



DESARROLLO DE UN SISTEMA DE GESTIÓN DEL CAPITAL BASADO EN REDES NEURONALES PARA OPERAR EN MERCADOS DE CRIPTODIVISAS

Máster en Ingeniería de Sistemas y de Control



Directores: Matilde Santos Peñas
Rodrigo Naranjo Mota

7 DE JUNIO DE 2022
UNIVERSIDAD COMPLUTENSE DE MADRID (UCM)
UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA (UNED)
Pedro Gabana Molina



Universidad Complutense de Madrid (UCM)

Universidad Nacional de Educación a Distancia (UNED)

Máster en Ingeniería de Sistemas y de Control

Curso 2021 – 2022, Trabajo Fin de Máster

**DESARROLLO DE UN SISTEMA DE GESTIÓN DEL CAPITAL BASADO EN REDES NEURONALES
PARA OPERAR EN MERCADOS DE CRIPTODIVISAS**

Pedro Gabana Molina

Directores: Matilde Santos Peñas

Rodrigo Naranjo Mota

Junio 2022



UNED

Autorización

Autorizamos a la Universidad Complutense y a la UNED a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a sus autores, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firmado:

Firma del alumno

Agradecimientos

No querría terminar esta etapa de mi vida sin agradecer todo el esfuerzo y comprensión a toda la gente que ha sabido estar ahí para llevarme y apoyarme.

En primer lugar, quiero dar las gracias a Matilde y a Rodrigo por ofrecerme esta oportunidad de formación y poder trabajar con vosotros. Dándome vuestro consejo y apoyo desde la distancia. Sin vosotros este trabajo no hubiera sido posible.

Además, quiero agradecer también todo el apoyo a los profesores del máster, que siempre han estado ahí dispuestos a ayudar cuando fuera necesario.

También quiero dar las gracias a mi Madre por todo su apoyo incondicional a lo largo de estos años.

Además, me gustaría dar las gracias a mis amigos, por su comprensión en esos largos días de estudio y trabajo en los que no he podido pasar tanto tiempo con ellos como hubiera querido.

Y finalmente, me gustaría dar las gracias a mi novia, cuyo apoyo emocional ha sido y es inestimable, incluso en los momentos más difíciles.

Resumen del proyecto.

Este trabajo titulado “*DESARROLLO DE UN SISTEMA DE GESTIÓN DEL CAPITAL BASADO EN REDES NEURONALES PARA OPERAR EN MERCADOS DE CRIPTODIVISAS*” se ha desarrollado como Proyecto Fin de Máster para el Máster interuniversitario “*Ingeniería de Sistemas y Control*” impartido por la Universidad Complutense de Madrid (UCM) y la Universidad Nacional de Educación a Distancia (UNED).

En este trabajo se plantea un procedimiento para desarrollar sistemas basados en redes neuronales que gestionen carteras de criptomonedas.

El estudio se ha centrado en el análisis del mercado del bitcoin al ser esta la criptomoneda más importante en la actualidad. Para ello, teniendo en cuenta los datos históricos del mercado, se han desarrollado herramientas para el tratamiento de los datos, también se ha desarrollado una metodología para identificar las tendencias que se han producido en un periodo de tiempo.

Se han abordado dos estrategias de entrenamiento de las redes neuronales, el aprendizaje supervisado y el aprendizaje reforzado.

Para el aprendizaje supervisado se han utilizado índices para evaluar los entrenamientos de las redes neuronales (tasa de acierto, error cuadrático medio, error absoluto medio, error relativo medio), también se ha planteado un índice adaptado al problema a resolver. Además, se han considerado distintas configuraciones de redes neuronales y se han utilizado distinto número de datos de entrada a las redes.

El aprendizaje supervisado se ha empleado para tratar de predecir tanto el precio del día siguiente al valor más actual de los datos de entrada como la evolución en la siguiente sesión (subida o bajada de precio).

A partir de las previsiones de la red se ha montado un sistema de gestión del capital que en función de la predicción invierta en el mercado del Bitcoin. Posteriormente se ha planteado un sistema experto que actúa por encima del sistema de gestión del capital y que en base a índices bursátiles evita situaciones de riesgo reduciendo el riesgo y mejorando el beneficio. Para evaluar los resultados de los distintos sistemas desarrollados se han utilizado distintas métricas (rentabilidad, profit factor, máximo draw down, ganancia media, pérdida media).

En el aprendizaje reforzado se han utilizado distintas funciones de recompensa para entrenar las redes (basadas en la rentabilidad de la sesión y basadas en la certeza de la decisión). A partir de las predicciones de las redes neuronales se han planteado sistemas de gestión del capital que actúan en función de las predicciones de las redes. Los resultados obtenidos con estos sistemas se han evaluado con las mismas métricas que el aprendizaje supervisado.

Palabras claves: Mercado de valores, criptomonedas, Redes neuronales, aprendizaje supervisado, aprendizaje reforzado.

Abstract.

This work entitled “*DESARROLLO DE UN SISTEMA DE GESTIÓN DEL CAPITAL BASADO EN REDES NEURONALES PARA OPERAR EN MERCADOS DE CRIPTODIVISAS*” has been developed as a Master Thesis for the interuniversity master’s degree “*Ingeniería de Sistemas y Control*” by the Complutense University of Madrid (UCM) and the National University of Distance Education (UNED).

This paper proposes a procedure for developing systems based on neural networks to manage cryptocurrency portfolios.

The study focused on the analysis of the bitcoin market since this is currently the most important cryptocurrency. To do this, taking into account historical market data, tools have been developed for data processing, and a methodology has also been developed to identify trends that have occurred over a period of time.

Two neural network training approaches, supervised learning and reinforcement learning, have been used.

For supervised learning, indices have been used to evaluate the training of the neural networks (hit rate, mean square error, mean absolute error, mean relative error), and an index adapted to this particular problem has also been proposed. In addition, different configurations of neural networks have been considered and different numbers of input data to the networks have been used.

Supervised learning has been used to predict both the price of the day following the most current value of the input data and the evolution in the next session (price rise or fall).

Based on the predictions of the network, a capital management system has been set up which, depending on the prediction, invests in the Bitcoin market. Subsequently, an expert system has been proposed that acts over the capital management system and, based on stock market indices, avoids risk situations by reducing risk and improving profit. In order to evaluate the results of the different systems developed, different metrics have been used (profitability, profit factor, maximum draw down, average profit, average loss).

In reinforcement learning, different reward functions have been used to train the networks (based on the profitability of the session and based on the certainty of the decision). Based on the predictions of the neural networks, capital management systems have been proposed that act on the predictions of the networks. The results obtained with these systems have been evaluated with the same metrics as supervised learning.

Key words: Stock market, cryptocurrencies, neural networks, supervised learning, reinforced learning.

Índice

1.	CAPÍTULO 1: Introducción.	6
1.1.	Descripción del problema abordado.	6
1.2.	Metodología.....	7
1.3.	Técnicas y bases de datos utilizadas.	7
1.4.	Objetivo general y objetivos específicos.	8
1.5.	Estructura de la memoria.	8
2.	CAPÍTULO 2: Conceptos teóricos.....	10
2.1.	Revisión de conceptos teóricos.....	10
2.1.1.	Candle	10
2.1.2.	Tipos de inversiones.	12
2.1.3.	Redes Neuronales Artificiales con aprendizaje supervisado.....	13
2.1.4.	Redes Neuronales Artificiales con aprendizaje por refuerzo.	13
2.2.	Estado del arte	15
2.2.1.	Sistemas inteligentes de gestión del capital en base a reglas y lógica fuzzy	16
2.2.2.	Tratamiento de los datos.	17
2.2.3.	Redes neuronales para predicción de precios.	17
2.2.4.	Predicción de tendencias en el mercado de Bitcoin con redes neuronales.	18
2.2.5.	Gestión de carteras de criptomonedas mediante técnicas de Machine Learning. 19	
3.	CAPÍTULO 3: Datos.....	21
3.1.	Datos económicos y herramientas para su obtención	21
3.1.1.	NinjaTrader.....	21
3.1.2.	Alpha Vantage.....	23
3.2.	Datos y preparación de los datos	23
3.2.1.	Criptomonedas	24
3.2.2.	Activos	24
3.3.	Medidas del error.	25
3.4.	Estimación del comportamiento de sistemas de gestión del capital.	26
4.	CAPÍTULO 4: Predicción de precios de criptomonedas con redes neuronales MLP	29
4.1.	Predicción de valores con NN	29
4.2.	Predicción de tendencias con NN.....	33
5.	CAPÍTULO 5: Sistema de gestión del capital con redes MLP.	37
5.1.	Sistema de gestión del capital.....	37
5.2.	Resultados operando en largo.	38

5.3.	Resultados operando en corto.....	41
5.4.	Resultados operando en largo y en corto.	44
5.5.	Comparación de las tres estrategias.....	46
5.6.	Sistema experto.....	48
5.6.1.	Configuración del sistema experto.	48
5.6.2.	Resultados del sistema experto.	50
5.7.	Análisis del sistema de gestión del capital.	51
6.	CAPÍTULO 6: Sistema de gestión del capital en base a aprendizaje por refuerzo.	52
6.1.	Sistema de recompensa del entrenamiento por refuerzo.	52
6.1.1.	Recompensa en función del beneficio obtenido.	53
6.1.2.	Recompensa en función de la decisión adoptada.	55
6.2.	Análisis de los sistemas de gestión basados en redes neuronales con aprendizaje por refuerzo.	58
7.	CAPÍTULO 7: Conclusiones y trabajos futuros.	60
7.1.	Conclusiones.	60
7.1.1.	Conclusiones obtenidas del estudio de sistemas de capital con redes neuronales con aprendizaje supervisado.	60
7.1.2.	Conclusiones obtenidas del estudio de sistemas entrenados con aprendizaje por refuerzo.	61
7.2.	Trabajos futuros.	62
8.	CAPÍTULO 8: Bibliografía	64
9.	Listado siglas, abreviaturas y acrónimos.	66

Índice de figuras

Figura 1, Metodología secuencial de tareas.....	7
Figura 2, Estructura de un candle [3].	10
Figura 3, Representación de un gap en un candle [3].	11
Figura 4, Situaciones destacables en un candle [3].	11
Figura 5, Aprendizaje supervisado para predicción [4].	13
Figura 6, Interacción agente ambiente [5].	14
Figura 7, Proceso de recompensa [5].	14
Figura 8, Fórmula de entrenamiento Q-learning.	15
Figura 9, Ventana principal de NinjaTrader.	21
Figura 10, Establecimiento de la conexión a NinjaTrader.....	22
Figura 11, Herramienta de descarga y exportación de datos económicos de NinjaTrader.	22
Figura 12, Diagrama de velas japonesas en NinjaTrader.	23
Figura 13, Logo de Alpha Vantage.....	23
Figura 14, Función para preparar datos para el entrenamiento de redes neuronales desarrollada en Matlab.....	23
Figura 15, Representación gráfica del Drawdown.	27
Figura 16, Predicción de valores con la MLP.	30
Figura 17, Comparación de errores cuadráticos medios en la predicción de valores.	31
Figura 18, Comparación de errores absolutos medios predicción de valores.	32
Figura 19, Comparación de errores relativos medios predicción de valores.	32
Figura 20, Representación gráfica de la predicción de tendencias.....	34
Figura 21, Comparación de tasas de acierto en predicción de tendencias.....	35
Figura 22, Comparación de tasas sintéticas de éxito en predicción de tendencias.	36
Figura 23, Rentabilidad de los sistemas entrenados mediante aprendizaje supervisado operando en largo.....	39
Figura 24, Máximo DrawDown de los sistemas entrenados mediante aprendizaje supervisado operando en largo.....	40
Figura 25. Profit factor de los sistemas entrenados mediante aprendizaje supervisado operando en largo.....	40
Figura 26, Ganancia media de los sistemas entrenados mediante aprendizaje supervisado operando en largo.....	41
Figura 27, Pérdida media de los sistemas entrenados mediante aprendizaje supervisado operando en largo.....	41
Figura 28, Rentabilidad de los sistemas entrenados mediante aprendizaje supervisado operando en corto.	43
Figura 29, Máximo DrawDown de los sistemas entrenados mediante aprendizaje supervisado operando en corto.	43
Figura 30, Profit factor de los sistemas entrenados mediante aprendizaje supervisado operando en corto.	44
Figura 31, Rentabilidad de los sistemas operando en largo y en corto.....	45
Figura 32, Máximo DrawDown de los sistemas operando en largo y en corto.....	46
Figura 33, Profit factor de los sistemas operando en largo y en corto.	46
Figura 34, Evolución del capital en función de la estrategia adoptada.	47
Figura 35, Evolución del capital en función de la estrategia.	47
Figura 36, MFE frente a MAE en largo y en corto en el periodo de selección de redes neuronales.....	50

Figura 37, Función recompensa aprendizaje por refuerzo según resultado	53
Figura 38, Función recompensa aprendizaje por refuerzo según acción	53
Figura 39, Rentabilidad de los sistemas con aprendizaje por refuerzo ponderando el resultado.	54
Figura 40, Máximo DrawDown de los sistemas con aprendizaje por refuerzo ponderando el resultado.	54
Figura 41, Profit factor de los sistemas con aprendizaje por refuerzo ponderando el resultado.	54
Figura 42, Evolución del capital en los sistemas con aprendizaje por refuerzo ponderando el resultado.	55
Figura 43, Rentabilidad de los sistemas con aprendizaje por refuerzo ponderando la decisión.	56
Figura 44, Máximo DrawDown de los sistemas con aprendizaje por refuerzo ponderando la decisión.	57
Figura 45, Profit factor de los sistemas con aprendizaje por refuerzo ponderando la decisión.	57
Figura 46, Evolución del capital en los sistemas con aprendizaje por refuerzo ponderando la decisión.	58

Índice de tablas

Tabla 1, Tabla de resultados de la selección de redes neuronales para la predicción de valores.	31
Tabla 2, Resultados de predicción de tendencias con margen 1%	34
Tabla 3, Resultados de predicción de tendencias con margen del 2%.....	35
Tabla 4, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en largo.	39
Tabla 5, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en corto.....	42
Tabla 6, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en largo y en corto.	45
Tabla 7, Tabla de resultados con el sistema experto operando en largo y en corto.	50
Tabla 8, Tabla de resultados del sistema entrenado mediante aprendizaje reforzado basando la recompensa en el beneficio.	53
Tabla 9, Tabla de resultados del sistema entrenado mediante aprendizaje reforzado basando la recompensa en la decisión.	56

1. CAPÍTULO 1: Introducción.

El objetivo del trabajo es llevar a cabo una investigación en el ámbito de la gestión de activos basado en técnicas inteligentes, concretamente utilizando redes neuronales.

La motivación del trabajo consiste en ampliar la línea de investigación propuesta por [1], [2] y [3] con el fin de aplicar el desarrollo descrito en esos artículos a la investigación en otros activos distintos, como son las criptomonedas.

Se va a ampliar la metodología que se ha venido utilizando para poder desarrollar un sistema que opere en mercados de criptomonedas. El objetivo es que el sistema financiero inteligente aquí propuesto sea capaz de operar en el mercado de criptomonedas y que obtenga unos beneficios económicos razonables minimizando el riesgo de las inversiones.

Los sistemas que se van a desarrollar en este trabajo van a estar basados en redes neuronales, probando así la validez de esta técnica inteligente del soft computing en este ámbito de aplicación.

1.1. Descripción del problema abordado.

El diseño y desarrollo de sistemas inteligentes de inversión en el mercado de las criptomonedas se trata en este trabajo desde la perspectiva del Machine Learning, con la hipótesis de que las redes neuronales son una herramienta que puede resultar adecuada a la hora de operar y prestar asistencia en mercados de valores. Por lo tanto, se propone llevar a cabo una serie de estudios para comprobar la idoneidad del uso de redes neuronales como medio de modelado de mercados financieros.

Para abordar dicho problema se proponen dos vías de trabajo:

- **Entrenamiento supervisado de redes neuronales para predicción de tendencias del mercado**, con diferentes estructuras, comprobando si la modificación de la configuración de la red afecta al resultado del modelado. Para ello se propone llevar a cabo un desarrollo de software que permita agilizar los procesos de entrenamiento y configuración de las diferentes redes. Una vez desarrollado dicho software, se llevará a cabo un estudio para comprobar si es posible alcanzar una configuración óptima de la red neuronal para un problema dado, y cómo afecta la modificación de los distintos parámetros de la configuración a la capacidad de predicción de las redes. Posteriormente, se implementará un sistema de gestión del capital que tome cuenta de las predicciones de las redes para la toma de decisiones a la hora de operar en el mercado.
- **Generar un sistema de gestión de capital en mercados financieros mediante técnicas de aprendizaje por refuerzo**. Se basará en redes neuronales, y se analizarán distintas situaciones para comprobar su funcionamiento dentro de un mercado específico. De esta forma se llevará a cabo un estudio con el fin de comprobar cómo la configuración del aprendizaje por refuerzo afecta al funcionamiento posterior de estos sistemas.

1.2. Metodología.

Para el tratamiento del problema se ha llevado a cabo un desarrollo **secuencial** de las tareas indicadas en el siguiente esquema de la Figura 1.

