

CAPÍTULO VI

Aprendizaje automático aplicado a la compraventa de criptomonedas

Gian Pietro Enzo Bellocca*

En los últimos años, las criptomonedas se han convertido en un nuevo activo financiero, atrayendo el interés especialmente de los pequeños inversores privados. Estudios recientes muestran que este nuevo mercado es particularmente inestable y propenso a anomalías de precio como el efecto *momentum*. Este trabajo tiene como objetivo proporcionar una visión general de la tecnología *blockchain* y cómo ha llevado al nacimiento de una nueva moneda digital. Posteriormente, se centra en la predicción y explotación del efecto *momentum* durante la actividad de inversión, centrándose en los períodos recientes de mercado alcista (2021) y de crisis (2022). En concreto, los modelos de aprendizaje automático pueden predecir, mediante el análisis de grandes bases de datos, la volatilidad de los precios a corto plazo, aumentando el rendimiento de la inversión en comparación con los enfoques tradicionales.

Palabras clave: *blockchain*, criptomonedas, aprendizaje automático, comercio de criptomonedas.

* El autor agradece a la profesora Pilar Poncela el apoyo brindado para la realización de este trabajo.

1. INTRODUCCIÓN AL MERCADO DE LAS CRIPTOMONEDAS

Las criptomonedas son un mercado joven y poco estructurado que tiene características y comportamientos muy distintos de los que se encuentran en los mercados tradicionales, donde se negocian productos como acciones, bonos, divisas, materias primas y derivados. Antes de introducir el concepto de criptomoneda y explorar las peculiaridades de su mercado, en este capítulo se presentan las principales características de las monedas fiduciarias (fiat), de los pagos electrónicos y de la cadena de bloques (*blockchain*), que han llevado al nacimiento de esta nueva forma de moneda digital.

1.1. La moneda fiduciaria

Una moneda es una unidad económica de valor que funciona como un medio de intercambio reconocido en una economía. Con el fin de realizar su tarea de la manera más eficiente posible, una moneda debe poseer características precisas como ser fungible, duradera, portátil, reconocible y estable. Inicialmente, la moneda, en forma de dinero, tomó la forma de una moneda compuesta por metales preciosos, como el oro y la plata. Por lo tanto, el valor de cada moneda era dado por la cantidad de metal precioso de la que estaba compuesta la misma moneda. Posteriormente se introdujo un tipo de moneda en papel, cuyo valor estaba representado por un bien material llamado subyacente, que a menudo era un metal precioso. Esto permitió facilitar enormemente el transporte y, por lo tanto, el intercambio de dinero. Más tarde, el 15 de agosto de 1971, con el fin de los acuerdos de Bretton Woods sobre la convertibilidad del dinero en oro, terminó la era del dinero basado en subyacente y comenzó la del dinero fiduciario.

El dinero fiduciario es una moneda emitida por un organismo gubernamental, que no está respaldada por una mercancía física como el oro o la plata, sino más bien por una autoridad central. A diferencia de la forma anterior de dinero, cuyo valor se define por el valor del subyacente, el valor del dinero fiduciario se deriva de la relación entre la oferta y la demanda y de la estabilidad del gobierno emisor. Muchas monedas actuales son monedas fiduciarias, como el dólar estadounidense, el euro y muchas otras monedas mundiales importantes. El dinero fiduciario toma principalmente la forma de dinero efectivo, generalmente monedas y billetes que, cuando se transfieren a otra persona, formalizan automáticamente la transferencia del valor que representan, sin la necesidad de involucrar a un tercero en la transacción. En efecto, la principal ventaja del efectivo reside en el hecho de que su posesión certifica también la posesión del valor que representa. Además, el efectivo permite a cualquiera participar en el sistema de pagos, sin barreras ni exclusiones. Entre las desventajas, sin embargo, encontramos la necesidad de estar físicamente presentes en el momento de la transacción, el alto riesgo de robo y falsificación y la dificultad en el seguimiento de los pagos por parte de los organismos de control financiero y fiscal.

Como se mencionó anteriormente, las monedas fiduciarias tradicionales necesitan un sistema centralizado y una figura de garantía, como gobiernos y bancos centrales, que pue-

dan garantizar el valor del dinero y gestionar su emisión. Un ejemplo es el euro, gestionado por varios organismos institucionales, entre ellos el Banco Central Europeo (BCE), encargados de su correcto funcionamiento. En particular, los países que han adoptado la moneda común europea han encomendado al BCE la ejecución de la política monetaria, que consiste en aumentar o disminuir la emisión de dinero, con el objetivo de estimular el crecimiento económico y garantizar la estabilidad de precios manteniendo una baja inflación.

1.2. Pagos electrónicos

Un sistema de pago electrónico permite transferir dinero electrónicamente a través de los llamados *cash data files*. Este tipo de archivos permite acceder a las ventajas del dinero en efectivo, y también es capaz de moverse libremente en las redes electrónicas, lo que facilita el movimiento de dinero a través de transferencia bancaria, correos electrónicos o redes sociales, sin exigir a las dos partes interesadas que estén en el mismo lugar para realizar la transacción. Una de las mayores debilidades de estos archivos de datos es que se puede duplicar fácilmente y sin coste alguno (problema de doble gasto). Como resultado, no se pueden usar los datos en efectivo como un sistema de pago seguro y eficiente. Para superar este problema, los sistemas de pago electrónico se basan en una autoridad centralizada, normalmente un banco, que verifica la legalidad de los pagos y realiza un seguimiento del estado de las distintas cuentas bancarias y de su valor monetario. En este tipo de sistema de transferencia de dinero, cuando un comprador inicia un pago enviando un pedido, la autoridad centralizada se asegura de que el comprador tenga los fondos necesarios para la transacción y actualiza las cuentas de las dos partes involucradas. Sin embargo, un sistema de pago centralizado requiere fiabilidad y seguridad. Los agentes implicados deben confiar en la autoridad central a la que delegan el poder de mantener la contabilidad correctamente actualizada, sin tomar posesión del dinero. Además, los sistemas centralizados son vulnerables a ataques de *hackers* y fallos técnicos, por lo que, se deben garantizar que los fondos están seguros en todo momento.

