendrá el correspondiente número de días desde hoy hasta la fecha, mientras que la de 2019, tendrá otro número menor, porque lógicamente 2019 está más cercano en el tiempo que 2011.
- 2) Número de monedas que se recompensan al minar un bloque en cada halving: Esta variable reguladora tiene un funcionamiento muy similar a la anterior, en este caso a cada dato proporcionado al algoritmo le añadimos el número de monedas que era recompensado a los mineros en el periodo halving correspondiente. Esta variable sirve para diferenciar el comportamiento del precio en cada era.

A pesar de aumentar la precisión en el modelo gracias a introducir estas dos nuevas variables, seguíamos obteniendo resultados muy altos. Recordamos que el rango de estudio es de [-80,36000] y solo nos es válido el rango [-80,2000], entonces decidimos utilizar un bucle que fuese creando redes neuronales entrenadas con más de un 80% de precisión, hasta tener diez resultados válidos. De estos diez resultados, tomamos el menor de todos como la predicción más racional y es la que mostramos al usuario.

También consideramos que el tiempo de cálculo debía ser relativamente rápido para mostrarlo al usuario, es decir, que no pasase más de medio minuto desde que el usuario ejecuta la predicción hasta que se muestran los resultados. Finalmente conseguimos estos requisitos junto a predicciones razonables a pesar de la dificultad de la naturaleza del problema.

Código en la figura 17:

```
34
35 #guardamos nuestro elemento ya normalizado (la tupla del presente que queremos predecir)
36 elementNormal = df.iloc[56]
37
38 #y la eliminamos de todos los datos
39 df=df[:-1]
40
41 #para finalmente tener todas las muestras ya normalizadas
42 samples=df[['RSI','DIFFPERMA9','MONTHSTILHALVING','LOSSRSI2MONTHS','NETUPL','DIAS','RCOINS']]
43
44 #conseguimos 10 ejecuciones de la red neuronal que tienen un score > 80
45 for x in range(10):
46     while True:
47         from sklearn.neural_network import MLPRegressor
48         mlp = MLPRegressor(solver='lbfgs',hidden_layer_sizes=(20,20),max_iter=300)
49         mlp.fit(samples, target) #entrenamiento del modelo || target=df['MAXBENEFICIOPER']
50
51         if mlp.score(samples,target) > 0.80: #si el score es mayor que 80...
52             res=mlp.predict([elementNormal]) #...predecimos
53             print(res) #mostramos el resultado
54             break
55
56
```

Figura 17: Código del bucle que genera diez redes neuronales con 80% de precisión.

### 4.3) El simulador de inversión

Hemos desarrollado un accesible simulador de inversión, para que los usuarios puedan experimentar con él y guardar perfiles de inversión con dinero ficticio y así observar la evolución de sus ganancias o sus pérdidas según la evolución del mercado real.

Antes de crear un perfil de inversión, recomendamos a los usuarios utilizar la calculadora de posiciones en el mercado pues esta funciona como el núcleo del simulador.

La calculadora tiene tres datos de entrada, estos son; 1) Elegir si va a apostar en largo o en corto. 2) Introducir la cantidad de dinero ficticio en euros con el que se va a llevar a cabo la estrategia. 3) Introducir el valor del precio del bitcoin que servirá como salida del mercado, es decir, cuando el valor llegue a ese punto, la operación se cerrará.

Una vez que se introducen estas tres variables, la calculadora da como resultado las ganancias o las pérdidas en valor neto y en porcentaje que se obtendrían (sin calcular otros gastos relacionados con las comisiones de apertura de operación)

La calculadora sirve para fijar un objetivo razonable de beneficios en caso de que el mercado sea favorable a nuestra estrategia, pero también sirve para calcular un punto de stop-loss, es decir, un punto en el que se asumen pérdidas en la estrategia de inversión, pero se deja de perder capital ya que se cerraría la operación.