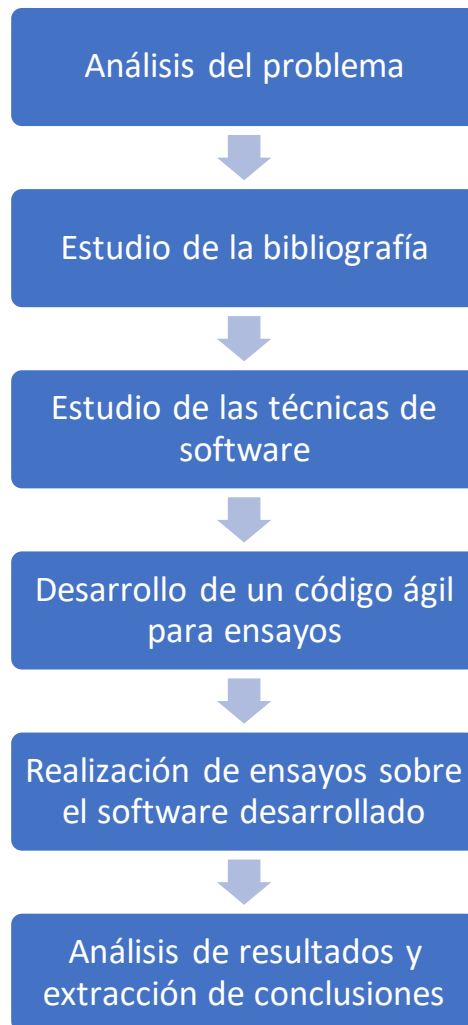


Figura 1, Metodología secuencial de tareas.

Estas tareas han de cumplirse **secuencialmente**, de tal manera que una vez finalizadas se dará por concluido el desarrollo de este trabajo. Estas tareas estarán presentes a lo largo de todo el trabajo y son la base de actuación sobre la que se asienta este.

1.3. Técnicas y bases de datos utilizadas.

En todas las fases del trabajo es preciso aplicar diversas herramientas, en concreto para el desarrollo del presente trabajo ha sido necesario utilizar el siguiente software:

- **MATLAB:** Se ha utilizado este lenguaje de programación para el desarrollo de las redes neuronales. Para el desarrollo del código se han utilizado scripts de MATLAB, combinados con herramientas incluidas en este lenguaje como “nnstart”, “Econometric Modeler”, “Regression Learner” y “AppDesigner”.
- **Bases de datos de criptomonedas:** Las bases de datos permiten obtener la información bursátil de las criptomonedas. Se han utilizados varias bases de datos y herramientas

para obtener la información, como NinjaTrader que es un analizador de datos que se conecta vía Internet a diversas bases de datos que muestran evoluciones de precios en tiempo real en diversos formatos y para diversos activos.

- **Microsoft Excel:** este software se ha utilizado para la representación gráfica de los resultados y permitir así extraer conclusiones más relevantes que las extraídas analizando simplemente los resultados de los ensayos.

1.4. Objetivo general y objetivos específicos.

El **objetivo general** y principal de este trabajo es llevar a cabo un estudio de diferentes técnicas de gestión de activos financieras basadas en redes neuronales artificiales y aplicarlo a mercados de criptomonedas (específicamente al Bitcoin), buscando que el sistema inteligente desarrollado sea capaz de predecir la evolución del mercado de activos para obtener el mayor beneficio económico, reduciendo al máximo posible el riesgo asumido.

Para cumplir con este objetivo general se han propuesto los siguientes **objetivos específicos**:

- **Estudio del estado del arte y análisis de las técnicas de modelado de mercados financieros**, para comprobar si realmente el desarrollo en base a redes neuronales es una solución adecuada.
- **Profundización en la bibliografía especializada en el uso de redes neuronales artificiales para la gestión de criptomonedas** con el fin de orientar el trabajo hacia las tipologías de redes que mejor encajen con el problema abordado.
- **Familiarización con el software a emplear en el trabajo**, en concreto, Matlab, Excel y NinjaTrader.
- **Analizar las posibilidades de modelado de mercados financiero en base a redes neuronales**, estudiando cómo afecta la configuración y el número de datos estudiados, así como el tipo de red entrenada.
- **Desarrollar una herramienta de software adecuado para simplificar los procesos de creación y entrenamiento de redes neuronales**, con el fin de simplificar el proceso y hacer más accesible los desarrollos abordados en este trabajo.
- **Desarrollar un sistema de gestión de activos** en base a las predicciones de la red neuronal desarrollada mediante aprendizaje supervisado, y extraer conclusiones que permitan mejorar la comprensión de la materia.
- **Analizar las posibilidades del aprendizaje de redes neuronales por refuerzo** a la hora de entrenar un sistema para operar en mercados de criptomonedas.
- **Desarrollar software para el entrenamiento de redes neuronales por refuerzo.**
- Llevar a cabo un **análisis de los parámetros que influyen en el aprendizaje por refuerzo.**
- **Valorar los resultados obtenidos con redes neuronales entrenadas mediante aprendizaje por refuerzo** y extraer conclusiones relevantes.

1.5. Estructura de la memoria.

La memoria se estructura en varios capítulos, que son los siguientes:

- **Introducción:** en este capítulo esboza una idea del problema planteado y de cómo se va a abordar a lo largo del trabajo.

- **Conceptos teóricos:** en este capítulo se explican de manera sencilla y resumida ciertos conceptos que son necesarios para comprender el trabajo.
- **Datos:** en este capítulo se describe cómo se han obtenido los datos utilizados y cómo se van a tratar a lo largo del trabajo.
- **Estudio sobre redes neuronales Perceptrón Multicapa (Multilayer Perceptron, MLP):** en este capítulo se explicará cómo se ha llevado a cabo el estudio con redes neuronales tipo MLP y cuáles han sido los resultados y su análisis.
- **Sistema de gestión del capital basado en redes MLP:** en este capítulo, partiendo de las redes MLP entrenadas, se desarrollará un sistema de gestión del capital que permita determinar qué hacer en el mercado de valores en función de la predicción de la red neuronal. Posteriormente se evalúan los resultados obtenidos por distintas redes.
- **Sistema de gestión del capital en base a aprendizaje por refuerzo:** En este capítulo se estudian distintos tipos de aprendizaje por refuerzo con el fin de determinar cómo afectan los distintos aspectos puestos en juego a la hora de entrenar la red.
- **Conclusiones:** en este capítulo se detallan las diferentes conclusiones a las que ha llevado el desarrollo del trabajo y las líneas de trabajo futuro.

2. CAPÍTULO 2: Conceptos teóricos.

Para el desarrollo del trabajo ha sido preciso indagar en la bibliografía existente sobre el modelado de mercados financieros, no tanto el modelado clásico sino el basado en técnicas de soft computing. Por lo tanto, este capítulo se va a dividir en dos apartados; primero se tratan las técnicas a utilizar y después se comenta la bibliografía consultada.

2.1. Revisión de conceptos teóricos.

Se va a exponer lo que son los “candle” o diagrama de velas japonesas, los tipos de inversiones que puede haber con criptomonedas, los principios básicos de funcionamiento del entrenamiento de redes neuronales mediante aprendizaje supervisado y mediante aprendizaje por refuerzo.

2.1.1. Candle

Los “candle” o diagramas de velas japonesas son ampliamente utilizados en la bibliografía sobre mercados financieros, generalmente para representar de una manera simplificada una serie de datos económicos de interés para conocer la evolución del precio de un activo a lo largo de un periodo de tiempo, que puede ser segundos, minutos, días, semanas, meses o años. A continuación, se muestran dos velas en la Figura 2.




Figura 2, Estructura de un candle [3].

Cada vela está compuesta por 4 precios: apertura, cierre, mayor y menor, significando cada uno lo que se especifica a continuación:

- **Apertura:** precio al que se inicia la puja del activo.
- **Cierre:** precio de finalización de la puja del activo.
- **Mayor:** precio máximo que ha alcanzado el activo durante el periodo.
- **Menor:** precio mínimo que ha alcanzado el activo durante el periodo.

El color de la vela indica si el precio de cierre es mayor que el de apertura (vela blanca) o menor (vela negra). En este tipo de representación puede haber casos en los que sucedan situaciones aparentemente inexplicables, como la que puede observarse en la siguiente imagen Figura 3, en la que aparece un “gap”.

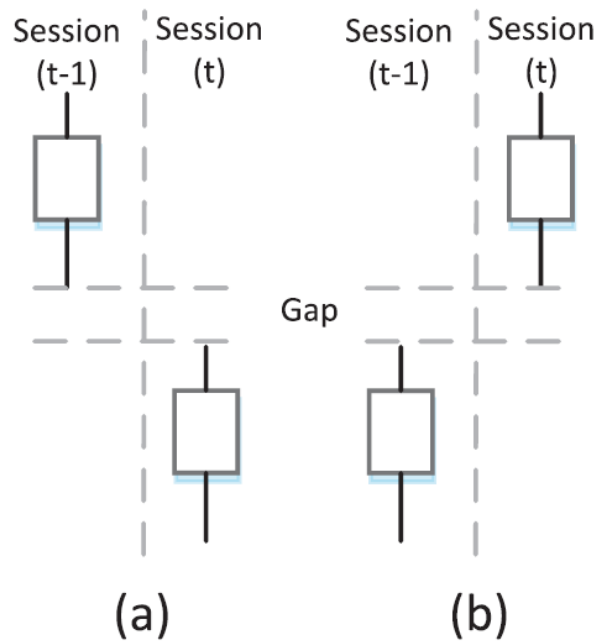


Figura 3, Representación de un gap en un candle [3].

El “Gap” presente entre los diferentes precios puede aportar mucha información económica. Se debe a que los precios de las dos sesiones estudiadas han estado muy alejados, lo que indica tendencias claramente marcadas. Mientras en el caso (a) es posible observar una tendencia descendente, en el caso (b) la tendencia ascendente es evidente.

Además del “Gap” especificado anteriormente, también es posible encontrar situaciones como las mostradas en la Figura 4.




Figura 4, Situaciones destacables en un candle [3].

En el caso (a) de la Figura 4 es posible observar como todas las fluctuaciones de precios se encuentran comprendidas entre el margen de precio de apertura y de cierre. Se puede deducir así que la evolución del precio a lo largo de la sesión no ha presentado fluctuaciones muy elevadas. En el caso (b) de la Figura 4 se puede observar que, a pesar de los precios de apertura y cierre, la sesión se ha caracterizado por ser altamente fluctuante. La situación observada en el caso (c) de la Figura 4 muestra un atisbo de recuperación, pudiendo observarse que el precio de cierre cambia de tendencia.

En este trabajo únicamente va a considerarse el precio de cierre del activo ya que, en situaciones normales, el precio de cierre de un periodo es el mismo que el de apertura del siguiente, por lo que a este respecto no se pierde información. De la misma forma, se puede considerar que durante el periodo no se va a operar, por lo tanto a efectos prácticos la fluctuación de precios a lo largo del periodo no trasciende, ya que lo que se busca es una operatividad a largo plazo.

Esto muestra la procedencia de los datos a emplear, así como la representación habitual dentro de la bibliografía y las razones que justifican la adopción del precio de cierre como variable a considerar.

2.1.2. Tipos de inversiones.

A la hora de analizar una inversión se puede hacer desde distintos puntos de vista. Es frecuente las operaciones “en largo”, que consisten en la compra de un activo financiero que pasa a ser propiedad del sujeto que realizó la compra y que puede venderlo (o intentar venderlo) cuando desee. El beneficio o la pérdida vendrá dado por el diferencial de precio que consiga el poseedor del activo cuando lo vende con respecto al precio que pagó por dicho activo en el momento de su compra.

Sin embargo, éste no es el único tipo de operación disponible, también es posible operar “en corto”. En este caso el comprador no adquiere un activo, sino que adquiere un compromiso con respecto al vendedor. Este compromiso viene dado por un número de activos que el comprador deberá darle al vendedor en una fecha determinada; a cambio, el comprador adquiere una retribución. Sin embargo, no hay que olvidar que el comprador está obligado a proporcionarle una serie de activos al vendedor en una fecha aunque, lógicamente, el comprador podrá adquirir dicho activo antes de que venza esa fecha.

De esta forma se puede deducir que cada tipo de inversión se utilizará en función de las expectativas del mercado. Así, cuando la expectativa sea alcista (que el precio del activo va a subir), la tendencia será adquirir dicho activo, es decir, invertir “en largo”. Mientras que si la expectativa es bajista (que el precio del activo va a caer) la tendencia será invertir “en corto”.

Hay un detalle muy importante que diferencia los dos tipos de inversiones, el riesgo potencial en relación con el beneficio. A la hora de invertir en largo, el comprador adquiere un activo, es decir, tiene algo en propiedad y él decide cuando lo vende, por lo que el beneficio puede llegar a ser virtualmente infinito y el riesgo está claramente acotado ya que, si las cosas le fueran realmente mal, no puede perder más dinero del que ha pagado inicialmente por el activo. Como es lógico, esto ocurre exactamente al contrario a la hora de invertir en corto, ya que el riesgo es virtualmente infinito. Si el precio del activo alcanzara un valor infinito, el comprador tendría que abonar dicha cantidad y, además, el beneficio potencial nunca podrá ser superior al precio del activo en el momento que lo compró.

La razón por la que se utilizan y se permiten las operaciones en corto es que agilizan mucho los flujos de capitales. En este trabajo se van a utilizar sobre todo operaciones en largo, pero también en corto.

2.1.3. Redes Neuronales Artificiales con aprendizaje supervisado.

Con el aprendizaje supervisado los algoritmos aprenden iterativamente de los datos que se les presentan [4]. En la Figura 5 se muestra que puede utilizar para predecir resultados conocidos, como patrones en una imagen o diferenciar objetos. En este trabajo aprenderá un modelo de comportamiento del mercado que sirva para predecir la evolución de precios de un activo.

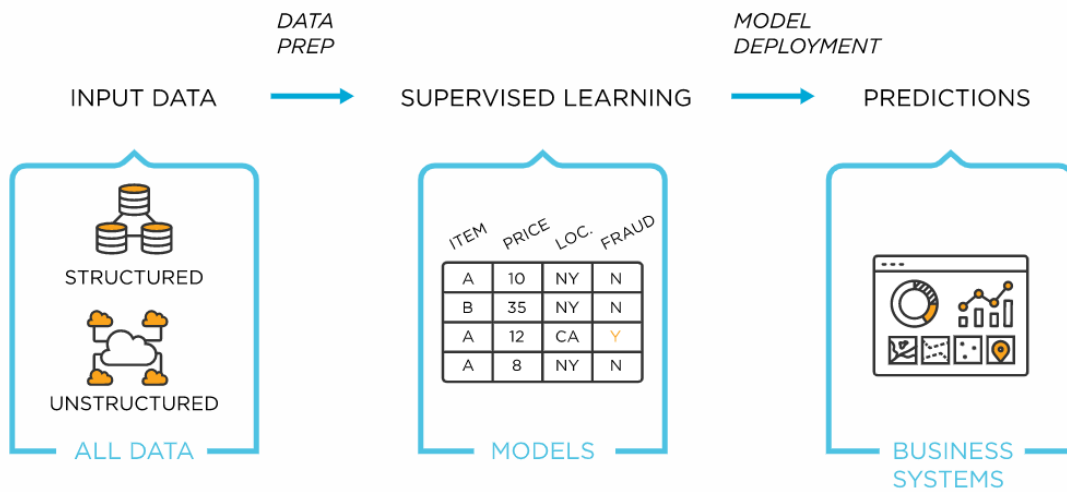


Figura 5, Aprendizaje supervisado para predicción [4].

Se puede utilizar para clasificación y regresión. Por un lado, la clasificación consiste en que el algoritmo relacione los datos de entrada de acuerdo con variables discretas o etiquetas, mientras que en la regresión el algoritmo predice un valor de salida a partir de un rango continuo de valores

En la regresión, el algoritmo necesita identificar una relación funcional entre los parámetros de entrada y de salida. El valor de salida no es discreto, como en la clasificación, sino que es una función de los parámetros de entrada. La precisión de un algoritmo de regresión se calcula en función de la desviación entre la salida real y la salida obtenida. Las redes que se van a entrenar durante el desarrollo de este trabajo son de este tipo, ya que los datos de precios son variables continuas.

2.1.4. Redes Neuronales Artificiales con aprendizaje por refuerzo.

Se trata de un método similar al de aprendizaje supervisado, la única diferencia es que no se dispone del resultado exacto que debería proporcionar la red neuronal para el entrenamiento, si no que se le indica si el resultado es aceptable o no para esa secuencia, y así se van ajustando los pesos de las neuronas

En el aprendizaje por refuerzo hay 2 componentes:

- **Agente:** es el modelo a entrenar y que aprende a tomar decisiones.
- **Ambiente:** es el entorno en donde interactúa el agente. El ambiente contiene las limitaciones y reglas posibles en cada momento.

Entre agente y ambiente hay una relación que se retroalimenta y cuenta con los siguientes nexos:

- **Acción:** las posibles acciones que puede tomar en un momento determinado el Agente.

- **Estado** (del ambiente): son los indicadores de cómo están los diversos elementos que lo componen en un momento dado.
- **Recompensas** (o castigos): a raíz de cada acción tomada por el Agente, se obtiene un premio o una penalización que orienta al Agente.

En la Figura 6 puede observarse una representación esquemática del comportamiento descrito.

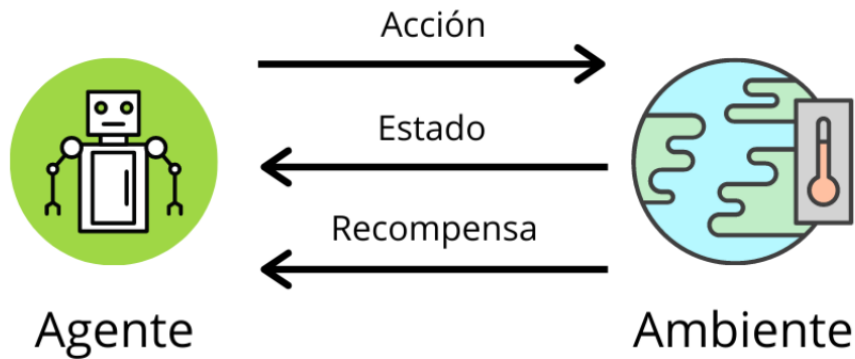


Figura 6, Interacción agente ambiente [5].

El proceso que se sigue en el entrenamiento es el siguiente (Figura 7):

1. En un primer momento el agente recibe un estado inicial y toma una acción, con lo cual influye e interviene en el ambiente.
2. En la siguiente iteración el ambiente devolverá al agente el nuevo estado y la recompensa obtenida.
3. Si la recompensa es positiva se reforzará ese comportamiento para el futuro. En cambio, si la recompensa es negativa se penalizará, para que ante la misma situación el agente actúe de manera distinta.