1.3. Blockchain

La tecnología *blockchain* fue introducida en 2008 por un individuo o grupo de desarrolladores anónimos bajo el seudónimo de “Satoshi Nakamoto”, y consiste en un libro mayor digital descentralizado, que registra una serie de transacciones. Su nombre proviene de los términos *bloque* y *cadena* introducidos por Satoshi Nakamoto. De hecho, en una *blockchain*, todas las transacciones se agrupan en bloques que luego se encadenan secuencialmente. De esta manera, toda la cadena de bloques representa un registro completo de toda la historia de las transacciones.

En la cadena de bloques, cada bloque no solo contiene detalles sobre la transacción y su marca de tiempo (*timestamp*), sino también un valor aleatorio (*nonce*) y el valor *hash* del blo-

que anterior. Este valor *hash*, que consiste en una serie de longitud fija que identifica de forma única el bloque, se utiliza para verificar la integridad y la corrección de la cadena de bloques al almacenar los detalles de una transacción. El valor *hash* se produce utilizando una función *hash* criptográfica específica, que asigna datos de transacciones a una serie de longitud fija compuesta de números y letras. Por lo tanto, cualquier cantidad de datos siempre producirá una serie alfanumérica de la misma longitud, dependiendo de la función *hash* utilizada. Este sistema criptográfico permite evitar cualquier tipo de cambio fraudulento de datos dentro de los bloques, ya que cualquier tipo de cambio conduciría también a un cambio en los valores *hash* respectivos. Para añadir un nuevo bloque a la cadena es necesario que las transacciones contenidas en el bloque y el bloque sean verificadas por la mayoría de los nodos descentralizados que forman la red, a través de un mecanismo de consenso. Este mecanismo garantiza que toda la información que se agregará sea válida y establece las reglas que los nodos deben seguir para llevar a cabo las verificaciones necesarias. Prueba de trabajo (*Proof of Work – PoW*) es el mecanismo de consenso más popular, en el que se basa el algoritmo *Hash Cash*, utilizado por varias criptomonedas, incluido bitc in. Con este algoritmo, un nuevo bloque se valida a trav s de un proceso de extracci n (*mining*), que recompensa al primer nodo que resuelve un problema matem tico complejo. En el caso de las criptomonedas, el premio consiste en una nueva moneda generada o una porci n de ella. La probabilidad de verificar un nuevo bloque y recibir la recompensa depende de la capacidad del nodo extractor, llamado *minero*, en resolver el problema matem tico. Este problema complejo consiste en encontrar un valor aleatorio (*nonce*) que, combinado con el valor *hash* de las transacciones y el encabezado del bloque anterior, produce un valor dado preciso. Cuando uno de los nodos encuentra una posible soluci n al problema, lo env a a los otros nodos de la red, que luego pueden verificarlo. Si la mayor a de los nodos est n de acuerdo con el resultado, el bloque se verifica y se agrega a la cadena de bloques. El nodo que produjo la soluci n es recompensado posteriormente. Cuanto m s tiempo pasa usando *PoW*, mayor es la dificultad en la extracci n, lo que conduce a una mayor dificultad para que los *mineros* obtengan la recompensa. Por lo tanto, los *mineros* se enfrentan a altos costes con objeto de poseer el mejor *hardware* para vencer a la competencia y a los costes de la electricidad. Otro mecanismo de consenso popular es la prueba de participaci n (*Proof of Stake – PoS*), en la que la capacidad de validar un bloque de transacci n depende de la cantidad de criptomonedas que posee el *minero*. Por lo tanto, este protocolo recompensa a los *mineros* no por su esfuerzo para resolver problemas matem ticos, sino por la cantidad de moneda acumulada por el nodo. Cuanto mayor sea la cantidad, mayor ser  la potencia de miner a.

Otra caracter stica importante de la tecnolog a *blockchain* es el cifrado asim trico, que permite al usuario proteger su propiedad digital y transferir informaci n cifrada. Todos los miembros de la cadena de bloques tienen dos claves, una privada y otra p blica. La primera, visible solo para el propietario, permite acceder a la cuenta espec fica del usuario y se utiliza como firma digital para las transacciones. La segunda es la direcci n de una cuenta individual. Para entender mejor el concepto de claves, podemos tomar como ejemplo el correo electr nico. En este caso, la clave p blica representa la direcci n de correo electr nico de un usuario, mientras que la clave privada es la contrase a para acceder a esa cuenta de correo electr nico espec fica. Al conocer la direcci n de un usuario, se le puede enviar un

correo electrónico, pero para acceder a una cuenta específica y enviar correos electrónicos desde ella también se debe conocer su contraseña. Del mismo modo en la cadena de bloques, al conocer la clave pública, se pueden enviar criptomonedas a esa cuenta específica, pero para acceder a ella o enviar criptomonedas desde ella, se debe conocer la clave privada relacionada, que pertenece a un propietario específico. Las claves públicas y privadas de un usuario se guardan en un monedero digital, en línea (*hot storage*) o fuera de línea (*cold storage*).

La cadena de bloques ofrece muchas ventajas sobre un sistema de pago normal, pero también tiene algunas desventajas que deben tenerse en cuenta. La principal ventaja es, sin duda, el sistema descentralizado que permite transacciones fiables sin la necesidad de un tercero. El sistema distribuido también permite una mejor tolerancia a los errores y una mayor resistencia a los ataques. Además, la cadena de bloques permite transacciones más rápidas con menores costes que los sistemas tradicionales, así como el acceso completo a todo el historial de transacciones de la red, de una manera totalmente transparente para sus usuarios. En cuanto a las desventajas, sin duda, la mayor es la actividad de extracción. Como ya se ha descrito anteriormente, esta última requiere inversiones en *hardware* cada vez más avanzado y unos costes energéticos elevados. Otro gran problema es la seguridad. En caso de pérdida de la clave privada del usuario, ya no será posible acceder a la correspondiente cuenta, y los recursos depositados se perderán para siempre. Además, una vez que se envía una transacción, no puede cancelarse para recuperar los recursos enviados. La transparencia total también puede tener un impacto negativo en la privacidad y la reputación del usuario, ya que todos pueden acceder al historial de toda la red. Por último existe el riesgo económico debido a la naturaleza volátil de las criptomonedas, lo que las convierte en una herramienta débil para usar como reserva de valor.