El código que hace los cálculos lo mostramos en la figura 18:

```

if (Number(target) < _precioServerEUR) {
  //largo en pérdidas, pues el precio actual es más grande que la estimación futura

  //el precio presente es el 100%, calculamos el nuevo porcentaje de variación con una regla de 3
  let percentage = ((Number(target) * 100) / Number(_precioServerEUR)).toFixed(2);

  //el porcentaje de variación es 100-percentage
  let finalPercentage = Number(100 - Number(percentage));

  //asignación de variables y redondeo de 2 cifras
  finalPercentage = finalPercentage.toFixed(2);
  recompensapServer = finalPercentage;

  //calculamos la recompensa y su porcentaje -> realmente son pérdidas por ello multiplicamos por -1
  recompensaServer = ((Number(requestQuery.ncap))*(recompensapServer))/100;
  recompensapServer = Number(recompensapServer) * -1;
  recompensaServer = Number(recompensaServer) * -1;
}
else{
  //largo en ganancias, pues el precio actual es más pequeño que la estimación futura

  //el precio presente es el 100%, calculamos el nuevo porcentaje de variación con una regla de 3
  let percentage = ((Number(target) * 100) / Number(_precioServerEUR)).toFixed(2);

  //el percentage es mayor que 100, por ello le restamos 100 para obtener la parte que ha variado
  let finalPercentage = Number(Number(percentage)-100);
  finalPercentage = finalPercentage.toFixed(2);

  //asignación de variables y cálculo de las ganancias
  recompensapServer = finalPercentage;
  recompensaServer = ((Number(requestQuery.ncap))*(recompensapServer))/100;
}
}
else{ //estamos ante un corto/venta -> los calculos siguen el mismo método que los largos
  activolServer=1;//variable de la interfaz
  if (Number(target) > _precioServerEUR) { //corto en pérdidas, pues el precio futuro es más grande que el presente...
  }else{ //corto en ganancias, pues el precio futuro es mas pequeño que el presente...
  }
}
}

```

Figura 18: Código de la calculadora de beneficios y pérdidas en el mercado.

#### 4.4) El análisis técnico y las noticias económicas:

La actual crisis económica del coronavirus nos ha enseñado que el análisis técnico no puede ir desligado de las noticias económicas. Pues en la semana del 9 al 15 de marzo de 2020, el valor del bitcoin llegó a caer más de 50%, y los indicadores técnicos no mostraban una sobrevaloración o sobrecompra en el precio, como en otros momentos del pasado.

En el apartado de nuestra aplicación llamado Covid-19, hemos recogido algunas noticias que posiblemente incitaron la caída de los precios. Estas noticias muestran caos general en el terreno económico. En el periódico new york times se hablaba de posible recesión económica, de planes billonarios de recuperación económica, y de caídas graves en los índices bursátiles. Además EEUU cerró los vuelos a Europa, mientras que en España e Italia comenzábamos la cuarentena obligatoria. Todo esto posiblemente generó un clima que favoreció a la venta de bitcoin, pues posiblemente los inversores necesitaban liquidez en la respectiva moneda de su país.

También en esas semanas descendió el valor del oro, la plata y el petróleo considerablemente.

A día de hoy seguimos sin un candidato claro para liderar un patrón económico mundial. El oro, después del Nixon Shock de 1971, perdió esa característica, entonces se declaró al dólar estadounidense como moneda de reserva de valor mundial y referencia en las transacciones internacionales, siendo vigente hasta hoy en día. Pero actualmente, después de las intensas caídas del valor del petróleo, después de la aparición y consolidación de las criptomonedas desde 2008 lideradas por bitcoin, después de que China anuncie su propia criptomoneda [38], con esta venidera crisis actual se inaugura un futuro que es incierto, donde el bitcoin podría ser aceptado cada vez más como intercambio de valor en cualquier parte del mundo, y donde probablemente entrarán en debate temas como la progresiva desaparición del dinero físico y el desarrollo de cada país de su propia criptomoneda centralizada.

Para hacernos una idea de la capitalización total del mercado del bitcoin, a grandes rasgos, estamos hablando de una criptomoneda que, a mediados de marzo de 2020, cuando los índices bursátiles cayeron y tocaron fondo debido a la crisis sanitaria, tenía una capitalización de mercado de cien billones de dólares estadounidenses [39]. Similar a la famosa empresa de ropa Nike, que también mostraba cien billones de capitalización bursátil en esos momentos.