Figura 7, Proceso de recompensa [5].

Es decir, el agente explora el ambiente y va aprendiendo cómo actuar. Al final almacenará el conocimiento en unas normas también llamadas “políticas”.

La función de entrenamiento más común es el **Q-learning**, que está compuesto por los siguientes elementos:

- **Políticas:** Es una tabla que le indica al modelo cómo actuar en cada estado.
- **Acciones:** Son las diversas elecciones que puede hacer el agente en cada estado.
- **Recompensas:** si se suma o se resta puntuación con la acción tomada.
- **Comportamiento “ávaro” (greedy) del agente:** Se da cuando el agente se deja llevar por grandes recompensas inmediatas, y no explora ni considera ganancias a largo plazo.

El objetivo principal al entrenar el modelo a través de las simulaciones es ir “rellenando” la tabla de Políticas de manera que las decisiones que tome el agente obtengan la mayor recompensa posible. Para saber cómo ir completando la tabla de políticas se emplea la ecuación de Bellman, Figura 8.

$$\hat{Q}(s,a) = Q(s,a) + \alpha \left[R + \left(\lambda \max_{s'} Q(s',a) \right) - Q(s,a) \right]$$

Figura 8, Fórmula de entrenamiento Q-learning.

Lo que explica esta ecuación es cómo ir actualizando las políticas $\hat{Q}(s,a)$ en base al valor actual más una futura recompensa recibida en caso de tomar dicha acción. Hay dos ratios que afectan a la manera en cómo influye esa recompensa: el aprendizaje, que regula “la velocidad” con la que se aprende, y la “tasa de descuento” que tendrá en cuenta la recompensa a corto o largo plazo [5].

También es posible utilizar estrategias conforme a las cuales ir modificando las recompensas en función de los resultados que se alcancen.

2.2. Estado del arte

Se ha llevado a cabo una extensa revisión de la bibliografía existente. La descripción del estado del arte sigue la siguiente secuencia: primero se van a comentar los trabajos que utilizan sistemas basados en lógica fuzzy para la gestión del capital, luego se va a comentar cómo se lleva a cabo el tratamiento de los datos dentro de la bibliografía. Después se va a hablar de los ensayos llevados a cabo para determinar la eficacia de las redes neuronales en la predicción de precios, y en concreto para el Bitcoin y para la predicción sus tendencias. Finalmente se expondrá brevemente cómo se aborda la gestión de carteras de criptomonedas mediante sistemas basados en aprendizaje por refuerzo.

2.2.1. Sistemas inteligentes de gestión del capital en base a reglas y lógica fuzzy

Un ejemplo de sistema de gestión del capital en base a reglas borrosas o difusas (fuzzy) se presenta en [6], donde se describen sistemas difusos probabilísticos de orden cero, que implementan un mapeo estocástico de entrada-salida. Este mapeo estocástico puede convertirse en determinista de entrada-salida para describir el comportamiento esperado. Para ambos tipos de mapeos se presentan esquemas de razonamiento adecuados que tienen en cuenta explícitamente las propiedades estadísticas de los datos.

La principal referencia que sirve como inspiración para este trabajo es [1], donde se propone un sistema de negociación en el que se aplica la lógica difusa no sólo para definir las reglas de negociación, sino también para gestionar el capital a invertir. De hecho se desarrollan dos sistemas difusos de apoyo a la decisión. El primero utiliza la lógica difusa para diseñar las reglas de negociación y para aplicar los indicadores técnicos del mercado de valores. El segundo mejora este sistema de negociación difusa añadiendo una estrategia borrosa para gestionar el capital a operar. Además, se introduce un nuevo indicador técnico de mercado que produce señales de entrada en corto y en largo. Las propuestas se comparan con una versión clásica determinista de los sistemas de negociación propuestos y con la estrategia buy-and-hold. Los resultados del sistema de trading difuso en los dos mercados considerados, NASDAQ100 y EUROSTOXX, son mejores. Las conclusiones sugieren que el uso de la lógica difusa para la gestión del capital es prometedor y merece una mayor exploración.

En [2] se propone una metodología para detectar patrones de velas en un sistema de negociación de valores utilizando la lógica difusa. Este enfoque permite tener en cuenta la vaguedad e incertidumbre de las características de los patrones. Más aún, el uso de reglas difusas permite incluir esa incertidumbre en un sistema de decisión de trading que no sólo aconseja al inversor sobre cuándo sino también sobre cuánto capital invertir. El rendimiento de este sistema de trading inteligente se ha probado en dos carteras de diferentes mercados de valores, Nasdaq-100 y Eurostoxx, y se ha comparado con su homólogo "crisp" y con la estrategia clásica de trading Buy-and-Hold. El sistema de trading basado en velas difusas no sólo mejora el reconocimiento de patrones respecto a su versión "crisp", sino que además proporciona resultados prometedores ya que muestra un comportamiento más estable en los mercados analizados, y obtiene más beneficios de forma menos arriesgada que los otros sistemas de trading considerados.

Finalmente, en [3] se propone un novedoso sistema de recomendación difusa para los inversores en bolsa. Esta herramienta de decisión inteligente utiliza velas japonesas difusas e incluye el efecto de la devaluación de la moneda en la previsión. Para ello, primero se obtiene la siguiente sesión bursátil mediante el nuevo sistema de previsión difusa diseñado. A continuación se compara con la obtenida por un sistema no paramétrico basado en la técnica k-nearest neighbours. Por último se considera una cantidad de dinero a invertir mediante una nueva estrategia difusa de gestión de capital. Los resultados se han comparado con un sistema análogo de comercio difuso que tiene la misma estrategia de inversión de todo o nada con control de riesgo, pero en el que no se incluye esta capitalización. Ambos sistemas de decisión inteligente se han aplicado a dos mercados bursátiles muy diferentes, el Nasdaq100 americano y el Ibex35 español, utilizando como referencia la estrategia de inversión Buy-and-Hold. Los resultados demuestran que el sistema difuso con capitalización propuesto es rentable y presenta una alta estabilidad, pudiendo ser un buen sistema de apoyo a los inversores.

Estos tres últimos artículos se citan por su marcada influencia a la hora de comprender los mercados bursátiles, así como a la hora de llevar a cabo este trabajo, y la importancia de la estrategia Buy&Hold para evaluar los resultados obtenidos por los distintos sistemas.

2.2.2. Tratamiento de los datos.

A la hora de entrenar redes neuronales, el primer paso consiste en adaptar los datos, en especial si se trabaja con criptomonedas. Por ello se ha analizado el artículo [7], donde se explican diferentes opciones de normalización de los datos, con el fin de conseguir un mejor funcionamiento de las redes neuronales. El tratamiento de los datos es un aspecto que requiere un análisis detallado. En este trabajo se han eliminado los datos de precios de cierre anteriores a 2015 ya que solamente introducen ruido al sistema y no son representativos de la situación actual de la moneda. También se ha comparado esta medida con el filtrado logarítmico propuesto en [7], demostrándose que los resultados son similares por lo que no merece la pena llevar a cabo este filtrado logarítmico.

2.2.3. Redes neuronales para predicción de precios.

Existe una extensa bibliografía que muestra el funcionamiento de las redes neuronales para la predicción de precios de distintos activos. En este sentido se puede destacar el trabajo llevado a cabo por [8], donde se presenta un enfoque híbrido que combina el uso de variables de análisis técnico y de análisis fundamental de los indicadores bursátiles para la predicción del precio futuro de las acciones. Los resultados obtenidos mostraron una notable mejora con respecto al uso de variables de análisis técnico únicamente. Además, la predicción del enfoque hibridado se consideró satisfactoriamente adecuada como guía para los operadores e inversores en la toma de decisiones cualitativas. El interés del artículo radica en que se muestran varias pruebas de rendimiento de redes MLP para predecir precios de distintos stocks financieros. El artículo resulta interesante tanto desde el punto de vista de la metodología como de comparación entre redes.

También en [9] se utilizan una serie de modelos de redes neuronales para predecir el valor de las acciones al día siguiente utilizando datos anteriores. Para ello se aplicaron dos tipos diferentes de redes neuronales, la red de Elman y la MLP. Los resultados obtenidos muestran que para predecir la dirección de los cambios de los valores al día siguiente ninguna de ellas mejora el modelo de regresión lineal simple. Sin embargo, el error de la predicción de la cantidad de cambios de valor utilizando la red neuronal MLP es menor que con la red de Elman y la regresión lineal. Además, cuando la red neuronal MLP feedforward predice correctamente la dirección de los cambios, la cantidad de cambio se acerca a la real en comparación con los otros dos métodos mencionados.

Otro análisis llevado a cabo en [10] es el de las series temporales del precio de Bitcoin con una red neuronal Bayesiana (BNN), utilizando información de Blockchain además de variables macroeconómicas. Teniendo en cuenta los datos de todo el rango de tiempo, los resultados experimentales muestran que el modelo BNN entrenado con las características seleccionadas describe eficazmente la evolución del precio del Bitcoin y la volatilidad del activo. También se demuestra experimentalmente que el rendimiento predictivo de las redes tipo BNN es mejor que el de otros métodos de referencia. A través del análisis empírico, se confirma que el modelo BNN describe la actuación de Bitcoin. Estos resultados son interesantes ya que

muestran que, a pesar de reducir del número de datos de entrada, esto no implica un incremento sustancial del error.

Por otro lado, en [11] se utilizan redes neuronales con arquitectura LSTM para la predicción del precio de Bitcoin. El trabajo incluye la implementación del ajuste de hiper-parámetros para obtener una arquitectura de red más precisa. Este artículo resulta de utilidad de cara a la información que ofrece con respecto a los errores de entrenamiento que se cometen.

Finalmente, [12] explora la predicción del precio de Bitcoin basándose en una lista exhaustiva de características con vínculos financieros. Este estudio considera un enfoque holístico para seleccionar las variables predictoras que podrían ser útiles para conocer las tendencias futuras del precio de Bitcoin. Los rendimientos del Tesoro estadounidense a dos y diez años son los indicadores de referencia para la inversión a corto y largo plazo en los mercados de bonos, por lo que un cambio en estos puntos de referencia podría impulsar a los inversores hacia vías de inversión alternativas como el Bitcoin. También se lleva a cabo un estudio de comportamiento de distintas arquitecturas de redes neuronales concluyéndose que las redes LSTM son las mejores para actuar en este tipo de entornos.

El trabajo llevado a cabo por [13] se centra en el estudio de la viabilidad de aplicar diferentes técnicas de aprendizaje automático (machine learning, ML) a muestras con diferentes estructuras de datos y características dimensionales, con el fin de predecir el precio de Bitcoin en diferentes frecuencias. Para ello, primero clasifica el precio diario de Bitcoin por precio diario y precio de alta frecuencia. Se utiliza un conjunto de características de alta dimensión que incluyen la propiedad y la red, el comercio y el mercado, la atención y el precio del oro, mientras que las características básicas de negociación de una bolsa de criptodivisas se utilizan para la predicción del precio en intervalos de 5 minutos. Esta investigación sobre la predicción del precio de Bitcoin puede considerarse un estudio piloto de la importancia de la dimensión de la muestra en las técnicas de aprendizaje automático. Esto se ha tenido en cuenta a la hora de considerar los datos con los que trabajar. Además, en el artículo se explican diversos métodos de Machine Learning para el modelado del mercado del bitcoin. Como referencia, en este artículo la precisión de los métodos basados en redes neuronales, en concreto con LSTM, es alrededor del 0,6.

En nuestro trabajo se ha utilizado la herramienta “Regression Learner” de MATLAB, que integra todos los métodos descritos en el artículo anterior [13]. Sin embargo, debido a que esta investigación se centra en el modelado con redes neuronales, se ha decidido no profundizar en el resto de las técnicas utilizadas para el modelado de mercados financieros.

2.2.4. Predicción de tendencias en el mercado de Bitcoin con redes neuronales.

Trabajar sobre la predicción de tendencias del mercado del Bitcoin es fundamental si se quiere desarrollar un sistema que opere en dicho mercado. En este sentido, en [14] se investiga el uso de redes neuronales para la predicción de estas tendencias, y también se calcula el coste computacional del entrenamiento. Se concluye que las redes neuronales tipo MLP superan la capacidad de predicción de los modelos ARIMA. A modo de referencia, para comparar con nuestros resultados, en la Tabla se muestran los valores de precisión (accuracy), que rondan el 50%.

Model	Temporal Length	Sensitivity	Specificity	Precision	Accuracy	RMSE
LSTM	100	37%	61.30%	35.50%	52.78%	6.87%
RNN	20	40.40%	56.65%	39.08%	50.25%	5.45%
ARIMA	170	14.7%	100%	100%	50.05%	53.74%

Tabla 1, Tabla de resultados de [14].

También en [15] se utilizan redes neuronales MLP para la predicción de la evolución del precio del Bitcoin, llegando a la conclusión de que el Bitcoin cuenta con una serie de características específicas que dificultan el poder predecir con precisión su evolución en el mercado.

Por otro lado, en [16] se desarrollan y comparan varios modelos de predicción del precio de Bitcoin basados en el aprendizaje profundo, utilizando la información del blockchain de Bitcoin. Más concretamente, se prueban modelos de Deep learning redes neuronales profundas (DNN), modelos de memoria a corto plazo (LSTM), redes neuronales convolucionales (CNN), redes residuales profundas (ResNet), y sus combinaciones. Se abordan tanto problemas de regresión como de clasificación, donde los primeros predicen el precio futuro de Bitcoin y los segundos predicen si el precio futuro subirá o bajará. Para los problemas de regresión, LSTM superó ligeramente a los otros modelos, mientras que, para los problemas de clasificación, DNN dio mejores resultados. Aunque se sabe que CNN y ResNet son muy eficaces en muchas aplicaciones, incluido el análisis de datos secuenciales, su rendimiento no fue especialmente bueno para la predicción del precio de Bitcoin. En general, no hubo un claro ganador y el rendimiento de todos los modelos de aprendizaje profundo estudiados en este trabajo fue comparable entre sí. Los resultados del estudio de predicción de tendencia se muestran a continuación Tabla , que nos servirá también como referencia para estimar la bondad de nuestros resultados (en torno al 50% en todos los casos).

Size (m)	DNN	LSTM	CNN	ResNet	CRNN	Ensemble	SVM	Base	Random
5	49.16%	50.43%	50.14%	50.88%	50.02%	49.14%	50.88%	50.88%	51.38%
10	48.19%	50.22%	48.74%	50.51%	48.37%	49.43%	50.79%	50.79%	50.62%
20	50.64%	49.70%	50.78%	49.84%	48.86%	51.02%	50.80%	50.80%	49.68%
50	53.06%	50.94%	52.48%	49.83%	51.52%	52.02%	50.85%	50.85%	50.98%
100	48.16%	48.89%	48.49%	50.00%	48.59%	49.40%	50.00%	50.00%	48.61%

Tabla 2, Tabla de resultados de [16].

Finalmente, en [17] se estudia el rendimiento de los modelos MLP y RNN para la predicción del cambio de precio del bitcoin. A largo plazo logra un resultado mejor que en corto con ambas redes. Al igual que en la predicción del precio del mercado de valores, la predicción del precio a largo plazo de la criptomoneda está en el rango del 50%. El modelo que mejor funciona en esta investigación es el MLP, aspecto a considerar ya que concuerda con el resto de los autores de la bibliografía.

2.2.5. Gestión de carteras de criptomonedas mediante técnicas de Machine Learning.

Un ejemplo de gestión de cartera de criptomonedas se presenta en [18], con una red neuronal convolucional que utiliza como entrada precios históricos de un conjunto de activos financieros, y da como resultado las ponderaciones de la cartera del conjunto. La red se entrena con datos de precios de 0,7 años de una bolsa de criptomonedas. Se usa aprendizaje por refuerzo para entrenarla, maximizando el rendimiento acumulado como función de

recompensa de la red. La red no se limita a criptomonedas sino que puede aplicarse a otros mercados financieros, al igual que el sistema que se desarrolla en este trabajo.

Otro ejemplo puede verse en [19], dónde se utiliza aprendizaje por refuerzo para aprender estrategias de negociación de contratos. El análisis se centra en tres algoritmos de aprendizaje por refuerzo, a saber: Deep Q-learning Network, Policy Gradients, y Advantage Actor-Critic, y se investigan los espacios de acción discretos y continuos. El método se prueba en 50 contratos de futuros de 2011 a 2019, y los resultados muestran que los algoritmos de aprendizaje por refuerzo superan a los modelos de referencia y ofrecen beneficios incluso con grandes costes de transacción.

Queda visto que generalmente se plantean sistemas entrenados mediante aprendizaje por refuerzo para la gestión de carteras de activos financieros, y el sistema es más eficiente para la gestión de una serie de activos en vez de para uno solo.

3. CAPÍTULO 3: Datos

La aplicación de redes neuronales requiere, en la mayoría de los casos, de una gran cantidad de datos, ya que es necesario disponer de datos suficientes como para entrenar la red neuronal, la validación del entrenamiento, realizar test del funcionamiento de la red y la simulación de la red neuronal con nuevas entradas.

En este capítulo se describe el formato de los datos que se va a emplear a lo largo del trabajo, así como las herramientas y servicios disponibles para su obtención.

3.1. Datos económicos y herramientas para su obtención

En general, en los mercados financieros se emplean los diagramas de velas japonesas para trabajar con la información de los valores. En este trabajo se va a considerarse únicamente el precio de cierre del activo ya que, en situaciones normales, es el mismo que el de apertura del siguiente periodo, por lo que a este respecto no se pierde información. De la misma forma, se puede considerar que durante el periodo no se va a operar, por lo que a efectos prácticos da igual la fluctuación de precios a lo largo del periodo ya que lo que se busca es operatividad a largo plazo.