1.4 El mercado de las criptomonedas

En los últimos treinta años se han propuesto varias alternativas para los sistemas de pago. En la década de 1990, Digicash Inc introdujo *eCash*, que se considera la primera moneda digital similar a las criptomonedas modernas; sin embargo, no superó la burbuja de internet de principios de la década de 2000. Soluciones más modernas fueron propuestas por PayPal, Google y Apple, pero todos estos sistemas digitales siempre se basan en monedas fiduciarias, y se utilizan principalmente para compras en línea en plataformas de comercio electrónico o para la gestión de tarjetas bancarias. De manera diferente, las criptomonedas se presentan como un nuevo instrumento financiero viendo también la primera y más conocida aplicación de la tecnología *blockchain*. Aprovechando esta nueva tecnología, se ha construido un sistema de pago distribuido disponible en internet, que proporciona la integridad de las transacciones, sin necesidad de una autoridad central. Este sistema de pago descentralizado se utiliza como una red de intercambio directo para esta nueva forma de dinero digital, y no solo como una forma de comprar en línea. Con más de 3.000 monedas y una capitalización global del mercado de más de 1 billón de dólares, el mercado de las criptomonedas se ha convertido en una importante realidad financiera. La primera moneda

introducida es bitcoin que ocupa una cuota de mercado del 38 % del total¹. A continuación, en el **cuadro 1**, se muestra una breve lista² de las diez principales criptomonedas basadas en la capitalización de mercado.

Cuadro 1.

Top 10 criptomonedas por capitalización de mercado en fecha 19/11/2022

Rango	Criptomoneda	Precio	Capitalización de mercado	Monedas en circulación
1	Bitcoin	\$ 16.641,67	\$ 319.673.440.976	19.211.512
2	Ethereum	\$ 1.207,65	\$ 147.748.194.141	122.373.866
3	Tether	\$ 1,00	\$ 65.891.584.463	65.944.935.626
4	USD Coin	\$ 1,00	\$ 44.386.336.278	44.378.144.428
5	BNB	\$ 270,72	\$ 43.308.820.429	159.973.276
6	Binance USD	\$ 1,00	\$ 22.876.078.976	22.872.131.211
7	XRP	\$ 0,3795	\$ 19.094.085.360	50.298.735.565
8	Cardano	\$ 0,324	\$ 11.149.733.980	34.411.552.943
9	Dogecoin	\$ 0,08396	\$ 11.138.768.715	132.670.764.300
10	Polygon	\$ 0,8609	\$ 7.517.278.844	8.734.317.475

Con la llegada de bitcoin se desarrolló considerablemente el mercado de las criptomonedas, tanto en términos de activos negociados como en el número de inversores y empresas que operan en él. A largo plazo, el precio de bitcoin, así como el de otras criptomonedas, ha aumentado constantemente, aunque el mercado ha estado sujeto a varios períodos de burbuja seguidos de otros tantos de crisis. Estas han provocado la desaparición de varias criptomonedas y empresas que operan en el mercado. Las diferentes monedas intercambiadas difieren en el tipo de cadena de bloques adoptada y su utilización final. Por ejemplo, en los últimos años se han introducido varias monedas estables (*stablecoins*), que tienen como objetivo facilitar las actividades de intercambio y proteger contra la alta volatilidad del mercado, vinculando el valor de la moneda estable con el de las monedas fiduciarias u otros activos. Otras, como ethereum, se han convertido en la base para plataformas de contratos inteligentes (*smartcontracts*), lo que ha llevado al desarrollo de mercados secundarios como el de los *non-fungible tokens* (NFT). Otras nacieron por pura diversión y con fines humorísticos, pero fueron capaces de hacerse con una gran parte del mercado, creando una categoría aparte, la de las *meme-coins*. Las dificultades iniciales de acceso al mercado, debido a la creación y uso de una billetera encriptada, se han superado gracias a la aparición de numerosas plataformas de intercambio, que permiten poseer e intercambiar criptomonedas de manera más fácil y rápida. Estas plataformas, aunque han hecho que el mercado sea más estructurado y accesible, no siempre lo han hecho más estable. Dichas plataformas han permitido la entrada de numerosos pequeños inversores, más interesados en las posibilidades especulativas que en invertir en una nueva clase de activos y en nuevas tecnologías. Muchas plataformas también han estado sujetas a fallos de seguridad que han llevado al robo de dinero, propiedad de usua-

¹ Fuente: www.coin360.com

² Fuente: www.coinmarketcap.com

rios registrados. Además, al estar poco reguladas, las empresas propietarias de intercambios tienden a realizar también una gestión especulativa, poniendo en riesgo los depósitos de los usuarios en tiempos de crisis del mercado. El crecimiento de estas compañías y su gran interconexión mediante la posesión cruzada de criptomonedas propietarias (BNB, FTT token, OKB, KuCoin, HT, CRO) y monedas estables también ha aumentado enormemente el riesgo sistémico del mercado de las criptomonedas. Por ejemplo, el reciente colapso de la plataforma FTX, a través de la depreciación de su criptomoneda FTX token (FTT), ha afectado a varios fondos de inversión y a compañías de cambio de moneda. Otro ejemplo reciente involucró a la moneda estable terraUSD. La empresa en gestión no pudo mantener el valor de la moneda estable vinculada al dólar estadounidense debido a un ataque especulativo. Esto llevó a la depreciación del valor de terraUSD, causando grandes pérdidas entre los inversores y las plataformas que la utilizaban. Todos estos problemas hacen que el mercado de las criptomonedas sea extremadamente inmaduro y particularmente arriesgado. La alta volatilidad, las quiebras y el fraude todavía lo hacen poco adecuado para actividades de inversión tradicionales y a largo plazo, siendo más adecuado para especulaciones a corto plazo.

2. EFECTO *MOMENTUM* EN LOS MERCADOS FINANCIEROS

En este capítulo se proporciona una introducción del efecto *momentum* en los mercados financieros y, en particular, en el mercado de las criptomonedas. Además, en los apartados siguientes se analizan algunos modelos para explotarlo durante la actividad de inversión.