## **5) Conclusión y trabajo futuro:**

En el momento presente existe bastante incertidumbre sobre qué estrategia de inversión es la más adecuada para llevar a cabo en el criptomercado. Una de las razones de por qué ocurre esto es por el impacto negativo que ha tenido la crisis sanitaria actual en la economía, pues en el pasado mes de marzo, provocó grandes caídas en los principales índices bursátiles de todo el mundo.

Una importante conclusión que hemos conseguido sobre este fenómeno es que los índices bursátiles más importantes y el mercado del bitcoin parecen estar correlacionados y en caso de crisis social-económica como esta, la criptomoneda no ha servido como refugio de valor inmediato a priori [40], pues su precio descendió fuertemente. Posteriormente, en el mes de abril después de las fuertes caídas, tanto índices bursátiles como la criptomoneda rebotaron y aumentaron su valor. En resumen, en el corto plazo estamos en tiempos de volatilidad e incertidumbre, aún nadie sabe a ciencia cierta si los mercados ya han tocado fondo y se va a recuperar el crecimiento económico después del gran parón de la economía en general, o si por el contrario, aún queda tiempo para ver nuevos mínimos en los mercados y fuertes ventas que vayan volver a hacer caer los valores.

Pero sin nos centramos en el mercado del bitcoin, llegamos a las siguientes conclusiones a través de ejecutar exitosamente los modelos de clasificación del mercado y de predicción:

- El modelo de clasificación desarrollado nos indica que es buen momento para iniciar una compra a corto plazo, con vistas a cerrar en menos de un año. Pues estamos ante un posible comienzo de mercado alcista. Las razones en las que nos basamos, son las siguientes:
  - a) En este mes de mayo acaba de empezar la cuarta era donde la recompensa a los mineros ha sido reducida a 6.25 bitcoin por bloque, por lo tanto se ha reducido la oferta en el mercado. Si sigue o aumenta la misma demanda en cuanto a volumen de compra, sería razonable un aumento en el precio.
  - b) Actualmente el precio se sitúa muy cerca de la media móvil de 9 meses, esto indica que si la media no se fractura y actúa como soporte, se confirmaría el mercado alcista.
  - c) Desde julio del año pasado parece ser que la tendencia ha sido invertir en corto. Puede que estos inversores ya hayan salido del mercado con beneficios y ahora cambie la tendencia al alza. El RSI marca alrededor de 50 puntos, lo que hace razonable esta teoría, al igual que el aumento del volumen de compras cuando el precio cayó bruscamente a mediados de mayo.
  - d) Además el modelo de predicción siempre nos está mostrando valores positivos, indicando que estamos en buenas condiciones para un aumento del precio en el futuro.

Riesgos que tiene esta estrategia:

- a) Aún es pronto para saber cómo va a impactar la minería al mercado con el nuevo protocolo de recompensa vigente desde mayo de 2020.
- b) Un buen indicador para esta estrategia sería ver una rotura en el canal bajista que se ha originado desde los máximos de 2018 que no se ha superado hasta ahora.
- c) Como comentábamos anteriormente, existe una aparente correlación con los índices bursátiles mundiales.

Trabajo futuro; consideramos tres puntos interesantes para seguir desarrollando en el futuro:

- Durante el paso del tiempo, cuando se vayan confirmando tendencias exitosas del pasado, se podría aumentar los casos de prueba con los nuevos datos para que los algoritmos dispongan de más casuística y más precisión.
- El simulador de inversión podría contener un futuro gestor de riesgos parametrizable por el usuario que mostrara su posición de stop-loss en el mercado, además de informar sobre las tarifas que se aplican sobre sus operaciones.
- Al existir una gran correlación entre bitcoin y la demás criptomonedas, se podría estudiar si siguiendo la tendencia del bitcoin, es más rentable invertir en otra criptomoneda, por ejemplo, teniendo una parte del capital de la inversión en bitcoin y otra parte más arriesgada pero con mejor previsión de rentabilidad en otra criptomoneda.

## Conclusions

At the present time, there is considerable uncertainty about which investment strategy is the most appropriate to start in the crypto-market. One of the reasons why this happens is due to the negative impact that the current health crisis has had on the economy, since in march, it caused large falls in the main stock market indices around the world.