Por otro lado, a la hora de operar en mercados financieros, la obtención de datos rápidamente, fiables y precisos es fundamental ya que puede marcar la diferencia en los resultados del operador a corto plazo. Sin embargo, es posible emplear datos menos actuales, garantizando que sean precisos y fiables, durante la investigación donde no existe la imperiosa necesidad de operar con rapidez.

En este trabajo de investigación se han empleado dos herramientas para la obtención de datos financieros. La primera permite exportar los datos financieros a un archivo .txt para posteriormente importarlos en Matlab (NinjaTrader), y la segunda permite conectarse mediante internet a un servidor para descargar los datos necesarios.

3.1.1. NinjaTrader

NinjaTrader es un gestor de *trading* digital que permite comprobar los precios (open, close, high, low) de aquellos activos a los que se suscriba el usuario [20]. La interfaz general de NinjaTrader es la que se muestra en la Figura 9. En la barra horizontal superior aparecen los activos y sus características, y en la de abajo las acciones y órdenes.




Figura 9, Ventana principal de NinjaTrader.

En dicho programa se ha configurado una conexión a un servidor donde se almacenan datos en tiempo real de criptomonedas, como se muestra en la Figura 10.

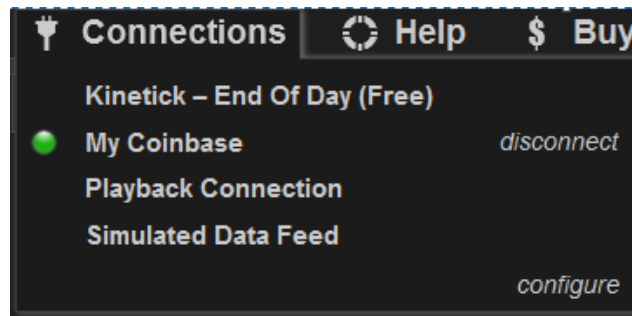


Figura 10, Establecimiento de la conexión a NinjaTrader.

Una vez configurada la conexión se puede emplear la herramienta de exportación de datos. Como puede verse en la Figura 11, esta herramienta permite descargar y exportar datos históricos de los activos con diversos formatos. También permite seleccionar el intervalo temporal en el que se quieren los datos, así como el inicio y el final del intervalo temporal y la división de tiempo utilizada en el intervalo temporal.

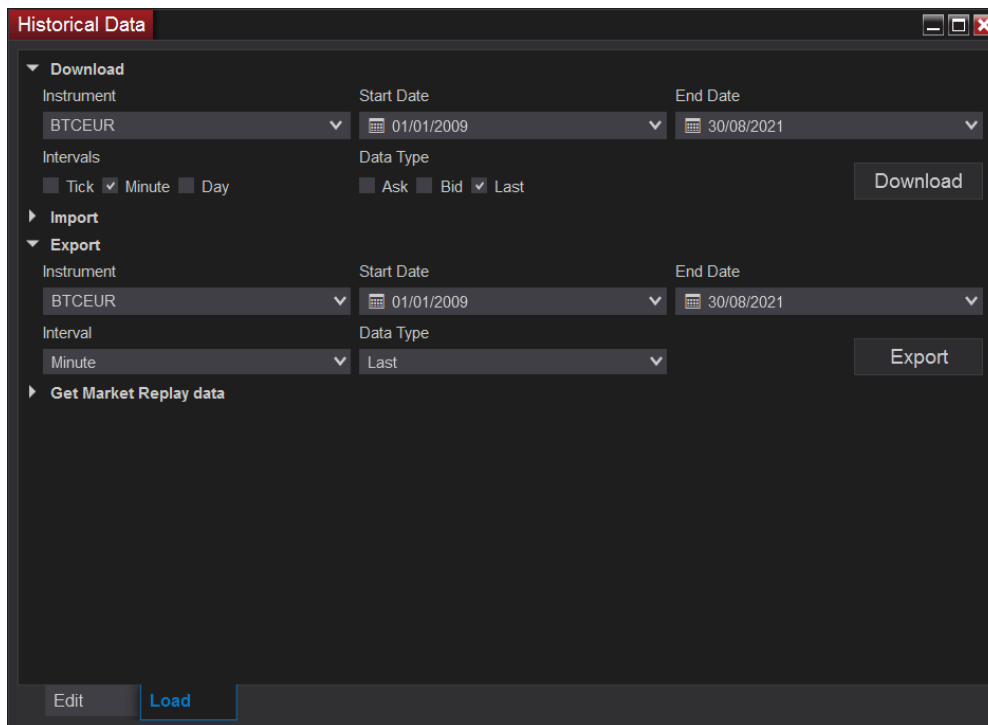


Figura 11, Herramienta de descarga y exportación de datos económicos de NinjaTrader.

Además, esta herramienta tiene una interesante funcionalidad, ya que permite la representación del diagrama de velas japonesas del activo (Figura 12), donde las velas rojas indican que el CLOSE está por debajo del OPEN y las verdes indican la situación contraria. Este diagrama es de gran utilidad para el análisis. Finalmente, los datos exportados se almacenan en archivos .txt.



Figura 12, Diagrama de velas japonesas en NinjaTrader.

3.1.2. Alpha Vantage

Se trata de un servidor de datos de cotización de activos online que colabora con una gran cantidad de entidades dedicadas a la investigación y operación en mercados financieros Figura 13. Además, dispone de archivos educativos y demostraciones. La ventaja de este sistema frente a NinjaTrader es que se encuentra alojado en la red, lo que permite descargar los precios de cierre directamente desde Matlab. Sin embargo, como desventaja se puede decir que es más complejo acceder a los datos y la configuración del sistema.



Figura 13, Logo de Alpha Vantage.

3.2. Datos y preparación de los datos

El entrenamiento de la red neuronal requiere que tanto los datos de entrada como de salida tengan una estructura dada. Para ello se ha desarrollado una función que prepara los datos en formato n días, es decir, que toma como entrada los datos de n días atrás y da como salida el dato del día de entrenamiento (Figura 14).

```
function [Input,Output] = PreparaInputOutput (Datos,nretardo,inicio,final)
%function [Input,Output] = PreparaInputOutput (Datos,nretardo)
% Detailed explanation goes here

Output=[Datos(inicio+nretardo:final)];
for i=0:nretardo-1
    Input(:,i+1)=Datos(inicio+i:final-nretardo+i);
end
end
```

Figura 14, Función para preparar datos para el entrenamiento de redes neuronales desarrollada en Matlab.

Para el desarrollo de este trabajo se han obtenido datos de distintos activos utilizando las herramientas descritas anteriormente. Los activos utilizados son de dos tipos: criptomonedas y activos financieros.

- Las criptomonedas analizadas son Bitcoin y Ethereum.
- Los activos analizados son Apple, Microsoft, Google y Amazon, entre otros.

3.2.1. Criptomonedas

Es necesario tener en cuenta que la reciente creación de las criptomonedas implica que no es posible obtener largas y extensas series de datos. Además, debido al exponencial crecimiento de éstas, será necesario seleccionar rangos de datos realmente representativos y relacionables con la situación actual.

A. Bitcoin

Aunque fue creado en 2008 y se tienen datos de precios desde entonces, debido a su crecimiento exponencial y a que actualmente la situación es completamente distinta a la de esta criptomoneda diez años atrás, se hace necesario descartar los datos anteriores a 2014.

Se han escogido las siguientes series de datos.

- Datos desde el 02/01/2015 hasta el 13/04/2020 para el entrenamiento.
- Datos desde el 14/04/2020 hasta el 14/04/2021 para selección.
- Datos desde el 15/04/2021 hasta el 15/04/2022 para el test.

Los porcentajes de datos utilizados para test y validación se detallarán en el capítulo siguiente.

B. Ethereum

Comenzó su operación en febrero de 2014, y su situación y evolución es la misma que con Bitcoin, con la salvedad de que los datos adecuados para la predicción son menos. Se puede utilizar para verificar que la metodología de desarrollo del sistema predictivo de precios para Bitcoin es adecuada para otras criptomonedas.

Únicamente se ha escogido una serie de datos ya que solamente se ha comprobado si la red entrenada para bitcoins sirve para operar en Ethereum.

- Datos desde el 15/04/2021 hasta el 15/04/2022 para test.

3.2.2. Activos

Se ha utilizado la conexión web para importar datos de precios de cierre de la cotización de distintas empresas, que posteriormente serán usados para el entrenamiento de las redes neuronales. Entre las compañías analizadas se pueden destacar Google (GOOGL), Amazon (AMZ), Microsoft (MSFT) y Facebook (FB), entre otras.

Los activos permiten comprobar el funcionamiento del sistema de aprendizaje por refuerzo, por lo que se escogen distintas series de datos temporales. Como el aprendizaje por refuerzo se entrenará considerando carteras de acciones, de no existir en la fecha de inicio del entrenamiento la acción referida, ésta simplemente no se considerará a la hora de comprar acciones. La serie temporal utilizada es la siguiente.

- Entrenamiento: desde el 15/01/2010 hasta 18/01/2020.
- Test: desde el 18/01/2020 hasta el 28/09/2021.

Debido a que el estudio objeto de este trabajo está centrado en el Bitcoin, no se han incluido los resultados en este documento. No obstante, es un aspecto a considerar de cara al desarrollo de trabajos futuros.

3.3. Medidas del error.

El error en las predicciones se puede medir de muchas formas. En este trabajo, siguiendo algunas referencias de la literatura, se han escogido las siguientes:

- El error cuadrático medio (RMSE).
- El error absoluto medio.
- El error relativo medio.
- Tasa de acierto.
- Tasa sintética de éxito.

La medida de los errores en las predicciones se realizará por medio del **error cuadrático medio**, ya que es una medida estandarizada y da una buena idea de cómo se ajusta la predicción al valor real. La expresión del error cuadrático medio es la siguiente (1):

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

Donde n es el número de datos, y_i es el valor del dato predicho e \hat{y}_i es el valor del dato real.

El error absoluto es un buen estimador del error cometido ya que da una idea de la magnitud del error tratado. A la hora de hablar de Bitcoins, los errores, por pequeños que sean, van a suponer grandes cantidades de dinero. En este contexto cobra sentido el **error absoluto medio**. Se define como el promedio de la diferencia absoluta entre el valor observado y los valores predichos. En el error absoluto medio las diferencias individuales se ponderan por igual en el promedio (2).

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_i - \hat{y}_i| \quad (2)$$

También el **error relativo** es un buen estimador del error cuando se quiere dejar de lado la magnitud del error. Al tratar el Bitcoin, los altos precios que alcanzan y los elevados valores de los errores absolutos hacen que se pierda de vista el acierto de las estimaciones. Por esto se ha empleado el error relativo medio, que es el promedio del cociente de la diferencia absoluta entre el valor observado y los valores predichos ente el valor observado (3).

$$MRE = \frac{1}{n} \sum_{j=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \quad (3)$$

A la hora de comprobar cómo ha sido el entrenamiento de las redes neuronales para predicción de futuras tendencias se utiliza la **tasa de acierto**, que se entiende como el cociente entre el número de aciertos entre el número de predicciones (4).

$$Tasa\ de\ acierto = \frac{aciertos}{fallos + aciertos} \quad (4)$$

Cuanto mayor sea la tasa de acierto, mejor será el sistema desarrollado.

Por último, para evaluar los sistemas entrenados para la predicción de tendencias también se han elaborado matrices de confusión. Estas matrices llevan a la definición de la tasa sintética de éxito, es decir, los aciertos que son realmente importantes dentro de las decisiones: Verdadero Positivo (TP), Falso Positivo (FP), Verdadero Negativo (TN) y Falso Negativo (FN).

- La red predice una subida del precio del Bitcoin y hay una subida (TP)
- La red predice una caída del precio y se produce una caída del precio (TN)
- La red predice una subida del precio del Bitcoin y se da una caída (FP)
- La red predice una caída del precio de Bitcoin y se da una subida (FN)

De tal manera que la tasa sintética de éxito se define como (5):

$$Tasa_{sintética_éxito} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Una mayor tasa sintética de éxito supone un mejor funcionamiento de la red en el periodo de test.

3.4. Estimación del comportamiento de sistemas de gestión del capital.

De igual forma, a la hora de evaluar los sistemas de gestión del capital hay varios índices que se pueden utilizar, como los siguientes:

- Rentabilidad.
- Máximo DrawDown.
- Profit factor.
- Ganancia media.
- Pérdida Media.
- Número de operaciones.

La **rentabilidad** es la expresión de la ganancia sobre la inversión inicial, de tal forma que una rentabilidad alta será un indicador de que el sistema es bueno, mientras que una rentabilidad baja indicará lo contrario. Se calcula de acuerdo a la expresión (6).

$$Rentabilidad\ (\%) = \frac{Dinero_{final}}{Dinero_{inicial}} \cdot 100 \quad (6)$$

El **DrawDown** es un indicador que mide el retroceso actual en la curva de resultados respecto al máximo anterior. El valor del Máximo DrawDown se utiliza para determinar el nivel de

riesgo de un sistema de trading ya que influye de manera directa en el capital mínimo con el que hay que contar para invertir Figura 15.



Figura 15, Representación gráfica del Drawdown.

El **profit factor** es un estimador que sirve para evaluar los sistemas de gestión del capital tomando cuenta los beneficios que obtienen y las pérdidas que asumen. Se calcula con la siguiente expresión (7).

$$Profit_factor = \frac{\sum ganancias}{\sum pérdidas} \quad (7)$$

Un profit factor mayor que uno significa que el sistema tiende a ser rentable, mientras que si es inferior a uno indica que el sistema tiende a ser perdedor. Cuanto mayor sea el profit factor implica que el sistema es capaz de obtener mayores beneficios asumiendo un riesgo menor.

El **número de operaciones** es también importante para analizar si el sistema ha operado un número de veces suficiente como para considerar la fiabilidad de los resultados. En este sentido, si el sistema únicamente operara pocas veces y generara un profit factor muy elevado, se podría considerar los resultados muy volátiles para tenerlos en consideración.

La **ganancia media** sirve para estimar el beneficio medio que se genera cada vez que el sistema gana. El estimador se calcula como (8).

$$Ganancia_media = \frac{\sum ganancias}{N^{\circ} operaciones ganadoras} \quad (8)$$

Un mayor valor de ganancia media es deseable.

La **pérdida media** sirve para estimar el detrimento medio que se produce cada vez que el sistema pierde. Se obtiene mediante (8).

$$Pérdida_media = \frac{\sum pérdidas}{N^{\circ} operaciones perdedoras} \quad (9)$$

Un menor valor de pérdida media es preferible sobre uno mayor.

Finalmente se puede plantear la esperanza matemática del sistema, que puede calcularse mediante (10).

$$E = \%aciertos \cdot ganancia_media - \%fallos \cdot pérdida_media \quad (10)$$

Si la esperanza matemática es mayor que cero el sistema tendrá beneficios y en caso contrario presentará pérdidas.

4. CAPÍTULO 4: Predicción de precios de criptomonedas con redes neuronales MLP

En este capítulo se van a detallar los distintos ensayos y entrenamientos con redes neuronales MLP para predecir la evolución de los precios de criptomonedas. Estas MLP se han usado para:

- Predicción de precios futuros en el mercado de las criptomonedas, en concreto el precio de cierre
- Predicción de tendencias futuras de las criptomonedas, es decir, discernir tendencias alcistas, bajistas o conservadoras en mercados de criptomonedas.

Se ha desarrollado una herramienta que permite entrenar de manera fácil e intuitiva las redes neuronales para probar distintas configuraciones. El procedimiento seguido es el siguiente:

- Empleando la herramienta desarrollada se selecciona el número de datos de entrada.
- Se selecciona el tipo de entrenamiento deseado entre las distintas opciones.
- Se ajusta el número de capas ocultas y el número máximo de neuronas de cada capa oculta.
- Se selecciona el método de discretización de tendencias.

Al ejecutar la herramienta, el algoritmo desarrollado encontrará la mejor solución al problema. La red entrenada se mostrará por pantalla, así como el resultado del método de evaluación obtenido.

- Para la predicción de valores del Bitcoin se entrena la red tipo MLP de forma que configuración óptima es la que minimice el error cuadrático medio de los datos de comprobación disponibles.
- La predicción de tendencias se divide en dos ensayos, ya que la identificación de tendencias de los datos brutos puede realizarse considerando distintos márgenes y se puede ajustar de acuerdo con un margen numérico.

El periodo de entrenamiento es:

- Desde el 02/01/2015 hasta el 13/04/2020.

El periodo de test es:

- Desde el 14/04/2020 hasta el 14/04/2021.

Es decir, un año de plazo para operar. En condiciones normales, un año es tiempo suficiente para que se den tendencias de todo tipo dentro del mercado.

4.1. Predicción de valores con NN

En este ensayo se ha utilizado la herramienta desarrollada para obtener redes MLP con distintas configuraciones, modificando el número de días de entrada, el número de capas y el número de neuronas por capa. El esquema de ensayo seguido es el siguiente:

- 10 datos de entrada:
 - 1 capa oculta con un máximo de 10 neuronas.
 - 2 capas ocultas con un máximo de 10 neuronas en la primera capa y 5 en la segunda.

- 30 datos de entrada:
 - o 1 capa oculta con un máximo de 20 neuronas.
 - o 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 50 datos de entrada:
 - o 1 capa oculta con un máximo de 20 neuronas.
 - o 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 100 datos de entrada:
 - o 1 capa oculta con un máximo de 20 neuronas.
 - o 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 150 datos de entrada:
 - o 1 capa oculta con un máximo de 20 neuronas.
 - o 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 200 datos de entrada:
 - o 1 capa oculta con un máximo de 20 neuronas.
 - o 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.

En la Figura 16 se muestran los resultados de predicción de valores. Se observa que la predicción se ajusta muy bien a los valores reales pero que hay un cierto retardo en algunas situaciones. La configuración utilizada es la que utiliza 50 datos de entrada y tiene una capa oculta. Los precios que se muestran son los precios de cierre del mercado del Bitcoin. Los datos de entrada a la red neuronal son los precios de cierre de las 50 sesiones anteriores a la predicción.