El funcionamiento y las causas del efecto *momentum* en los mercados financieros debe buscarse en el método con el que se determinan los precios de los productos financieros según las dos teorías principales, la de las finanzas tradicionales y la de las finanzas conductuales. La teoría de las finanzas tradicionales utiliza una serie de hipótesis que definen el comportamiento de los inversores y las condiciones en las que operan, con el fin de comprender la dinámica y dar forma al funcionamiento de los mercados financieros. Esta teoría afirma que los inversores se oponen al riesgo, tienen acceso completo a la información sobre los mercados y toman decisiones racionales para maximizar los beneficios, sin ser influenciados por otros factores. Además, los modelos basados en esta teoría requieren un mecanismo de arbitraje eficiente, que permita que el precio de los productos financieros permanezca anclado en el valor de equilibrio, corrigiendo rápidamente cualquier cambio. Muchas de las hipótesis en las que se basan las finanzas tradicionales a menudo son poco realistas, ya que suponen un mercado ideal. En la década de los ochenta, un gran número de investigadores e inversores comenzaron a encontrar una serie de resultados empíricos incompatibles con el equilibrio de precios y los modelos de mercado eficientes. Estos hallazgos llevaron al desarrollo de una nueva teoría para fijación de precios llamada finanzas conductuales. Más concretamente, el nuevo modelo de comportamiento intenta explicar las anomalías detectadas basándose en dos pilares fundamentales. El primer pilar, relativo a la psicología del inversor, afirma que los operadores en los mercados no actúan racionalmente. A diferencia de los modelos financieros tradicionales, el inversor se ve afectado por algunos prejuicios (sesgo) y de la información que recibe. El segundo pilar, por el contrario, defiende la ineficacia del sistema de arbitraje, reconociendo así la posibilidad de una desviación prolongada de los precios de su valor de equilibrio.

Entre las anomalías estudiadas por las finanzas conductuales está también el efecto *momentum*, que consiste en la autocorrelación positiva de los precios. Esto, por ejemplo, puede ocurrir durante un mercado alcista, donde el aumento de los precios empuja a los inversores a comprar para especular (*fear of missing out*). Del mismo modo, durante un período de crisis y bajada de precios, los inversores se ven presionados a vender para tratar de contener las pérdidas, empujando así los precios cada vez más bajos. Se han encontrado pruebas de este mecanismo en los principales mercados, empezando por el estadounidense (Jegadeesh y Titman, 1993). También, Lansdorff y Jellema (2013) observaron un comportamiento similar en el mercado de valores durante la burbuja de las empresas. El alto nivel de especulación alcanzado durante la burbuja también atrajo el interés de los pequeños inversores, quienes poco informados sobre los productos y servicios en los que estaban invirtiendo, compraban las acciones de las empresas tecnológicas atraídos por las altas ganancias realizadas. Además, Rouwenhorst (1999) muestra cómo la dificultad para obtener información hace que los mercados emergentes sean particularmente vulnerables al efecto *momentum*.

2.1. Evidencia del efecto *momentum* en el mercado de las criptomonedas

El mercado de las criptomonedas es un caso nuevo y relativamente inexplorado de mercado muy vulnerable a las anomalías descritas por las finanzas conductuales. Esto se debe a su alta volatilidad en comparación con los mercados tradicionales. Estudios recientes han analizado su eficiencia, las propiedades de memoria larga y la persistencia de los precios (Bartos, 2015; Urquhart, 2016; Bariviera, 2017), la existencia de burbujas (Corbet, Lucey y Yarovaya, 2018), su competitividad (Gandal y Halaburda, 2014), la predictabilidad de los precios (Plastun *et al.*, 2021) y la presencia de anomalías (Kurihara y Fukushima, 2017).

La influencia del efecto *momentum* en el mercado de las criptomonedas se debe a sus afinidades con los mercados emergentes, como la baja regulación y la falta de información confiable. Esto hace que las grandes instituciones financieras no tengan la autorización o el interés de operar en este mercado, dejándolo principalmente en manos de pequeños fondos o individuos. Además, la complejidad de los activos negociados a menudo no permite invertir de manera consciente. Los inversores con menos experiencia, al encontrar extremadamente complicado desarrollar su propio análisis de la evolución de los precios, se dejan guiar por los rumores y el deseo de especular, y no por un interés real en las tecnologías *blockchain*. Algunos estudios recientes se han centrado en el efecto *momentum* y la volatilidad de los precios en el mercado de las criptomonedas. Chevapatrakul y Mascia (2019), basándose en el modelo autorregresivo, muestran que los inversores están listos para abandonar el mercado en los días en que los precios tienden a caer, y a realizar compras masivas durante las semanas en que los precios están en fuerte aumento. Sin embargo, no se han encontrado resultados significativos durante períodos más largos, lo que sugiere que el mercado de las criptomonedas se caracteriza por una dinámica mucho más rápida que los mercados en los que se negocian activos tradicionales. Más tarde, Caporale y Plastun (2020) muestran la presencia de patrones en la evolución de los precios de las criptomonedas como resultado de una reacción de precios

excesiva, llamada *sobrerreacción* (*overreaction*). En particular, como consecuencia de una reacción positiva o negativa excesiva, los precios tienden a aumentar o disminuir más durante ese mismo día y, en algunos casos, también durante parte del día siguiente, mostrando rastros

Figura 1.

Rendimiento horario promedio de bitcoin en días de reacción excesiva (positiva y negativa) y en días normales en el período comprendido entre 2015 y 2019



de un efecto *momentum* a corto plazo. Además, se ha identificado la posibilidad de detectar los días atípicos antes del final del día, y así poder aprovechar el siguiente efecto *momentum* para obtener un beneficio. El sistema de seguimiento utiliza un comportamiento inusual de los rendimientos por hora durante los días en que se produce una reacción excesiva de los precios. Específicamente, en días de reacción excesiva positiva o negativa, los rendimientos por hora son significativamente más altos o bajos que los rendimientos por hora alcanzados durante los días considerados normales.

La *figura 1* muestra este comportamiento para bitc on, comparando los rendimientos horarios medios de los d as normales y de los d as caracterizados por una reacci n excesiva.

3. MODELOS PARA LA EXPLOTACI N DEL EFECTO *MOMENTUM* EN LA ACTIVIDAD DE INVERSI N

Este cap tulo presenta dos modelos para la predicci n del efecto *momentum* que sigue una reacci n excesiva del precio de las criptomonedas. Estos modelos son basados en los hallazgos que se muestran en la secci n 2 y se utilizan como estrategias en la actividad de inversi n. El primero es un enfoque heur stico propuesto por Caporale y Plastun (2020). El segundo utiliza el aprendizaje autom tico para desarrollar una nueva estrategia de inversi n que aumente la eficiencia y rentabilidad de la anterior desarrollado por Bellocca *et al.* (2022).