An important conclusion that we have reached regarding this phenomenon is that the most important stock market indices and the bitcoin market seem to be correlated and in the event of a social-economic crisis such as this, the cryptocurrency has not served as a refuge of value [40] , since its price fell sharply. Subsequently, in the month of April after the sharp falls, both stock indices and the cryptocurrency rebounded and increased in value. In summary, in the short term we are in times of volatility and uncertainty, nobody yet knows for sure if the markets have already bottomed out and economic growth will recover after the great slowdown in the economy in general, or if the on the contrary, there is still time to see new lows in the markets and strong sales that will bring values down again.

But focusing on the bitcoin market, we reached the following conclusions through the successful execution of the market classification and prediction models:

- The classification model developed indicates that it is a good time to start a short-term purchase, with a view to closing in less than a year. Maybe we are facing a possible start of the bull market. The reasons on which we rely are the following:
  - a) In this month of may, the fourth era has just started where the reward to miners has been reduced to 6.25 bitcoin per block, therefore, the offer in the market has been reduced. If the same demand continues or increases in purchase volume, an increase in price would be reasonable.
  - b) Currently the price is very close to the 9-month moving average, this indicates that if the average does not fracture and acts as a support, the bull market would be confirmed.
  - c) Since july last year, it seems that the trend has been to invest short. These investors may have already left the market with profits and now the upward trend is starting. The RSI marks around 50 points, which makes this theory reasonable. Also is important the increase in the volume of purchases when the price fell sharply in mid-May.
  - d) Furthermore, the prediction model is always showing positive values, indicating that we are in good condition for a price increase in the future.

Risks of this strategy:

- a) It is still too early to know how mining will impact the market with the new reward protocol in force since May 2020.

- b) A good indicator for this strategy would be to see a break in the bearish channel that has originated from the 2018 highs that has not been exceeded so far.
- c) As we mentioned previously, there is an apparent correlation with world stock indices.

## Referencias Bibliográficas:

[1] Eichholz, L. (2020) Retail Interest in Bitcoin: Addresses with  $\geq 0.1$  BTC Reach All-Time High. *Medium*.

Figura 1: <https://studio.glassnode.com/metrics?a=BTC&m=addresses.NonZeroCount>

[2] Gómez, S. C., Castro, S., Presidente, G., Malagón, J., Técnico, V., Montoya, G., & Sánchez, A. (2017). Blockchain: mirando más allá del Bitcoin. *Semana Económica*, 1084(6).

[3] Scharnowski, S. (2020). Understanding bitcoin liquidity. *Finance Research Letters*, 101477.

Enlace al mercado: <https://www.coinbase.com/>

[4] TradingView; web de gráficas e indicadores: <https://www.tradingview.com/>

[5] Bianchi, D., & Dickerson, A. (2019). Trading volume in cryptocurrency markets. *WBS Finance Group Research Paper No. 254*.

Enlace interesante: <https://www.bitcointradevolume.com/>

[6] Jalan, A., Matkovskyy, R., & Urquhart, A. (2019). What If Bitcoin Futures Had Never Been Introduced? *Available at SSRN 3491272*.

Enlace a los mercados: <https://www.binance.com/es> <https://www.bitfinex.com/>

[7] Klumov, G. (2020). Why Internet Growth Is a Prime Cryptocurrency-Adoption Driver. *Cointelegraph*.

Enlace interesante a noticia:

[https://www.abc.es/tecnologia/redes/abci-51-por-ciento-poblacion-mundial-cuenta-acceso-internet-201906181500\\_noticia.html](https://www.abc.es/tecnologia/redes/abci-51-por-ciento-poblacion-mundial-cuenta-acceso-internet-201906181500_noticia.html)

[8] Crisis actual similar a la de 2008, enlace a la noticia:

<https://www.theguardian.com/business/2020/apr/08/the-2008-financial-crisis-will-be-seen-as-a-dry-run-for-covid-19-cataclysm>

[9] Kristoufek, L. (2020). Bitcoin and its mining on the equilibrium path. *Energy Economics*, 85, 104588.