Figura 16, Predicción de valores con la MLP.

Los resultados de todas las pruebas se muestran en la Tabla 1.

	Nº datos de entrada	Nº capas ocultas	Configuración	RMSE	Error Absoluto Medio	Error Relativo Medio
CapasOcultas_1	10	1	6	1186.9723	678.1739	0.026272
	30	1	8	1192.4011	689.8203	0.027213
	50	1	12	1151.2968	678.0836	0.028187
	100	1	12	1182.1012	700.492	0.029158
	150	1	13	1203.5325	716.4278	0.029886
	200	1	7	1237.2039	745.3219	0.031706
CapasOcultas_2	10	2	[10,1]	1165.9256	659.1366	0.025544
	30	2	[4,3]	1145.1051	655.737	0.02573
	50	2	[14,3]	1122.7003	664.8437	0.027122
	100	2	[12,2]	1164.0049	696.0384	0.028132
	150	2	[13,4]	1196.6659	747.076	0.031205
	200	2	[7,3]	1189.766	719.1473	0.030201

Tabla 1, Tabla de resultados de la selección de redes neuronales para la predicción de valores.

Los resultados se muestran también en la Figura 17, para analizar la efectividad de la predicción de la red neuronal en función del del número de capas y neuronas. En el eje y se muestra el valor del RMSE y en el eje x el número de datos de entrada.




Figura 17, Comparación de errores cuadráticos medios en la predicción de valores.

Las conclusiones de este análisis son, en primer lugar, que aumentar el número de capas ocultas en estas redes MLP permite mejorar el error cuadrático medio. En segundo lugar, un mayor número de datos de entrada no tiene por qué implicar un mayor acierto a la hora de entrenar la red. De hecho, los resultados muestran que el menor error cuadrático medio se da utilizando los precios de cierre de 50 días como datos de entrada a la red.

Respecto a la comparación de errores absolutos medios de las tendencias, en la Figura 18 se puede ver que, hasta un número de datos de entrada de 50, los errores absolutos se mantienen. A partir de ese punto, para un mayor número de datos de entrada se disparan los errores absolutos medios. También se puede observar que aumentar el número de capas ocultas ayuda a la reducción del error absoluto medio, con una excepción en el caso de 150

datos de entrada, lo que confirma que aumentar el número de capas ocultas de la red MLP implica una reducción en el error de predicción.




Figura 18, Comparación de errores absolutos medios predicción de valores.

Las tendencias en los errores relativos medios se muestran en la Figura 19.




Figura 19, Comparación de errores relativos medios predicción de valores.

Se observa que todas las redes presentan errores relativos medios inferiores al 3,5%. La conclusión clara es que, en estos niveles de precios del activo, el error relativo medio no es una herramienta fiable para valorar la bondad de las redes entrenadas.

4.2. Predicción de tendencias con NN

Nuevamente se ha utilizado la herramienta de optimización para obtener redes MLP con distintas configuraciones, modificando el número de días de entrada, el número de capas y el número de neuronas por capa, en este caso tratando de predecir tendencias en los precios del Bitcoin. Ahora se trata de discernir cuándo una variación de los precios supone una tendencia alcista. Es decir, detectar un incremento o caída en el precio de la acción. En este trabajo se han considerado 2 situaciones, cuando se produce un cambio en el precio superior al 1% del valor de éste o con un margen de cambio superior al 2%. El estudio de márgenes superiores no tiene sentido ya que se ha comprobado que una variación del precio del Bitcoin más elevada es algo realmente inusual en el mercado.

El esquema de pruebas es el siguiente, tanto para el margen de un 1% como para variación del 2%.

- 10 datos de entrada:
 - 1 capa oculta con un máximo de 10 neuronas.
 - 2 capas ocultas con un máximo de 10 neuronas en la primera capa y 5 en la segunda.
- 30 datos de entrada:
 - 1 capa oculta con un máximo de 20 neuronas.
 - 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 50 datos de entrada:
 - 1 capa oculta con un máximo de 20 neuronas.
 - 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 100 datos de entrada:
 - 1 capa oculta con un máximo de 20 neuronas.
 - 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 150 datos de entrada:
 - 1 capa oculta con un máximo de 20 neuronas.
 - 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.
- 200 datos de entrada:
 - 1 capa oculta con un máximo de 20 neuronas.
 - 2 capas ocultas con un máximo de 20 neuronas en la primera capa y 5 en la segunda.

De cada prueba se obtiene una gráfica como la de la Figura 20, dónde se muestra la situación real y la predicción. El eje x muestra el número de la predicción, mientras que en el eje y se muestra el valor de la predicción (1 para subida, 0 que se mantiene el precio y -1 que el precio cae). De esta forma, cuando el valor de cierre real coincide con el de predicción la red neuronal acierta la tendencia.

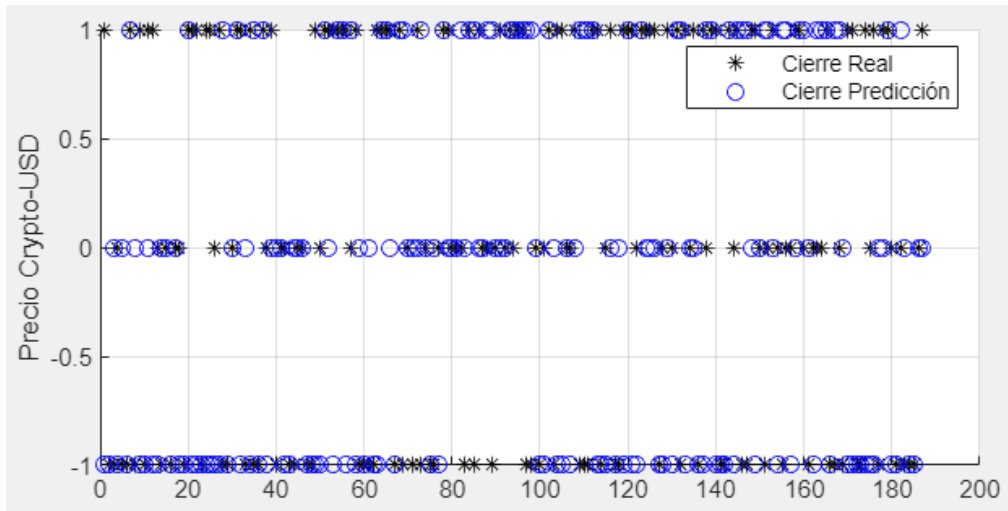


Figura 20, Representación gráfica de la predicción de tendencias.

En este contexto cobra sentido la definición de la tasa sintética de éxito descrita en el capítulo anterior, respecto a los aciertos con las predicciones de subida y bajada que hace la red.

Para un margen de un 1% los resultados obtenidos son los siguientes (Tabla 2):

Margen (%)	Nº datos de entrada	Nº capas ocultas	Configuración de la capa	Tasa acierto	Tasa Sintetica de éxito
1	10	1	2	0.37	0.417475728
1	30	1	8	0.37	0.46835443
1	50	1	17	0.38	0.47
1	100	1	9	0.40	0.50617284
1	150	1	13	0.38	0.539877301
1	200	1	12	0.39	0.535483871
1	10	2	[1,1]	0.36	0.401785714
1	30	2	[5,5]	0.38	0.469387755
1	50	2	[13,4]	0.39	0.513513514
1	100	2	[8,3]	0.43	0.596491228
1	150	2	[5,4]	0.41	0.572580645
1	200	2	[8,3]	0.39	0.537414966

Tabla 2, Resultados de predicción de tendencias con margen 1%

Para un margen de un 2% los resultados obtenidos son los de la Tabla 3:

Margen (%)	Nº datos de entrada	Nº capas ocultas	Configuración de la capa	Tasa acierto	Tasa Sintetica de éxito
2	10	1	8	0.55	0.605263158
2	30	1	6	0.55	0.530612245
2	50	1	3	0.54	0.5625
2	100	1	2	0.55	0.55
2	150	1	6	0.54	0.587301587
2	200	1	1	0.53	0.4
2	10	2	[8,4]	0.55	0.461538462
2	30	2	[7,2]	0.57	0.642857143
2	50	2	[5,3]	0.56	0.58974359
2	100	2	[13,1]	0.57	0.545454545
2	150	2	[14,1]	0.56	0
2	200	2	[4,1]	0.56	0

Tabla 3, Resultados de predicción de tendencias con margen del 2%

Los resultados en forma gráfica, para su análisis, se muestran a continuación. La tasa de acierto global, entendida como el número de veces que la red acierta en su predicción frente al número de predicciones totales se muestra en la Figura 21. Puede observarse que ni un aumento en el número de capas ni en el número de datos de entrada implican un aumento en la tasa de acierto. Sin embargo, un cambio en el margen de predicción sí que mejora la tasa de acierto, dado que se está acertando un mayor número de veces.




Figura 21, Comparación de tasas de acierto en predicción de tendencias.

Los resultados de la tasa sintéticas de éxito se muestran en la Figura 22. Se espera que dado que la tasa sintética de éxito es un indicador del resultado en la selección de redes que se adapta mejor al problema estudiado en este trabajo, las redes que presenten una mayor tasa de acierto tendrán una mayor rentabilidad cuando se integren en los sistemas de gestión del capital.




Figura 22, Comparación de tasas sintéticas de éxito en predicción de tendencias.

Como puede observarse, el hecho de acertar más veces no implica tener un mayor éxito ya que es mucho más importante que las veces que aciertes sean las adecuadas.

La conclusión de este análisis es que las redes neuronales son buenas prediciendo tendencias en función de valores anteriores; sin embargo, no resultan tan buenas a la hora de predecir acontecimientos inesperados, ya que carecen de la información necesaria para ello.

De hecho, la volatilidad de los precios en los mercados de criptomonedas hace que la tarea de predicción de precios sea realmente compleja, y no sólo es importante predecir bien sino cuándo hacerlo. Esta situación, sumada a que un comportamiento pasado del mercado no implica un comportamiento similar en el futuro, hace que el tratamiento de estos datos sea un reto.

Como conclusiones, se puede resumir lo obtenido en este capítulo de la siguiente manera.

- Las redes MLP se pueden utilizar para hacer un seguimiento del valor del precio del Bitcoin con errores relativos medios inferiores al 3,5%.
- El seguimiento de las predicciones sobre los precios es bueno cuando el mercado está inmerso en una tendencia, pero es malo cuando se producen cambios bruscos en éste.
- El error cuadrático medio y el error absoluto medio son buenos estimadores de la bondad de la red cuando ésta está operando.
- La predicción de tendencias en los mercados depende en gran medida de la discretización que se haga en las tendencias. El tomar como un cambio una situación común es un error que puede llevar a un mal entrenamiento de la red.
- A la hora de escoger redes neuronales para operar en mercados financieros, el hecho de que una red tenga una mejor tasa de predicción no implica que tenga una mayor tasa de éxito.

5. CAPÍTULO 5: Sistema de gestión del capital con redes MLP.

Una vez se han entrenado las redes neuronales para la predicción, se propone diseñar un método de inversión del capital, ya que al final lo que se quiere es un sistema que gestione el capital y produzca beneficios. Se plantea aquí una estrategia de inversión para operar en largo, en corto y en ambos a la vez.

Primero se hará una descripción detallada del sistema de gestión y luego de la estrategia de gestión del capital que se va a utilizar. Finalmente se mostrarán las pruebas llevadas a cabo, se hará un análisis de los resultados y se expondrán las conclusiones obtenidas.

Las redes neuronales que se van a utilizar en este apartado son las que predicen tendencias, ya que su funcionamiento las hace mucho más apropiadas para ser utilizadas en un sistema de gestión del capital.

El periodo de test utilizado para el sistema de gestión del capital abarca desde el 15/04/2021 hasta el 15/04/2022.

5.1. Sistema de gestión del capital.

En este trabajo se han planteado distintos sistemas de gestión del capital, sin embargo, en vista a los resultados obtenidos, se ha decidido escoger el que mejor funciona. Este funciona de la siguiente forma:

Las operaciones se efectúan con todo el capital disponible (estrategia todo-nada). En función de la predicción de tendencia hecha por la red neuronal se decide invertir todo el dinero o mantenerlo. Las posibilidades de inversión son dos, invertir en corto e invertir en largo. Si la predicción de la red neuronal es que el precio va a subir, se invertirá en largo, y si la predicción es de bajada del precio del Bitcoin se invertirá en corto. Si el sistema está inmerso en una operación y la predicción para la siguiente sesión cambia, el sistema se retirará del mercado en la apertura de la siguiente sesión y efectuará la acción correspondiente.

En este sentido, es de esperar que las redes que presenten una mayor tasa sintética de éxito sean las mejores para operar en el mercado. Sin embargo, hasta que no se ejecute la simulación, no se puede confirmar o desmentir esta afirmación ya que, aunque se gane más veces de las que se pierde, puede ocurrir que cuando se gana el beneficio es muy reducido y cuando se pierde la pérdida sea elevada. Además, no hay que olvidar que situaciones pasadas no tienen por qué producirse nuevamente en el futuro.

Las estrategias complementarias utilizadas para configurar el sistema experto son las siguientes:

A. *Stoploss.*

La primera opción añadida al sistema de gestión es el stoploss, que consiste en una orden condicionada que ejecuta la venta de un determinado activo si su precio desciende por debajo del límite marcado (suponiendo una entrada en largo y viceversa en corto). El inversor es quien fija este nivel del precio a través de su bróker, estableciendo de esta manera el nivel de pérdida máximo que está dispuesto a asumir.

Estos límites eliminan la posibilidad de sufrir mayores pérdidas si la acción continúa bajando, aunque también se pierde la posibilidad de obtener beneficios de las subidas si la acción se recupera posteriormente.

El principal problema de los stoploss es que se ejecutan con excesiva frecuencia, especialmente si el nivel de pérdidas que asumen los inversores es muy pequeño con respecto al precio actual del activo. En estos casos, una mala jornada puntual del mercado puede desencadenar la venta masiva de estos activos, provocando que su precio descienda aún más y activando a su vez las órdenes de ventas que se encontraban por debajo de ese nivel. Al final se produce un efecto que en la literatura se denomina como “bola de nieve” y que genera pérdidas que no están justificadas por la situación de la empresa. Esto explica que muchas veces el valor se recupera de forma bastante rápida.

B. Takeprofit.

El Takeprofit es una herramienta que consiste en definir un precio de venta mayor que el actual (suponiendo entrada en largo y viceversa en corto), para que se ejecute la venta consiguiendo beneficios. Se utiliza para garantizar el beneficio de las subidas, sin arriesgarse a perderlo si después baja el precio de la acción. La consecuencia es que también se desechan las posibles subidas posteriores.

La combinación de las estrategias de take-profit y stop-loss supone más seguridad en las operaciones a corto plazo, evitando grandes movimientos no deseados.

C. Retirada del mercado.

Se entiende que con unas pérdidas superiores al 20% ningún bróker continuaría en el mercado, por lo tanto, se planteó una estrategia que liquidara la posición cuando la pérdida fuera igual al 30% del capital inicial invertido.

Inicialmente se ha configurado el sistema de gestión del capital sin el sistema experto, se han analizado los resultados y posteriormente se ha introducido el sistema experto.

5.2. Resultados operando en largo.

A la hora de evaluar el comportamiento del sistema, es conveniente tener una estrategia con la cual compararlo. Se ha escogido la estrategia más común, la evolución del dinero si se deja invertido sin actuar sobre él, estrategia comúnmente conocida como “Buy and Hold” (B&H). De esta manera se puede comparar el sistema desarrollado que opera a corto plazo con el de un inversor o sistema que opera a largo plazo.

Primero se desarrolla una estrategia de inversión que únicamente actúa cuando la red predice que el Bitcoin va a subir. En ese caso el sistema decide comprar; ante cualquier otra predicción de la red el sistema decide vender. El capital inicial invertido es de 1000\$.

Los resultados obtenidos se muestran en la Tabla 4. Del análisis del número de operaciones se puede extraer que hay sistemas que no están operando en el mercado, ya que el número de veces que compran o venden es muy bajo o nulo. En la tabla se han agrupado los sistemas de la misma forma que en el capítulo anterior. En la tabla se pueden observar los resultados de rentabilidad, el máximo Drawdown, el profit factor, la ganancia media, la pérdida media y el número de operaciones.

Inversión en largo									
Margen	Nº datos de entrada	Nº capas ocultas	Rentabilidad	maxDrawDown	Profit_factor	Ganancia media	Pérdida media	Trades	
1	10	1	0	0	0	0	0	1	
1	30	1	9.64	5.11	2.57	52.63	0.17	46	
1	50	1	2.95	25.98	1.05	35.9	1.67	69	
1	100	1	-8.42	9.22	0.49	20.45	0.46	34	
1	150	1	-18.2	31.09	0.85	27.53	3.66	80	
1	200	1	3.22	13.86	1.1	24.65	0.96	34	
1	10	2	0	0	0	0	0	1	
1	30	2	-0.96	13.31	0.95	24.28	0.5	55	
1	50	2	22.64	13.11	1.59	28.94	1.11	69	
1	100	2	-31.54	46.3	0.92	20.71	18.66	20	
1	150	2	-41.22	42.36	0.7	21.3	4.28	78	
1	200	2	-30.85	34.25	0.49	19.39	1.71	48	
2	10	1	-40.61	45.03	0.83	22.07	8.37	148	
2	30	1	-25.22	33.41	0.81	22.06	4.22	153	
2	50	1	0.36	17.4	1.01	24.43	0.96	77	
2	100	1	-2.94	2.94	0	0	0.08	24	
2	150	1	-15.8	39.93	0.92	22.38	6.43	126	
2	200	1	0	0	0	0	0	0	
2	10	2	-50.27	50.88	0.45	14.77	2.72	90	
2	30	2	-32.51	51.35	0.88	19.26	11.77	66	
2	50	2	-12.58	17.63	0.69	23.46	1.15	25	
2	100	2	-2.66	9.85	0.91	39.85	0.85	49	
2	150	2	0	0	0	0	0	0	
2	200	2	0	0	0	0	0	0	
Estrategia Buy&Hold			-35.9	52.98	0.91	19.19	20.94	0	

Tabla 4, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en largo.