3.1. El enfoque heur stico

El m todo de detecci n de la reacci n excesiva de los precios propuesto por Caporale y Plastun (2020) es un m todo heur stico basado en la inspecci n horaria de los precios de las criptomonedas. La detecci n se lleva a cabo mediante el uso de dos umbrales de precio predefinidos, que tambi n sirven para activar las operaciones comerciales.

Los umbrales adoptados en el m todo heur stico se calculan utilizando el rendimiento medio diario de la criptomoneda y su desviaci n est ndar. Los rendimientos diarios (R_i) se calculan como sigue:

$$R_i = (Close_i / Open_i - 1) * 100 \% \quad [1]$$

donde R_i es el rendimiento del d a i en %, $Open_i$ es el precio de apertura del d a i y $Close_i$ es el precio de cierre del d a i . Los dos umbrales se calculan para cada d a de funcionamiento utilizando datos hist ricos. Para ello, los datos se dividen en d as de rendimiento positivo y negativo. Los dos subconjuntos se utilizan para calcular los umbrales de precio positivo y negativo, respectivamente. El d a i se caracterizar  por una reacci n excesiva positiva si:

$$R_i > (R_n + k * \sigma_n) \quad [2]$$

y se caracterizará por una reacción excesiva negativa si:

$$R_i < (R_n - k * \sigma_n) \quad [3]$$

donde R_n es el rendimiento diario medio durante n días, σ_n es la desviación típica durante n días y k es un número positivo que indica de desviaciones típicas que estamos considerando para definir los umbrales.

El rendimiento diario medio y la desviación típica para un período de n días se calcularán como sigue:

$$R_n = \sum_{i=1}^n \frac{R_i}{n} \quad [4]$$

$$\sigma_n = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_i - R_n)^2} \quad [5]$$

El método heurístico compara el precio actual con los umbrales para asignar el día de negociación actual a una de las siguientes categorías: reacción excesiva positiva, reacción excesiva negativa o día normal. Para hacerlo, realiza una comprobación de precio por hora a fin de detectar si el precio de la criptomoneda considerada es superior a uno de los dos umbrales calculados diariamente. Si el precio supera un umbral determinado, el día actual se clasifica con la etiqueta de reacción excesiva correspondiente. Al final del día, una predicción es correcta si el precio de cierre diario todavía está por encima del nivel de umbral. El sistema de *trading* propuesto por Caporale y Plastun (2020) utiliza estas lecturas para abrir posiciones largas o cortas si el umbral superado es positivo o negativo, respectivamente. Todas las posiciones se cierran al final del día.

3.2. El enfoque de aprendizaje automático

El término aprendizaje automático fue introducido por Arthur Samuel en los años 50 para describir tareas de reconocimiento de patrones. A partir de ese momento, el uso práctico de las técnicas de aprendizaje automático ha abarcado varios sectores, especialmente el económico y financiero, gracias a su capacidad de analizar grandes cantidades de datos, incluso aquellos poco estructurados. Entre las diversas aplicaciones encontramos el análisis de documentos legales y datos bancarios internos para resolver problemas de cumplimiento bancario, combatir el fraude y prevenir el lavado de dinero. Un segundo ámbito de aplicación es el relativo a la gestión del cliente. De hecho, utilizando el aprendizaje automático, los bancos y las instituciones financieras han desarrollado *chatbots* y *robo-advisor* capaces de mejorar el servicio al cliente y ofrecer servicios para la creación y gestión automática de una cartera de inversión. Otra aplicación es la gestión de riesgos, tanto la de mercado, mediante las previsiones de la evolución de los precios, como la de crédito, mediante el análisis de la situación financiera de los solicitantes de préstamos. La última aplicación importante es, sin duda, la

actividad de inversión. Los complejos sistemas informáticos implementados por bancos y fondos consiguen que las decisiones de *trading* sean extremadamente rápidas, llegando a realizar millones de operaciones diarias (*high frequency trading*). Estas decisiones implican el uso del aprendizaje automático, por ejemplo, mediante el análisis de sentimientos aprovechando enormes cantidades de noticias de artículos, blogs y sitios web, redes sociales y archivos multimedia como videos y audios. Varios estudios académicos han analizado la posibilidad de aprovechar las técnicas de aprendizaje automático para predecir la evolución de los precios en el mercado de valores (Bustos y Pomares-Quimbaya, 2020; Huang *et al.*, 2019; Ozbayoglu, Gudelek y Sezer, 2020; Rundo *et al.*, 2019), pero pocos trabajos han intentado reutilizar los sistemas comerciales modernos en el mercado de las criptomonedas. Un ejemplo es Attanasio *et al.* (2019), que han estudiado la aplicación de algunas técnicas de clasificación (*Support Vector Machine* y *Decision Trees*) para predecir el precio de las criptomonedas durante el día siguiente a la predicción. Otros estudios (Lahmiri y Bekiros, 2021; Livieris *et al.*, 2020) se centraron en las técnicas de aprendizaje profundo (*Deep learning*), explorando diferentes tipos de datos de entrada, como información económica financiera o información relacionada con la *blockchain* en la que se apoya la criptomoneda analizada. Otra serie de trabajos investiga el uso de enfoques ensemble como *Random Forests* y *Stochastic Gradient Boosting Machine* (Derbentsev *et al.*, 2021) y el algoritmo *Gradient Boosting Decision Tree* (Sun, Liu y Sima, 2020). Por último, algunos estudios han utilizado técnicas de minería de texto usando datos de redes sociales, tales Twitter (Kraaijeveld y De Smedt, 2020) o GitHub y Reddit (Glenski, Weninger y Volkova, 2019) para predecir los precios de las principales criptomonedas. Sin embargo, todas las estrategias anteriores se caracterizan típicamente por un alto grado de ruido, lo que hace que el proceso de inferencia sea complejo y no sea fácil de explicar.