Enlace interesante: <https://www.binance.vision/es/economics/the-2008-financial-crisis-explained>

[10] Calculadora de ahorros en bitcoin, enlaces a ejemplos citados:

<https://for-bitcoin.com/calculator/?amount=50.00&freq=month&month=January&day=01&year=2012>

<https://for-bitcoin.com/calculator/?amount=50.00&freq=month&month=January&day=01&year=2016>

- [11] Bitcoin Block Reward Halving Countdown: <https://www.bitcoinblockhalf.com/>
- [12] Meynkhart, A. (2019). Fair market value of bitcoin: halving effect. *Investment Management & Financial Innovations*, 16(4), 72.
- [13] Huang, J. Z., Huang, W., & Ni, J. (2019). Predicting bitcoin returns using high-dimensional technical indicators. *The Journal of Finance and Data Science*, 5(3), 140-155.
- [14] Liu, R., Wan, S., Zhang, Z., & Zhao, X. (2019). Is the introduction of futures responsible for the crash of Bitcoin? *Finance Research Letters*.
- [15] Nakano, M., Takahashi, A., & Takahashi, S. (2018). Bitcoin technical trading with artificial neural network. *Physica A: Statistical Mechanics and its Applications*, 510, 587-609.
- [16] Express; framework web: <https://expressjs.com/>
- [17] Node.js; servidor en JavaScript: <https://nodejs.org/en/>
- [18] Pandas, librería en Python; <https://pandas.pydata.org/>
- [19] Scikit-learn; <https://scikit-learn.org/stable/>
- [20] Librería JavaScript; Python Shell: <https://github.com/extrabacon/python-shell>
- [21] Paquete Mysql de Node: <https://www.npmjs.com/package/mysql>
- [22] Axios: paquete de Node.js; <https://www.npmjs.com/package/axios>
- [23] JQuery Ajax: <https://api.jquery.com/jquery.ajax/>
- [24] Embedded JavaScript templating; <https://ejs.co/>
- [25] SASS; <https://sass-lang.com/>
- [26] Volatilidad absoluta: <https://www.tradingview.com/script/H1z9wItE-Volatilidad-absoluta/>
- [27] Cálculo del RSI: Stock-Charts:  
[https://school.stockcharts.com/doku.php?id=technical\\_indicators:relative\\_strength\\_index\\_rsi](https://school.stockcharts.com/doku.php?id=technical_indicators:relative_strength_index_rsi)
- [28] Pérdidas de RSI en 2 meses:  
<https://www.tradingview.com/script/a1MgJUoT-P%C3%A9rdidas-de-RSI-en-2-m/>
- [29] Variación precio/media (nosotros no lo calculamos en valor absoluto):  
<https://www.tradingview.com/script/XX11WpUX-Percent-difference-between-price-and-MA/>
- [30] Peters, S. (2020). El halving abre un rally para el bitcoin: Los analistas de criptomonedas apuntan la posibilidad de que alcance los 100.000 dólares en 18 meses. *Inversión: el semanario líder de bolsa, economía y gestión de patrimonios*, (1186), 2.
- [31] Schultze-Kraft, R. (2019) Dissecting Bitcoin's Unrealised On-Chain Profit/Loss, *Medium*.
- [32] Preprocesador de datos; <https://scikit-learn.org/stable/modules/preprocessing.html>

[33] Scikit-learn - Algoritmo de vecinos cercanos:

<https://scikit-learn.org/stable/modules/neighbors.html>

Librería:

<https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>

[34] Matplotlib; gráfica para deducir el mejor valor de k: <https://matplotlib.org/>

[35] Librería model\_selection – separación de datos validación y prueba:

[https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.train\\_test\\_split.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.train_test_split.html)

[36] Redes neuronales: Scikit-learn:

[https://scikit-learn.org/stable/modules/neural\\_networks\\_supervised.html](https://scikit-learn.org/stable/modules/neural_networks_supervised.html)

[37] Algoritmo de red neuronal utilizado: MLPRegressor;

[https://scikit-learn.org/stable/modules/generated/sklearn.neural\\_network.MLPRegressor.html](https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html)

[38] Ting, P (2020) Former Bank of China President Says Digital Yuan Can Replace Cash, *Cointelegraph*.

[39] Johnson, J. (2020). Question: Do Bitcoin/Yen Traders Ever Take a Day Off? *Available at SSRN*.

[40] Conlon, T., Corbet, S., & McGee, R. J. (2020). Are Cryptocurrencies a Safe Haven for Equity Markets? An International Perspective from the COVID-19 Pandemic. *Research in International Business and Finance*, 101248.