La rentabilidad de los sistemas operando en largo se muestra en la Figura 24.

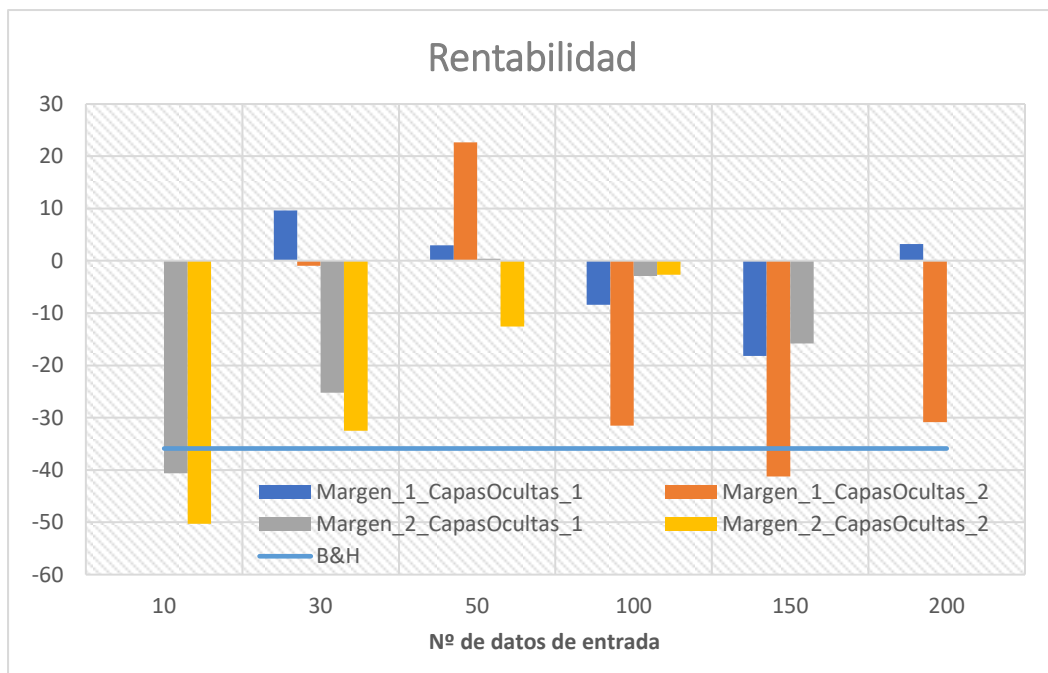


Figura 23, Rentabilidad de los sistemas entrenados mediante aprendizaje supervisado operando en largo.

Lo primero que se observa es que prácticamente todos los sistemas se comportan mejor que la estrategia B&H. De hecho, hay sistemas que consiguen obtener rentabilidades positivas. No obstante, aparentemente esto no responde a ninguna relación con respecto a ningún parámetro de la fase de entrenamiento ya que cada red ha aprendido unas tendencias diferentes, que luego son las que se han repetido o no en el periodo de ensayo.

La gráfica del máximo DrawDown (Figura 24) muestra que todas las redes son más seguras que la estrategia B&H y que las redes que más han sabido reducir el riesgo son las que han obtenido mayores beneficios.




Figura 24, Máximo DrawDown de los sistemas entrenados mediante aprendizaje supervisado operando en largo.

Por otro lado, ni el profit factor (Figura 25), ni la ganancia media (Figura 26), ni la pérdida media (Figura 27) muestran resultados interesantes a la hora de evaluar el rendimiento del sistema de gestión implementado, ya que estos resultados no eran predecibles en la fase de entrenamiento.




Figura 25. Profit factor de los sistemas entrenados mediante aprendizaje supervisado operando en largo.

Hay sistemas que presentan profit factor mayores que el de la estrategia B&H, sin embargo, se puede observar que solamente algunos superan la unidad. Con 50 datos de entrada se puede observar que las redes predicen adecuadamente.




Figura 26, Ganancia media de los sistemas entrenados mediante aprendizaje supervisado operando en largo.




Figura 27, Pérdida media de los sistemas entrenados mediante aprendizaje supervisado operando en largo.

Se puede observar también una relación entre estos tres últimos parámetros ya que un mayor profit factor implica o bien una pérdida media menor o bien una ganancia media mayor.

5.3. Resultados operando en corto.

En este caso la apuesta que puede abordar el sistema está restringida al juego en corto, es decir, que el sistema solamente entrará en el mercado cuando estime que el precio del activo va a bajar. Además, se ha limitado la cantidad que puede apostar en corto a 1000\$. Los resultados se muestran en la Tabla 5. Los sistemas se han agrupado de la misma forma que en el capítulo anterior. En la tabla se pueden observar los resultados de rentabilidad, el máximo Drawdown, el profit factor, la ganancia media, la pérdida media y el número de operaciones.

Inversión en corto								
Margen	Nº datos de entrada	Nº capas ocultas	Rentabilidad	maxDrawDown	Profit_factor	Ganancia media	Pérdida media	Trades
1	10	1	23.27	28.14	1.11	13.25	12.18	2
1	30	1	23.14	26.75	1.12	13.3	9.25	84
1	50	1	27.32	25.46	1.16	13.45	7.92	97
1	100	1	7.65	30.42	1.04	13.06	10.05	58
1	150	1	8.37	22.03	1.05	13.63	6.83	94
1	200	1	13.23	27.56	1.07	13.13	9.38	43
1	10	2	22.78	28.24	1.1	13.25	12.21	0
1	30	2	7.78	28.99	1.04	13.48	8.84	90
1	50	2	38	22.14	1.23	13.93	7.55	97
1	100	2	0	0	NaN	NaN	0	10
1	150	2	-2.48	30.32	0.98	13.27	5.45	86
1	200	2	9.4	33.68	1.05	13.58	8.72	58
2	10	1	1.5	0	Inf	7.52	0	76
2	30	1	-9.19	18.53	0.9	12.74	3.07	175
2	50	1	32.71	19.71	1.24	12.97	5.78	117
2	100	1	11.54	21.85	1.08	11.76	6.09	48
2	150	1	0.55	20.44	1.01	14.16	1.77	120
2	200	1	22.78	28.24	1.1	13.25	12.21	0
2	10	2	1.1	1.7	1.28	12.42	0.11	57
2	30	2	-0.99	4.5	0.88	11.8	0.22	43
2	50	2	-0.03	31.97	1	12.75	6.48	23
2	100	2	-1.2	29.28	0.99	12.46	5.35	74
2	150	2	16.07	29.74	1.08	13.15	10.89	1
2	200	2	0	0	NaN	NaN	0	0
Estrategia Buy&Hold			56.16	55.88	1.08	42.04	39.42	0

Tabla 5, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en corto.

Los resultados de rentabilidad se muestran en la Figura 28. Operando en corto se observa que los sistemas con 50 datos de entrada obtienen mejores resultados que el resto, lo que guarda cierta relación con los resultados del entrenamiento. También se observa que en este periodo se han dado más situaciones de operar en corto que de operar en largo, por lo que los sistemas que hayan aprendido estas tendencias serán mejores. También se puede observar que la rentabilidad nunca es mayor que la de la estrategia B&H en corto.




Figura 28, Rentabilidad de los sistemas entrenados mediante aprendizaje supervisado operando en corto.

Además, a la hora de analizar el nivel de riesgo, se puede comprobar en la Figura 29 que las redes han asumido un riesgo mucho menor, ya que el DrawDown máximo es menor que el de la estrategia B&H.




Figura 29, Máximo DrawDown de los sistemas entrenados mediante aprendizaje supervisado operando en corto.

Se puede comprobar de manera general que los resultados a la hora de invertir en corto son claramente mejores que a la hora de invertir en largo, ya que el periodo de estudio tiene más situaciones bajistas que alcistas (Figura 30).




Figura 30, Profit factor de los sistemas entrenados mediante aprendizaje supervisado operando en corto.

Del análisis del profit factor se puede extraer que todas las redes tienen beneficios similares, y que son superiores al de la estrategia B&H, lo que implica que la mayoría de los sistemas están operando adecuadamente.

5.4. Resultados operando en largo y en corto.

Se combinan ahora las dos posibilidades, permitiendo al sistema que efectúe operaciones en largo y en corto. De este análisis se pueden extraer las mejores conclusiones ya que es el que está directamente vinculado a la estrategia de entrenamiento y selección de las redes. Los resultados del estudio se muestran en la Tabla 6. Los sistemas se han agrupado de la misma forma que en el capítulo anterior. En la tabla se pueden observar los resultados de rentabilidad, el máximo Drawdown, el profit factor, la ganancia media, la pérdida media y el número de operaciones.

Inversión largo y en corto en corto									
Margen	Nº datos de entrada	Nº capas ocultas	Rentabilidad	maxDrawDown	Profit_factor	Ganancia media	Pérdida media	Trades	
1	10	1	23.27	28.14	1.11	13.25	12.18	2	
1	30	1	36.72	25.02	1.19	14.3	9.72	90	
1	50	1	32.77	27.38	1.13	16.89	12.29	130	
1	100	1	-0.74	28.65	1	13.3	11.13	65	
1	150	1	-7.3	36.44	0.98	17.95	14.85	156	
1	200	1	15.68	32.96	1.07	14.31	12.07	63	
1	10	2	22.78	28.24	1.1	13.25	12.21	0	
1	30	2	7.41	29.1	1.03	14.16	10.1	107	
1	50	2	68.1	11.73	1.32	16.97	10.87	130	
1	100	2	-31.54	46.3	0.92	20.71	18.66	20	
1	150	2	-44.61	53.14	0.84	15.6	12.96	129	
1	200	2	-24.93	61.13	0.9	14.16	12.53	84	
2	10	1	-39.48	45.03	0.83	22.11	8.56	150	
2	30	1	-34.53	42.31	0.85	16.87	9.04	247	
2	50	1	35.32	31.04	1.2	14.67	7.96	135	
2	100	1	8.61	22.38	1.06	11.76	6.22	48	
2	150	1	-15.97	47.91	0.93	19.2	9.7	171	
2	200	1	22.78	28.24	1.1	13.25	12.21	0	
2	10	2	-49.81	50.42	0.48	14.62	2.9	98	
2	30	2	-33.61	51.22	0.88	18.9	12.42	73	
2	50	2	-11.84	38.48	0.94	13.64	8.52	32	
2	100	2	-2.01	32.61	0.99	14.2	6.7	82	
2	150	2	16.07	29.74	1.08	13.15	10.89	1	
2	200	2	0	0	NaN	NaN	0	0	

Tabla 6, Resultados de la gestión del capital con el sistema entrenado mediante aprendizaje supervisado operando en largo y en corto.

Analizando los resultados se puede observar que se da es un incremento de los beneficios, ya que con la misma red se operará bajo las dos posibilidades, lo que implica una mayor posibilidad de éxito (Figura 31).




Figura 31, Rentabilidad de los sistemas operando en largo y en corto.




Figura 32, Máximo DrawDown de los sistemas operando en largo y en corto.




Figura 33, Profit factor de los sistemas operando en largo y en corto.

De manera general se puede observar que los resultados son mejores cuando se toman 50 datos de entrada, de acuerdo con el entrenamiento. También se puede observar que los resultados son mejores cuando se pretende predecir un margen de variación del 1% en el precio, demostrando que ni la tasa sintética de éxito ni la tasa de acierto son estimadores de rendimientos futuros.

5.5. Comparación de las tres estrategias.

Para comparar las tres estrategias (corto, largo, B&H) se muestran las evoluciones del capital para los sistemas desarrollados. El sistema que se muestra a continuación tiene un margen de predicción de un 1% con 50 datos de entrada y una capa oculta (Figura 34).

Los resultados obtenidos son muy interesantes ya que se puede observar cómo la red aprende mejor las tendencias que más observa (es decir, tendencias alcistas). También la red comete fallos, aunque en general la gestión que lleva a cabo la red es realmente buena. Otra conclusión es que la red opera mejor cuando lo hace en los dos mercados, aunque también asume un mayor riesgo debido a que interviene un mayor número de veces.




Figura 34, Evolución del capital en función de la estrategia adoptada.

Se puede observar claramente (Figura 34) que se dan aciertos tanto operando en largo como operando en corto. El sistema gana más operando en corto que operando en largo ya que tiene un mayor número de eventos. En las tres estrategias los resultados son mejores que los de las estrategias B&H.

A continuación, se muestra el mismo análisis con el sistema de margen 2% y 100 datos de entrada y una capa oculta (Figura 35).




Figura 35, Evolución del capital en función de la estrategia.

En esta Figura 35 se muestra que, aunque haya sistemas mejores que el analizado en este caso, el comportamiento no es malo. Se aprecia que el sistema en corto no interviene ya que la red escogida no es buena para detectar subidas de precio, o bien no las detecta debido al

margen tomado. Sin embargo, sí que se observa que la gestión en corto genera resultados razonables con DrawDown contenidos.

5.6. Sistema experto.

Como se ha comentado anteriormente, existen técnicas que permiten mejorar los resultados y el riesgo asumido por los sistemas desarrollados. En este trabajo se ha integrado un sistema experto que, basado en el stoploss, el takeprofit y el punto de retirada del mercado, supervisa la gestión de la red neuronal y apoya en la toma de decisiones.

5.6.1. Configuración del sistema experto.

La retirada del mercado se realiza cuando las pérdidas superan el 20% del capital inicial invertido, que en este trabajo es de 1000\$. El sistema se retirará del mercado cuando el capital baje de los 800\$. Sin embargo, esta retirada se efectuará una vez que la sesión en la que se active haya finalizado.

A la hora de fijar los stoploss y los takeprofit existen diversas alternativas. En este trabajo se han estudiado tres posibilidades.

A. Stoploss y takeprofit fijos.

La primera consiste en fijar el stoploss y el takeprofit a un porcentaje fijo sobre el precio de entrada al mercado. De esta forma los stoploss se calcularían en largo de acuerdo con la siguiente expresión (11).

$$\text{stoploss} = \text{OPEN} (1 - x) \quad (11)$$

Siendo x el porcentaje fijo en el que se situaría el stoploss. Por otro lado, el takeprofit se calcularía de la expresión (12):

$$\text{takeprofit} = \text{OPEN} (1 + x) \quad (12)$$

Siendo x el porcentaje fijo en el que se situaría el takeprofit.

Esta estrategia ha dado lugar a resultados muy malos dado que no había un análisis del histórico del mercado. En concreto, la volatilidad del Bitcoin hacía que saltaran los stoploss en sesiones en las que las redes acertaban con la predicción.

B. Stoploss y takeprofit en función del Average True Range (ATR).

El ATR es un parámetro que permite analizar la volatilidad de las sesiones anteriores. En función de dicha volatilidad es posible fijar puntos de stoploss y takeprofit mediante (13).

$$\text{ATR} = \frac{\text{HIGH} - \text{LOW}}{\text{OPEN}} \quad (13)$$

Así es posible coger los ATR de n sesiones anteriores (típicamente 7 o 14 sesiones) y en función de ese valor calcular los stoploss y los takeprofit con k veces el ATR según (14) y (15).

$$\text{stoploss} = \text{OPEN} (1 - k \text{ATR}) \quad (14)$$

$$\text{takeprofit} = \text{OPEN} (1 + k \text{ATR}) \quad (15)$$

Los resultados de esta estrategia tampoco han sido buenos ya que no se sabía con exactitud dónde situar el ATR. Además, la necesidad de utilizar parámetros diferentes para ajustar el stoploss y el takeprofit es evidente.

C. Stoploss y takeprofit en función de las máximas excursiones adversas (MAE) y las máximas excursiones favorables (MFE).

El MAE es una métrica que mide las pérdidas máximas parciales que tuvo una operación mientras estuvo abierta. Si se lleva a cabo una operación de compra, el MAE es la diferencia entre el precio de entrada y el precio más bajo que tuvo el activo financiero desde la apertura hasta que la operación se cerró (16).

$$\text{MAE} = \frac{\text{OPEN} - \text{LOW}}{\text{OPEN}} \quad (16)$$

En el caso de abrir una operación en corto, El MAE es la diferencia entre el precio de entrada y el precio más alto que tuvo el activo desde la apertura hasta el cierre de la operación (17).

$$\text{MAE} = \frac{\text{HIGH} - \text{OPEN}}{\text{OPEN}} \quad (17)$$

El MAE es una métrica sumamente útil para definir cuantitativamente dónde colocar los stoploss.

El MFE es una métrica que mide las ganancias máximas parciales de la operación mientras estuvo abierta. Si se abre una operación de compra, el MFE es la diferencia entre el precio de entrada y el precio más alto que tuvo el activo financiero desde la apertura hasta que la operación se cerró (18).

$$\text{MFE} = \frac{\text{HIGH} - \text{OPEN}}{\text{OPEN}} \quad (18)$$

En el caso de abrir una operación en corto, el MFE es la diferencia entre el precio de entrada y el precio más bajo que tuvo el activo desde la apertura hasta el cierre de la operación (17).

$$\text{MFE} = \frac{\text{OPEN} - \text{LOW}}{\text{OPEN}} \quad (19)$$

El MFE permite definir cuantitativamente dónde colocar los takeprofit.

Para calcular el MAE y el MFE se puede utilizar un cálculo dinámico como en el ATR o se puede analizar los MAE y los MFE de periodos anteriores (Figura 36).