Bellocca *et al.* (2022), a diferencia de los trabajos anteriores en los que se investigaba la posibilidad de predecir los precios de las criptomonedas a corto plazo, proponen una nueva estrategia basada en el aprendizaje automático para prever la aparición de una reacción excesiva. El enfoque propuesto aprovecha las propiedades del mercado destacadas por recientes evidencias empíricas (Caporale y Plastun, 2020) junto con el poder predictivo de los modelos de aprendizaje automático, para contrarrestar la mayor desventaja del método heurístico, es decir, la generación de señales comerciales falsas. El objetivo es, otra vez, prever si un día de actividad se caracteriza por una reacción excesiva de los precios, de modo que pueda utilizarse esta información durante la actividad de inversión. A diferencia de la estrategia heurística, que realiza una inspección horaria del precio para detectar una reacción excesiva y generar señales, la estrategia de aprendizaje automático utiliza datos de granularidad diaria para hacer una predicción sobre el siguiente día de actividad. El modelo propuesto es el siguiente:

$$O_c(d_{i+1}) = f_c(S_c(d_i), S_c(d_{i-1}), \dots, S_c(d_{i-W+1})) \quad [6]$$

donde $f_c()$ es la función de predicción y O_c es el indicador que se quiere predecir. Específicamente, O_c indica si el día de operación d_{i+1} para la criptomoneda c es un día de reacción excesiva, positiva o negativa, o un día con una tendencia de precios normal. Los datos de entrada utilizados por el modelo son un conjunto de datos históricos, que describen c durante el día actual d_i , en el que se hace la predicción, y los días anteriores $d_{i-1}, d_{i-2}, \dots, d_{i-W+1}$. W indica

el tamaño de la ventana de datos históricos utilizados para la predicción. Para generar las etiquetas de clase O_c correctas, útiles para entrenar y verificar la precisión del clasificador, se utilizan los valores umbral definidos por Caporale y Plastun (2020). Para generar los valores umbral se ensayaron diferentes valores de W , comprendidos en el intervalo $[50,360]$ días, y de k , incluidos en el intervalo $[0,2]$. Los datos de entrada utilizados para entrenar al clasificador no se limitan sólo a los precios y volúmenes históricos de negociación. De acuerdo con Attanasio, Cagliero y Baralis (2020), las variaciones de precios diarias se describen con una serie de indicadores técnicos preestablecidos (Murphy, 1999), con el fin de resumir el estado y las tendencias de la criptomoneda. El conjunto de los 22 indicadores técnicos utilizados tiene como objetivo señalar si el precio de la criptomoneda está siguiendo una tendencia, evaluar la fuerza de esta tendencia y detectar evidencia de efecto *momentum*.

Finalmente, la estrategia de *trading* basada sobre el enfoque que utiliza el aprendizaje automático difiere de la que se basa en el método heurístico. En este caso, al disponer de la etiqueta diaria desde el inicio del día, se abren inmediatamente las posiciones correspondientes sin realizar un análisis de los precios por hora para la generación de señales de compra o venta. Todas las operaciones se cierran al final del día, como en la estrategia heurística.

4. APLICACIÓN EMPÍRICA

Este apartado presenta la aplicación empírica. Después de mostrar la metodología utilizada en Bellocca *et al.* (2022) para comparar la eficiencia del modelo heurístico y el modelo basado en aprendizaje automático, se presenta la aplicación empírica de este trabajo. El objetivo es ampliar el análisis realizado anteriormente, proporcionando una evaluación más exhaustiva de los resultados de la predicción y la inversión en diferentes condiciones de mercado.

4.1. Estrategias previas

Bellocca *et al.* (2022) comparan los resultados obtenidos replicando el enfoque heurístico de Caporale y Plastun (2020) y los obtenidos con diferentes clasificadores de aprendizaje automático a través de extensas pruebas retrospectivas. Para ello, recopilan datos históricos diarios³ sobre un conjunto de criptomonedas que luego dividen en dos intervalos de tiempo. El primer intervalo de datos se utiliza para entrenar los modelos de aprendizaje automático, proporcionando información sobre los indicadores técnicos y la clasificación correcta de la reacción excesiva para cada día de actividad que contiene. La parte restante de los datos se utiliza para la evaluación de los diferentes modelos, comparándolos también con los resultados obtenidos siguiendo la estrategia heurística de Caporale y Plastun (2020). El estudio incluye tres de las principales criptomonedas: bitc in (BTC), ethereum (ETH) y litecoin (LTC). Los intervalos temporales van del 2 de septiembre de 2015 al 31 de diciembre de 2019

³ Fuente: Kraken exchange APIs y www.cryptodatadownload.com

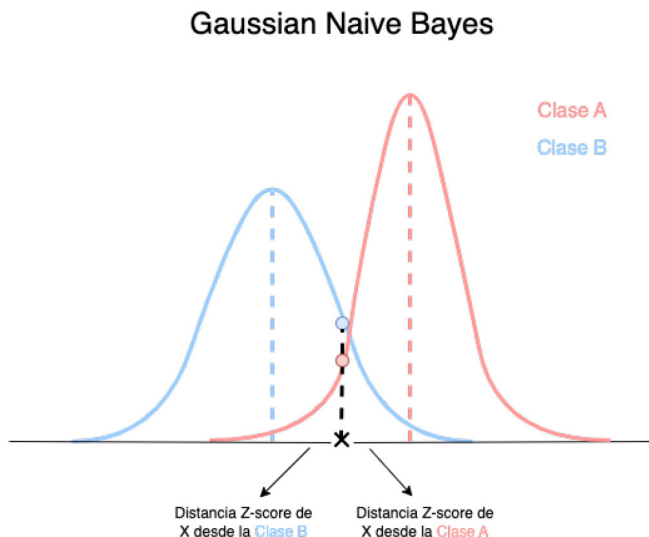
para el entrenamiento de modelos, y del 1 de enero de 2020 al 31 de diciembre de 2020 para la evaluación.

La predicción se configura, como se mencionó anteriormente, como una tarea de clasificación de tres clases, con el objetivo de predecir situaciones de reacción excesiva positiva o negativa o días neutros. Los algoritmos de clasificación considerados son los siguientes:

- **Multi-Layered Perceptron (MLP):** un *perceptrón* multicapa (MLP) es una clase completamente conectada de red neuronal artificial de retroalimentación. Está compuesto por al menos tres capas de nodos: una capa de entrada, una capa oculta y una capa de salida. A excepción de los nodos de entrada, cada nodo es una neurona que utiliza una función de activación no lineal. En el aprendizaje supervisado el entrenamiento se realiza a través de la retropropagación, una generalización del algoritmo de mínimos cuadrados medios.
- **Gaussian Naive-Bayes (GNB):** Naive Bayes es un grupo de algoritmos de clasificación de aprendizaje automático supervisados basados en el teorema de Bayes. *Gaussian Naive Bayes* soporta características de ingreso (*classification features*) de valor continuo y conforme a una distribución gaussiana (normal). El modelo se construye simplemente encontrando la media y la desviación estándar de los puntos dentro de cada clase. Luego, en cada punto de datos, se calcula el *z-score* (distancia entre ese punto y la media de clase dividida por la desviación estándar de clase) para asignar cada punto de datos a la clase más cercana.

Figura 2.

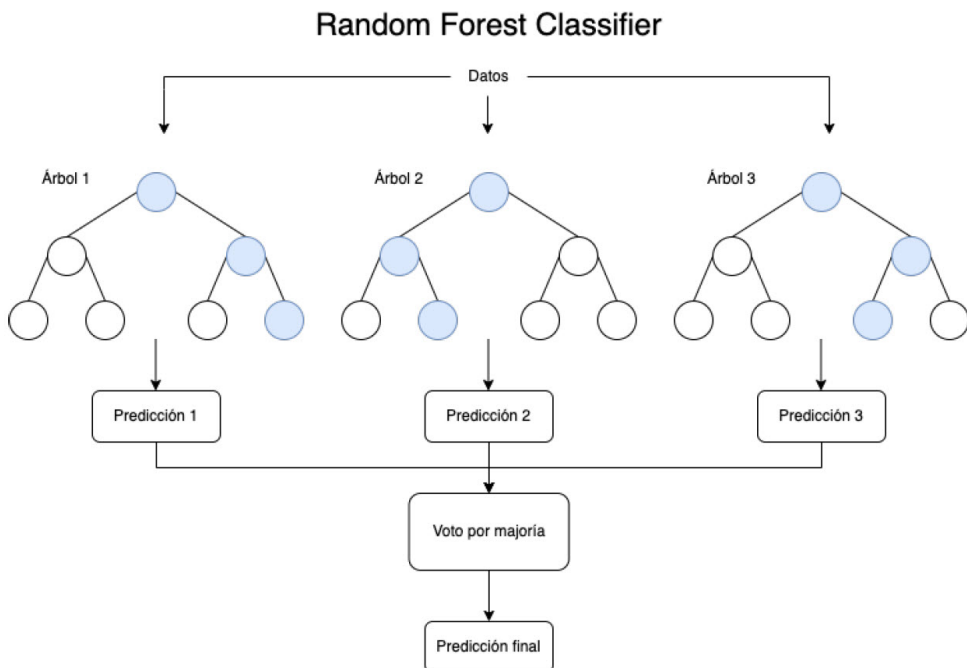
Ejemplo gráfico de clasificación utilizando GNB con dos clases



- **Multinomial Naive-Bayes (MNB):** este algoritmo es un método de aprendizaje probabilístico adecuado para la clasificación con características discretas. La distribución multinomial normalmente requiere conteos enteros, pero también puede trabajar con conteos fraccionarios.
- **Random Forest (RFC):** el bosque aleatorio (*Random Forest*) es un método de aprendizaje *ensemble* utilizado principalmente para la regresión y la clasificación, que opera construyendo una multitud de árboles de decisión durante la fase de formación. Su aplicación a problemas de clasificación se llama clasificador en bosque aleatorio (*Random Forest Classifier*), que consiste en un estimador que entrena a un número de clasificadores en árbol de decisión sobre varias submuestras del conjunto de datos disponible y utiliza el promedio para mejorar la precisión predictiva y controlar el sobreajuste (*overfitting*).

Figura 3.

Ejemplo gráfico de clasificación utilizando el bosque aleatorio con tres árboles de decisión

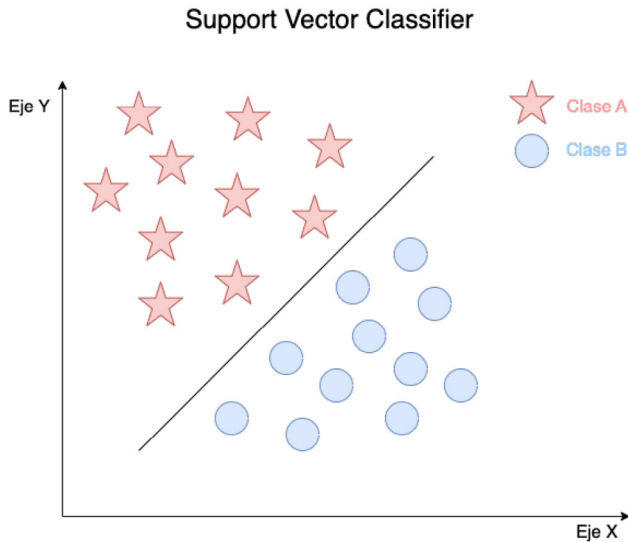


- **Support Vector Machine (SVM):** una máquina vectorial de soporte es un algoritmo de aprendizaje automático supervisado que se puede utilizar para tareas de clasificación y regresión. En la tarea de clasificación (*Support Vector Classifier*) funciona mapeando

puntos de datos a un espacio de alta dimensión y luego encontrando el hiperplano óptimo que divide los datos en dos clases, maximizando el margen entre las dos clases.

Figura 4.

Ejemplo gráfico de clasificación utilizando el SVC en dos dimensiones



- **Logistic Regressor (LG):** la regresión logística es un ejemplo de algoritmo de aprendizaje supervisado. Se utiliza para predecir la probabilidad de un resultado binario, como verdadero o falso, o resultado no binario (regresión logística multinomial), basado en observaciones previas de un conjunto de datos. En el caso de la clasificación binaria, la probabilidad siempre oscila entre 0 (falso) y 1 (verdadero) y se calcula utilizando una función sigmoide, utilizada para convertir datos en un valor entre 0 y 1.
- **K-Nearest Neighbors (KNN):** vecinos más cercanos (KNN) es un algoritmo de aprendizaje supervisado utilizado para la clasificación. Mediante el modelo KNN, un objeto se clasifica por un voto de pluralidad de sus vecinos, con el objeto asignado a la clase más común entre sus k vecinos más cercanos.