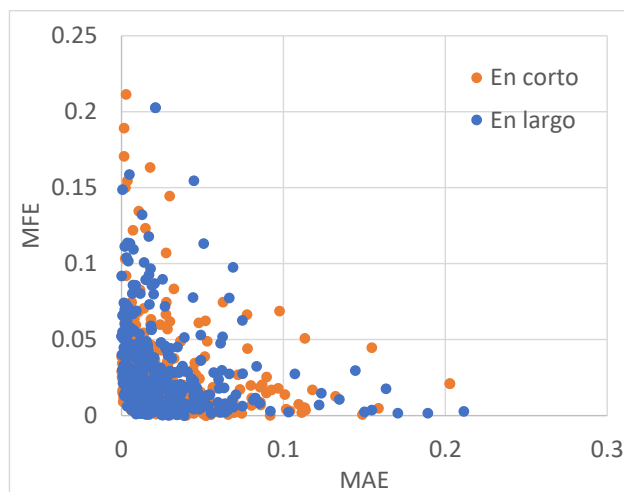


Figura 36, MFE frente a MAE en largo y en corto en el periodo de selección de redes neuronales.

De esta forma se ha decidido fijar el MAE en un 5% y el MFE en un 2%. Los stoploss y takeprofit se fijarán en largo de acuerdo con las siguientes expresiones (20) y (21).

$$\text{stoploss} = \text{OPEN} (1 - \text{MAE}) \quad (20)$$

$$\text{takeprofit} = \text{OPEN} (1 + \text{MFE}) \quad (21)$$

Mientras que en corto las expresiones son (22) y (23):

$$\text{stoploss} = \text{OPEN} (1 + \text{MFE}) \quad (22)$$

$$\text{takeprofit} = \text{OPEN} (1 - \text{MAE}) \quad (23)$$

De esta forma se ha planteado el sistema experto que actúe por encima de los resultados del sistema de gestión del capital.

5.6.2. Resultados del sistema experto.

Se muestran los resultados del sistema operando en largo y en corto con las redes entrenadas para predecir un cambio del 1% en el precio del Bitcoin (Tabla 7).

Inversión largo y en corto en corto								
Margen	Nº datos de entrada	Nº capas ocultas	Rentabilidad	maxDrawDown	Profit_factor	Ganancia media	Pérdida media	Nº Movimientos
1	10	1	13.68	26.93	1.03	31.69	20.98	466
1	30	1	-11.16	30.45	0.95	32.89	6.97	246
1	50	1	14.82	26.97	1.03	31.68	19.28	464
1	100	1	-19.51	30.74	0.92	25.05	9.16	330
1	150	1	-28.4	31.28	0.55	28.7	1.78	72
1	200	1	-21.42	30.94	0.9	28.59	7.15	266
1	10	2	11.45	26.93	1.03	31.23	20.77	468
1	30	2	-2.22	30.12	0.99	35.31	7.16	258
1	50	2	53.6	26.08	1.12	34.21	19.14	478
1	100	2	-32.84	33.11	0.43	17.78	1.64	46
1	150	2	-29.1	33.29	0.61	28.64	2.15	72
1	200	2	-27.62	30.48	0.66	28.26	2.35	94

Tabla 7, Tabla de resultados con el sistema experto operando en largo y en corto.

Se puede observar en la Tabla 7 que tras la aplicación del sistema experto no se han conseguido mejores resultados. Probablemente esto sea debido a que los puntos de stoploss y takeprofit no se han escogido de forma adecuada lo que produce que, en las sesiones con buenos resultados, estos no sean todo lo buenos que podrían haber sido y que haya situaciones en las que el sistema se salga del mercado en pérdidas cuando la red ha acertado en la predicción.

También hay que tener en cuenta que este sistema actúa bajo la hipótesis más pesimista ya que se está suponiendo que el LOW se alcanza antes que el HIGH, lo que provoca que se evalúe antes el stoploss que el takeprofit.

5.7. Análisis del sistema de gestión del capital.

De manera general a lo largo de la prueba se puede observar que se cumplen las siguientes afirmaciones:

- Los sistemas que mejor responden son los que operan en largo y en corto, ya que las redes han sido entrenadas para predecir subidas y bajadas.
- Los sistemas más seguros son los que operan en largo, ya que los incrementos son las situaciones que se dan con más frecuencia durante el periodo de entrenamiento, por lo que durante la prueba las redes saben predecir mejor si se van a dar estas situaciones.
- Es muy difícil predecir en la fase de entrenamiento si el sistema se va a comportar adecuadamente en la fase de prueba, ya que situaciones pasadas no tienen por qué replicarse en el futuro.
- En el caso del Bitcoin se ha observado que tratar de predecir con un margen del 1% y utilizar información desde 50 días atrás resulta ser la mejor estrategia.
- En el caso específico del Bitcoin, debido a la volatilidad de la criptomoneda, fijar un stoploss y un takeprofit pueden ser herramientas útiles siempre y cuando estos sean los adecuados. Unos malos stoploss y takeprofit pueden suponer un empeoramiento drástico de los resultados del sistema de gestión.

6. CAPÍTULO 6: Sistema de gestión del capital en base a aprendizaje por refuerzo.

En este capítulo se ha planteado una estrategia de entrenamiento mediante aprendizaje por refuerzo, con la idea de llevar a cabo un estudio para determinar qué sistema de entrenamiento de redes neuronales es mejor para sistemas que operen en el mercado del Bitcoin.

Como ya se ha explicado anteriormente, el aprendizaje por refuerzo es un método de entrenamiento que consiste en otorgar recompensas al sistema si se efectúan “buenas acciones” y castigarlo si las acciones son malas.

En este caso se ha desarrollado un sistema de gestión del capital que opera únicamente en largo, partiendo del desarrollado por [21], y se ha modificado para incluir acceso a la base de datos del Bitcoin, lo que permite ofrecer la posibilidad de que el sistema opere solamente con un activo y modificar el rango de fechas en las que operará el sistema, entre otra serie de modificaciones que han sido requeridas a lo largo del desarrollo.

El funcionamiento del sistema difiere en ciertos aspectos del sistema desarrollado previamente en este trabajo. Aun así, los datos se obtienen de forma similar, se accede a un servidor online y se descargan los datos de cierre que posteriormente serán utilizados para el entrenamiento de la red. Los sistemas también son similares en cuanto que operan con todo el capital, es decir, si compran Bitcoins, compran por valor de todo el capital disponible, y si los venden, venden todos los activos que tienen en posesión.

La principal diferencia entre el sistema desarrollado para las redes con aprendizaje supervisado y las de aprendizaje por refuerzo radica en que este último opera de forma dinámica y aleatoriza la acción sobre el entorno. Es decir, si en la fase de prueba el sistema comete un error, éste aprende de dicho error, pero también tiene que generar salidas para explorar el entorno. Esto puede generar problemas ya que la repetitividad de la misma no es posible. La solución adoptada es ejecutar varias simulaciones sobre el mismo periodo de ensayo y obtener la media.

Además de esta primera diferencia, existe otra importante: los datos introducidos no son únicamente los precios de cierre sino también los índices, como en [21]. Dichos índices son: el cambio de precio de cierre en un día, el cambio en dos días, el cambio en 7 días y el cambio con respecto a la media de los últimos 7 días. Con esas entradas el sistema tomará una decisión.

El aspecto más importante del aprendizaje por refuerzo es la asignación de recompensas. Por lo tanto, decidir cómo otorgar recompensas es un aspecto crucial dentro del aprendizaje por refuerzo. En este trabajo se han estudiado dos posibilidades de asignación de recompensas, en función del beneficio obtenido en la sesión o en función de la decisión adoptada.

6.1. Sistema de recompensa del entrenamiento por refuerzo.

El sistema de recompensa que se ha seguido parte de que cuando se compra no se otorga ninguna recompensa, dado que únicamente se está intercambiando dinero líquido por bitcoins. Por ello las recompensas se dan o bien cuando se mantiene o bien cuando se venden bitcoins. En ambos casos la recompensa se calcula en función del beneficio obtenido.

El valor de la recompensa puede asignarse, como se muestra en la Figura 37, en función del resultado económico, o en función de si la acción es buena o mala, Figura 38. Así cuando se gana dinero se recompensa al agente, mientras que cuando se pierde, se penaliza al sistema.

```

if Reward > 0 || Profit > 0
    Reward = Profit/prev_val;
elseif Reward < 0 || Profit < 0
    Reward = Profit/prev_val;
end

```

Figura 37, Función recompensa aprendizaje por refuerzo según resultado

```

if Reward > 0 || Profit > 0
    Reward = 1;
elseif Reward < 0 || Profit < 0
    Reward = -1;
end

```

Figura 38, Función recompensa aprendizaje por refuerzo según acción

Los periodos temporales utilizados para el estudio son los siguientes:

- Datos desde el 02/01/2015 hasta el 14/04/2021 para el entrenamiento.
- Datos desde el 15/04/2021 hasta el 15/04/2022 para el test.

Los entrenamientos se han realizado con un total de 2282 pasos que es el número de sesiones que se tienen en el periodo de entrenamiento y un límite de 20 episodios que es el número de veces que se repiten las simulaciones de todos los pasos (se han escogido 20 episodios porque a partir de ese punto las políticas no varían). En esta serie de ensayos, y al igual que en el capítulo anterior, el dinero inicial invertido es de 1000\$.

6.1.1. Recompensa en función del beneficio obtenido.

En este caso la prueba se basa en la modificación de los parámetros utilizados para ponderar la recompensa en función del beneficio obtenido. Los sistemas entrenados se simulan 100 veces para obtener datos promediados de los comportamientos que presentan. Los resultados se muestran en la Tabla 8.

Coeficiente Beneficio	Coeficiente Pérdida	Rentabilidad (%)	Máximo Draw Down (%)	Profit Factor	Ganancia Media	Pérdida Media
1	2	-3.73	39.29	0.97	26.15	7.99
1	1.5	-1.81	38.90	0.98	26.01	8.26
1	1.25	-4.27	41.99	0.97	25.96	10.15
1	1.1	-5.65	41.60	0.96	25.54	8.56
1	1	-2.55	40.76	0.97	25.56	8.35
1.1	1	-11.77	44.61	0.94	24.16	9.88
1.25	1	-0.52	41.50	0.98	27.00	9.54
1.5	1	-10.38	43.22	0.95	24.70	9.51
2	1	-16.02	45.75	0.93	23.06	10.78
Estrategia Buy&Hold		-35.9	52.98	0.91	19.19	20.94

Tabla 8, Tabla de resultados del sistema entrenado mediante aprendizaje reforzado basando la recompensa en el beneficio.

Los resultados gráficos se presentan en las Figura 39, Figura 40 y Figura 41.




Figura 39, Rentabilidad de los sistemas con aprendizaje por refuerzo ponderando el resultado.

Los resultados de rentabilidad obtenida por los sistemas (Figura 40) muestran que el aprendizaje por refuerzo es mucho mejor que la estrategia B&H, y que un coeficiente de pérdida de 1 y uno de ganancia de 1 es una buena estrategia de recompensa sobre el sistema.

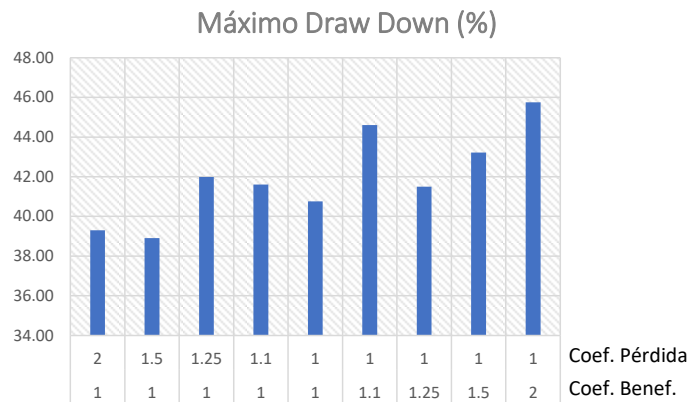


Figura 40, Máximo DrawDown de los sistemas con aprendizaje por refuerzo ponderando el resultado.

Analizando el máximo DrawDown (Figura 41) se aprecia que al tener un mayor coeficiente de pérdida que de ganancia el sistema de recompensa reduce el riesgo asumido. Los resultados en términos de riesgo también son mejores en el caso del aprendizaje por refuerzo.

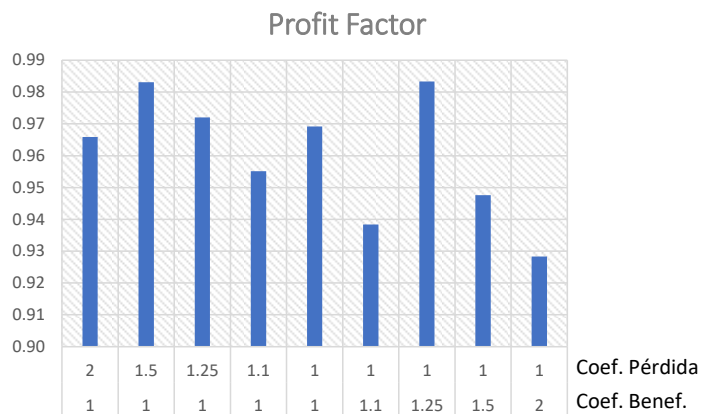


Figura 41, Profit factor de los sistemas con aprendizaje por refuerzo ponderando el resultado.

Los resultados del profit factor (Figura 42) están ligados a los de rentabilidad y máximo DrawDown. Se puede comprobar como tener un mayor coeficiente de pérdida que de ganancia en el sistema de recompensa mejora el profit factor.

A continuación, se muestran 5 simulaciones del sistema entrenado con un coeficiente de ponderación de la pérdida sobre el beneficio de 2 (Figura 42).




Figura 42, Evolución del capital en los sistemas con aprendizaje por refuerzo ponderando el resultado.

Se puede apreciar que las actuaciones del sistema son distintas dependiendo de las experiencias que vaya adquiriendo a lo largo de la prueba ya que la red puede ir entrenándose de manera que les dé más peso a las entradas de un índice que a las de otro.

Estos sistemas son capaces de anticipar las situaciones de crecimiento y en muchos casos también de anticipar las caídas. Hay que tener en cuenta que a lo largo de la serie de datos del precio del Bitcoin son más comunes las subidas que las caídas en el precio de la criptomoneda, por lo que no es de extrañar que los sistemas sean mejores anticipando este tipo de situaciones.

6.1.2. Recompensa en función de la decisión adoptada.

En este caso, como se ha explicado anteriormente, lo que se hace es recompensar en función de la decisión que se adopte, de tal manera que si el sistema toma una buena decisión que le lleva a obtener un beneficio, se le recompensa sin atender a la cuantía del beneficio obtenido. De la misma forma, si el sistema toma una mala decisión se le castiga con independencia de la cuantía perdida. En este caso, se recompensa que la red acierte la tendencia, de manera similar al entrenamiento mediante aprendizaje supervisado. Los resultados obtenidos se muestran en la Tabla 9.

Valor Beneficio	Valor Pérdida	Rentabilidad (%)	Máximo Draw Down (%)	Profit Factor	Ganancia Media	Pérdida Media
1	-2	0.00	0.00	0.00	0.00	0.00
1	-1.5	3.18	20.58	1.08	26.49	1.60
1	-1.25	-9.59	45.77	0.96	26.03	12.52
1	-1.1	-11.48	42.86	0.94	26.38	9.84
1	-1	-8.83	45.28	0.96	23.27	14.04
1.1	-1	-7.10	44.80	0.96	24.48	11.38
1.25	-1	-20.28	49.68	0.95	23.80	23.91
1.5	-1	-19.57	50.39	0.95	23.69	23.16
2	-1	-22.10	50.08	0.95	23.63	23.52
Estrategia Buy&Hold		-35.9	52.98	0.91	19.19	20.94

Tabla 9, Tabla de resultados del sistema entrenado mediante aprendizaje reforzado basando la recompensa en la decisión.

La representación gráfica de los resultados se muestra en las Figura 43, Figura 44 y Figura 45.




Figura 43, Rentabilidad de los sistemas con aprendizaje por refuerzo ponderando la decisión.

El primer resultado que se puede apreciar (Figura 44) claramente es que todas las rentabilidades están por encima de la estrategia B&H, y que evaluar las buenas jugadas por encima de las malas lleva a peores resultados medios de los sistemas. Por el contrario, el mejor funcionamiento en términos de rendimiento se da cuando se penaliza las malas decisiones por encima de las buenas. Sin embargo, hay que tener cuidado con aumentar el valor del coeficiente de pérdida de las malas decisiones, ya que se puede llegar a entrenar un comportamiento ávaro.

Al contrario que cuando se penaliza en función del beneficio obtenido, el máximo DrawDown (Figura 45) no disminuye hasta que se penaliza mucho la pérdida. Esta situación hace ver que las pérdidas ocasionadas durante el periodo de prueba son elevadas, pero al penalizarse igual que las que no lo son, el sistema no es capaz de reducir el riesgo con el que opera.

En la Figura 46 se observa que el profit factor está relacionado con los resultados anteriores, y en todos los caso es superior al de la estrategia B&H.

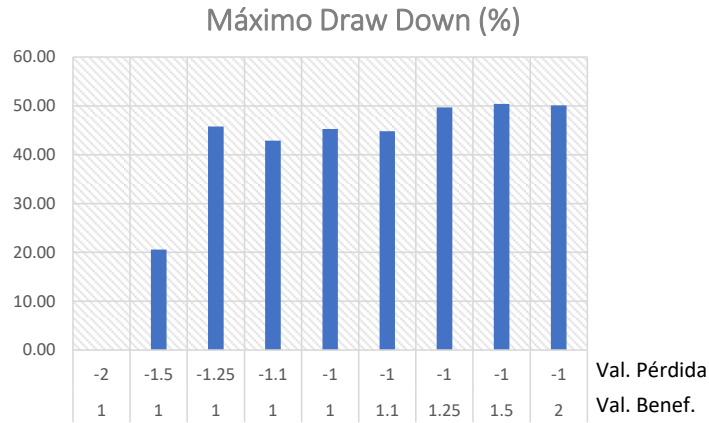


Figura 44, Máximo DrawDown de los sistemas con aprendizaje por refuerzo ponderando la decisión.




Figura 45, Profit factor de los sistemas con aprendizaje por refuerzo ponderando la decisión.

A continuación, se muestra la evolución en el caso de que el sistema esté entrenado con un coeficiente de pérdida para las malas decisiones de -1.5 y las buenas con un coeficiente de beneficio de 1 (Figura 46). En la figura se puede observar la evolución temporal de las diferentes simulaciones de las carteras gestionadas por el sistema entrenado mediante aprendizaje por refuerzo en el periodo de ensayo.




Figura 46, Evolución del capital en los sistemas con aprendizaje por refuerzo ponderando la decisión.

En el estudio se puede apreciar que el aumento del coeficiente de pérdida a sobre el de beneficio ha dado lugar a mejores resultados. El agente ha aprendido correctamente cómo actuar cuando el precio va a subir y a pararse cuando el precio cae. Así se consigue que la red aprenda a realizar predicción de tendencias, independientemente del margen que se requiera.

6.2. Análisis de los sistemas de gestión basados en redes neuronales con aprendizaje por refuerzo.

Del entrenamiento mediante aprendizaje por refuerzo de los sistemas de gestión del capital se pueden extraer varias conclusiones:

- Los sistemas de gestión del capital en base a aprendizaje por refuerzo se pueden utilizar para gestionar capitales en mercados de criptodivisas.
- Es posible actuar sobre la función recompensa para modificar el resultado del aprendizaje.
- Los agentes siguen aprendiendo de su interacción con el entorno y además han de interaccionar con él incluso cuando se está en fase de entrenamiento.
- Se puede hacer que el agente aprenda en función de la recompensa obtenida o en función de si la acción que ha realizado es buena o mala.
- Es posible plantear un sistema de gestión que reparta el capital disponible entre varios sistemas como el desarrollado con el fin de diversificar la inversión.
- En el caso específico del Bitcoin es mejor tener un mayor coeficiente de pérdida que sobre el beneficio en la función de recompensa, ya que mejora la seguridad de los sistemas.
- De manera general se viene observando que cuando se penaliza mucho la pérdida, lo que ocurre es que el sistema coge “miedo” y decide no invertir. Por otro lado, si se premia mucho la ganancia, el sistema se puede volver muy agresivo y asumir riesgos mucho mayores.
- Para este problema específico es mejor trabajar premiando la decisión que premiando el beneficio, ya que premiando la decisión se consigue que el sistema aprenda las tendencias buscadas independientemente del valor final que se alcance tras la tendencia.

- Los sistemas de gestión del capital en base a aprendizaje por refuerzo no aseguran el éxito futuro de la inversión, ya que hay muchos parámetros que pueden entrar en juego y que el sistema no haya aprendido o experimentado hasta el momento. Esto confirma que los rendimientos pasados no implican rendimientos futuros.

7. CAPÍTULO 7: Conclusiones y trabajos futuros.

7.1. Conclusiones.

El desarrollo de este trabajo ha llevado a la obtención de una serie de conclusiones y también ha dejado abiertas varias líneas de investigación para asistir a operaciones en mercados de criptomonedas.

7.1.1. Conclusiones obtenidas del estudio de sistemas de capital con redes neuronales con aprendizaje supervisado.

Para llevar a cabo esta parte del estudio se ha desarrollado una herramienta en Matlab que permite entrenar y evaluar el entrenamiento de redes neuronales para predicción de valores y tendencias de criptomonedas variando su configuración (número de neuronas, capas ocultas y entradas). El análisis se ha enfocado desde dos puntos de vista, predecir la tendencia del precio del bitcoin y predecir el valor futuro que va a tener esta criptomoneda.

Tras el estudio se ha determinado que las redes MLP son buenas para predecir tendencias en el precio del bitcoin, por lo que se ha desarrollado un sistema de gestión del capital en base a las redes neuronales entrenadas previamente, y se ha ensayado para todas las redes con distintas opciones de operación (en largo, en corto y en largo y en corto). Se pueden extraer las siguientes conclusiones:

- Las redes neuronales son una técnica adecuada para modelar mercados financieros. De hecho, son capaces de competir con los métodos estadísticos y matemáticos empleados en este campo.
- La configuración de las redes neuronales afecta a la capacidad de modelar el mercado. Por lo tanto, se ha implementado un proceso iterativo de optimización para buscar, para cada situación, la configuración que mejor modela el mercado financiero a estudiar.
- También las redes neuronales son una buena alternativa a la hora de gestionar activos.
- Las redes MLP se pueden utilizar para hacer un seguimiento del valor del precio del Bitcoin con errores relativos medios de hasta el 3,5%.
- Las redes neuronales funcionan bien prediciendo tendencias de los mercados. Sin embargo, debido a la "falta de información", las redes neuronales no son capaces de predecir acontecimientos puntuales e inesperados.
- El error cuadrático medio y el error absoluto medio son buenos estimadores de la bondad de la red cuando ésta está operando.
- Es posible entrenar una red neuronal que gestione una cartera de activos o criptomonedas.
- A pesar de no ser capaces de predecir acontecimientos inesperados, las redes neuronales sí pueden anticipar las tendencias posteriores a dichos sucesos.
- La predicción de tendencias en los mercados depende en gran medida de la discretización que se haga en las tendencias. El tomar como un cambio una situación común es un error que puede llevar a un mal entrenamiento de la red.
- A la hora de escoger redes neuronales para operar en mercados financieros, el hecho de que una red tenga una mayor tasa de predicción no implica que tenga una mayor tasa de éxito.
- Se consigue reducir el riesgo de pérdida de capital ante la mayor parte de las situaciones, incluso ante una crisis del mercado.

- Los sistemas que mejor responden son los que operan en largo y en corto, ya que las redes han sido entrenadas para predecir subidas y bajadas.
- Los sistemas más seguros son los que operan en largo, ya que los incrementos son las situaciones que se dan con más frecuencia durante el periodo de entrenamiento, por lo que, durante la prueba, las redes saben predecir si se van a dar estas situaciones con mayor certeza.
- Es muy difícil predecir en la fase de entramiento si el sistema se va a comportar adecuadamente en la fase de ensayo, ya que situaciones pasadas no tienen por qué replicarse en el futuro.
- En el caso del Bitcoin se ha observado que tratar de predecir con un margen del 1% y utilizar información desde 50 días atrás resulta ser la mejor estrategia.
- En el caso específico del Bitcoin, debido a la volatilidad de la criptomoneda, fijar un stoploss puede resultar realmente contraproducente cuando se utiliza una red neuronal entrenada para predecir resultados diarios.
- De manera general la predicción de tendencias en el Bitcoin es mejor cuando el mercado está en una fase alcista, ya que el entrenamiento de las redes dispone de una mayor cantidad de situaciones alcistas que bajistas, lo que provoca que para las redes sea más fácil aprender estas dinámicas.
- En predicción de valores, los mejores resultados también se obtienen con un número de datos de entrada de 50.
- En términos de efectividad es mejor entrenar las redes neuronales para predecir la tendencia del activo a un día vista que entrenarlas para que predigan el valor futuro y, a partir de ahí, extraer la tendencia. Esto es debido a que, a la hora de predecir el valor, el error relativo cometido es del orden del 3,5%, valor claramente superior al 1% o 2% que se quiere predecir en tendencia.
- Es posible aplicar un sistema experto que tome decisiones a un nivel superior que la red fijando puntos de stoploss y takeprofit, pero una mala configuración de este sistema experto puede llevar a resultados nefastos.

7.1.2. Conclusiones obtenidas del estudio de sistemas entrenados con aprendizaje por refuerzo.

Se ha llevado a cabo un estudio sobre gestión de activos en mercados de criptomonedas mediante sistemas de aprendizaje por refuerzo, desarrollando una aplicación en Matlab que permite agilizar el proceso de entrenamiento de redes neuronales con esta técnica. Se ha llevado a cabo un estudio sobre cómo la ponderación de los parámetros que determinan la recompensa o el castigo del agente afectan a los resultados.

A partir del estudio se pueden extraer las siguientes conclusiones:

- Los sistemas de gestión del capital en base a aprendizaje por refuerzo se pueden utilizar para gestionar capitales en mercados de criptodivisas ya que se ayudan a decidir cuándo invertir o incluso se pueden utilizar para decidir cuánto y cómo invertirlo.
- La función recompensa del sistema de aprendizaje por refuerzo es trascendental para el entrenamiento, de modo que un sistema entrenado mediante aprendizaje por refuerzo puede tener comportamientos muy dispares según cual sea la función recompensa que se integre en el entorno.
- Los sistemas de aprendizaje por refuerzo funcionan mejor en términos de riesgo que los sistemas basados en aprendizaje supervisado a la hora de gestionar activos

altamente volátiles, como es el caso del Bitcoin, ya que se encuentran actualizados en todo momento y aprenden durante la fase de entrenamiento.

- En los sistemas basados en aprendizaje por refuerzo ocurre lo mismo que en los sistemas de aprendizaje supervisado, es más importante ganar mucho cuando se gana que ganar muchas veces.
- Es posible hacer que el agente aprenda en función de la recompensa obtenida o en función de si la acción que ha realizado es buena o mala. Sabiendo que hay otras muchas posibilidades, en este estudio, se han barajado estas dos opciones.
- Es posible plantear un sistema de gestión que reparta el capital disponible entre varios sistemas como el desarrollado con el fin de diversificar la inversión y así diversificar el riesgo de vicios en la aleatoriedad del proceso de exploración del entorno.
- En el caso específico del aprendizaje por refuerzo del Bitcoin es mejor penalizar en mayor medida las pérdidas que la recompensa por las ganancias, ya que los sistemas aprenden a ser más seguros.
- Al principio de la operación los sistemas basados en aprendizaje por refuerzo presentan un comportamiento ávaro, ya que requieren 7 datos de entrada para recabar información de la situación del mercado.
- Los sistemas entrenados mediante aprendizaje por refuerzo son más seguros que los sistemas B&H.
- De manera general se viene observando que cuando se penaliza mucho la pérdida, lo que ocurre es que el sistema coge “miedo” y decide no invertir. Por otro lado, si se premia mucho la ganancia, el sistema se puede volver muy agresivo y asumir riesgos mucho mayores. Por esta razón es preciso ensayar límites a las ponderaciones de los distintos sistemas.
- Se ha observado experimentalmente que para el problema específico tratado es mejor trabajar premiando la decisión que premiando el beneficio, ya que premiando la decisión se consigue que el sistema aprenda las tendencias buscadas independientemente del valor final que se alcance tras la tendencia.
- Los sistemas basados en aprendizaje supervisado se comportan peor que los basados en aprendizaje por refuerzo en el mercado del Bitcoin, dado que no precisan de un análisis previo para discretizar cuando se considera que el precio de un activo va a subir o a bajar. Es decir, no precisan de la intervención de un operador, lo que reduce los riesgos.
- Los sistemas de gestión del capital en base a aprendizaje por refuerzo no aseguran el éxito futuro de la inversión ya que hay muchos parámetros que pueden entrar en juego y que el sistema no ha aprendido o experimentado hasta el momento. Esto confirma que los rendimientos pasados no implican rendimientos futuros.

7.2. Trabajos futuros.

El desarrollo de este trabajo deja abiertas muchas líneas de trabajo. A continuación, se van a enumerar algunas:

- Los puntos de stoploss y takeprofit en el mercado del Bitcoin es un aspecto que merece más investigaciones.
- A la hora de modelar el mercado con aprendizaje supervisado se podría llevar a cabo una futura investigación en las que se introdujeran entradas externas que permitieran adelantarse a situaciones poco predecibles.

- Se puede ampliar el estudio del aprendizaje supervisado a más tipos de redes neuronales, como las redes LSTM que parecen mejores para predicción de tendencias que las redes MLP.
- Se podrían buscar nuevas funciones de recompensa para el aprendizaje por refuerzo. Este es un campo que presenta una gran cantidad de posibilidades ya que el entrenamiento de los agentes depende en gran medida de la recompensa recibida.
- Se podría diseñar un sistema experto que actuara también sobre el aprendizaje por refuerzo.
- Se podrían desarrollar estudios similares en otras criptomonedas o activos.

8. CAPÍTULO 8: Bibliografía

- [1] R. Naranjo, A. Meco, J. Arroyo y M. Santos, «An Intelligent Trading System with Fuzzy,» *INTERNATIONAL JOURNAL OF INTELLIGENT SYSTEMS*, p. 963–983, 2015.
- [2] R. Naranjo, J. Arroyo y M. Santos, «Fuzzy modeling of stock trading with fuzzy candlesticks,» *Expert Systems With Applications*, pp. 17-27, 2018.
- [3] R. Naranjo y M. Santos, «A fuzzy decision system for money investment in stock markets based on fuzzy candlesticks pattern recognition,» *Expert Systems with Applications*, pp. 34-48, 2019.
- [4] J. Barrios, «Health Big Data,» 2 septiembre 2021. [En línea]. Available: <https://www.juanbarrios.com/redes-neurales-convolucionales/>.
- [5] «Aplicaciones de Machine Learning,» 2 septiembre 2021. [En línea]. Available: <https://www.aprendemachinelearning.com/aplicaciones-del-machine-learning/#supervisado>.
- [6] Jan van den Berg, Uzay Kaymak y Willem-Max van den Bergh, «Financial markets analysis by using a probabilistic fuzzy modelling approach,» *International Journal of Approximate Reasoning*, p. 291–305, 2003.
- [7] S. Velankar, S. Valecha y S. Maji, «Bitcoin Price Prediction using Machine Learning,» *International Conference on Advanced Communications Technology(ICACTION)*, 2018.
- [8] A. Ayodele A., A. Charles K., A. Marion O. y O. Sunday O., «Stock Price Prediction using Neural Network with Hybridized,» *Stock Price Prediction using Neural Network with Hybridized*, pp. 1-9, 2012.
- [9] N. Mahdi Pakdaman , T. Hamidreza y H. Baradaran Hashemi, «Stock Market Value Prediction Using Neural Networks,» *IEEE*, 2010.
- [10] HUISU JANG y JAEWOOK LEE, «An Empirical Study on Modeling and Prediction of Bitcoin Prices With Bayesian Neural Networks Based on Blockchain Information,» *IEEE Access*, pp. 5427-5437, 2017.
- [11] Kejsi Struga y Olti Qirici, «Bitcoin Price Prediction with Neural Networks,» pp. 1-9, 2019.
- [12] Aniruddha Dutta, Saket Kumar y Meheli Basu, «A Gated Recurrent Unit Approach to Bitcoin Price Prediction,» *Journal of Risk and Financial Management*, pp. 1-16, 2020.
- [13] Z. Chen, C. Li y W. Sun, «Bitcoin price prediction using machine learning: An approach,» *Journal of Computational and Applied*, 2020.
- [14] Sean McNally, Jason Roche y Simon Caton, «Predicting the Price of Bitcoin Using Machine Learning,» *26th Euromicro International Conference on Parallel, Distributed, and Network-Based Processing*, 2018.

- [15] Edwin Sin y Lipo Wang, «Bitcoin Price Prediction Using Ensembles of Neural Networks,» *13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD 2017)*, 2017.
- [16] Suhwan Ji, Jongmin Kim y Hyeonseung Im, «A Comparative Study of Bitcoin Price Prediction Using Deep Learning,» *Mathematics*, pp. 1-20, 2019.
- [17] Rahmat Albariqi y Edi Winarko, «Prediction of Bitcoin Price Change using Neural Networks,» *2020 International Conference on Smart Technology and Applications (ICoSTA)*, pp. 1-40, 2020.
- [18] Z. Jiang y J. Liang, «Cryptocurrency Portfolio Management with Deep Reinforcement Learning,» de *Intelligent Systems Conference*, London, UK, 2017.
- [19] Zihao Zhang, Stefan Zohren y Stephen Roberts, «Deep Reinforcement Learning for Trading,» pp. 1-16, 2019.
- [20] NINJATRADER, «NINJATRADER_SUPPORT,» 31 8 2021. [En línea]. Available: https://ninjatrade.com/es/support/helpGuides/nt8/?language_reference_wip.htm.
- [21] D. Willingham, «Reinforcement Learning for Financial Trading Retrieved,» 31 August 2021. [En línea]. Available: https://github.com/matlab-deep-learning/reinforcement_learning_financial_trading.
- [22] M. Hudson Beale, M. T. Hagan y H. B. Demuth, *Deep Learning Toolbox Reference*, Natick, MA 01760-2098: The MathWorks, Inc., 2021.
- [23] The MathWorks, Inc., *Financial Toolbox User's Guide*, Natick, MA 01760-2098: The MathWorks, Inc., 2021.
- [24] Mathworks Ink., «Aplicación de aprendizaje de regresión,» 30 8 2021. [En línea]. Available: <https://es.mathworks.com/help/stats/regression-learner-app.html>.
- [25] «alphavantage,» 9 septiembre 2021. [En línea]. Available: <https://www.alphavantage.co/>.

9. Listado siglas, abreviaturas y acrónimos.

- ATR: Average True Range
- BTC: Bitcoin.
- B&H: Buy and Hold.
- CLOSE: Precio de cierre en una sesión.
- ETH: Ethereum.
- EUR: Euros.
- FN: Falso negativo.
- FP: Falso positivo.
- GPR: Gaussian Process Regression Models.
- HIGH: Precio máximo alcanzado en una sesión.
- K-nn: k-nearest neighbours.
- LOW: Precio mínimo alcanzado en una sesión.
- LRM: Linear Regression Models.
- MAE: Máximas excursiones adversas.
- MFE: Máximas excursiones favorables.
- MLP: Multi layered Perceptron.
- ML: Machine Learning.
- NN: Neural Network.
- OPEN: Precio de apertura en una sesión.
- RL: Reinforced Learning.
- RMS: Error Cuadrático Medio.
- SVM: Support Vector Machines.
- TN: Verdadero negativo.
- TP: Verdadero positivo.
- USD: Dólares.