Para mejorar el rendimiento de la clasificación, se optimizan los parámetros de cada algoritmo de aprendizaje mediante búsqueda exhaustiva (*exhaustive grid-search*). La validación se realiza utilizando una validación cruzada dividiendo los datos en k fracciones (*k-fold cross-validation*), con un número de fracciones igual a 5. Por último, en la fase de prueba se

Figura 5.

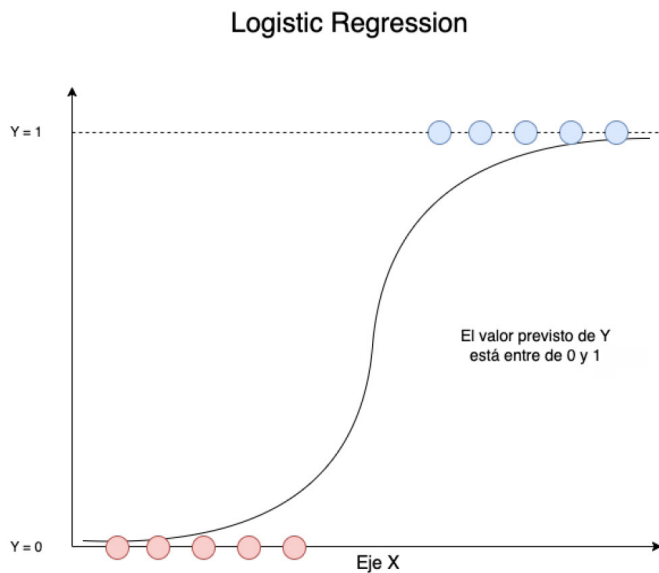
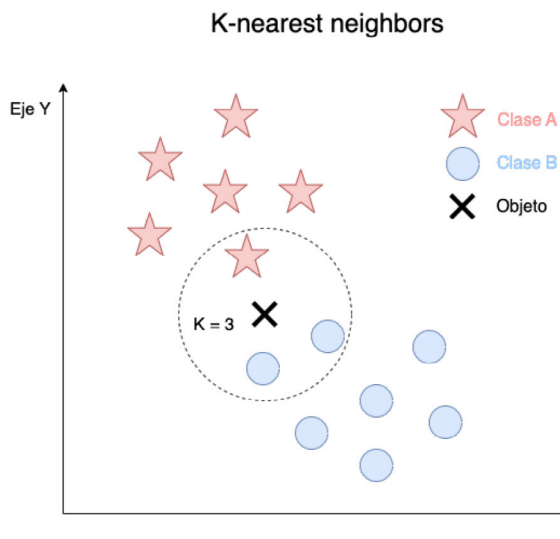
Ejemplo gráfico de clasificación utilizando la regresión logística binaria

Figura 6.

Ejemplo gráfico de clasificación utilizando el KNN con $k=3$ 

utiliza para cada algoritmo de aprendizaje la configuración más eficaz en términos de F1⁴ ponderada obtenida en la fase de validación.

4.2. Extensión de la aplicación empírica

Las pruebas realizadas por Bellocca *et al.* (2022) se centran solo en 2020, un año predominantemente poco agitado para el mercado de las criptomonedas. De hecho, solo en los últimos meses de este año, se ha producido un aumento en la volatilidad que ha llevado al precio de bitcóin a superar sus máximos históricos alcanzados tres años antes, en diciembre de 2017. La intención de este trabajo es probar los modelos presentados anteriormente, tanto heurístico como basado en el aprendizaje automático, en una etapa diferente del mercado. El período que va desde principios de 2021 hasta finales de 2022 brinda esta oportunidad, ya que se caracteriza por un fuerte mercado alcista antes, y un período de caída de precios posterior. En particular, el nuevo período de valoración se divide en dos partes, utilizando el 10 de noviembre de 2021, fecha del máximo histórico de bitcóin, como punto de división. Los dos períodos de evaluación son una fase alcista del mercado (del 1 de enero de 2021 al 10 de noviembre de 2021) y una fase bajista (del 11 de noviembre de 2021 al 20 de noviembre de 2022). Esta división permite estudiar la eficiencia de los métodos de previsión y la actividad de inversión en ambos escenarios de mercado.

En cuanto a la fase de entrenamiento del clasificador, se utilizan todos los datos disponibles antes del primer día de prueba. Por esta razón, el segundo segmento de prueba tiene un mayor intervalo de entrenamiento. Además, la mayor disponibilidad de datos para monedas nacidas después de bitcóin, ethereum y litecoin permite incluir otras monedas, como ripple (XRP), tron (TRX) y monero (XMR), a fin de ampliar la muestra a una parte más grande del mercado.

5. RESULTADOS

En este apartado se presentan los resultados obtenidos de los dos métodos, heurístico y de aprendizaje automático, tanto en la predicción de los días de reacción excepcional como en su eficiencia en una simulación comercial. Para empezar, se resumen brevemente los resultados derivados del trabajo anterior (Bellocca *et al.*, 2022) basado en los datos relativos al año 2020, a fin de compararlos posteriormente con los nuevos obtenidos analizando los dos años siguientes. También se presentan algunos resultados obtenidos mediante simulaciones de inversión cruzada, para analizar mejor la correlación de bitcóin con otras criptomonedas en períodos de alta volatilidad.

5.1. Resultados anteriores

Los resultados de predicción de reacciones de precios excesivas presentados por Bellocca *et al.* (2022) muestran que los métodos de aprendizaje automático superan el enfoque heu-

⁴ La puntuación F1 se define como la media armónica entre la precisión y el recuerdo. Se utiliza como medida estadística para evaluar el rendimiento de la clasificación.

rístico en términos de F1 ponderada, pero no hay un mejor método para todas las criptomonedas analizadas. Además, las simulaciones de inversión realizadas implican dos estrategias diferentes, como ya se ha mencionado anteriormente. En concreto, la estrategia de *trading* heurística realiza un control horario de los precios. Cuando el precio alcanza el umbral positivo o negativo, se abre una posición larga o corta correspondiente. En contraste, la estrategia de negociación basada en el aprendizaje automático no adopta el seguimiento horario de precios. Esta utiliza las etiquetas producidas por el clasificador para abrir una posición larga o corta dependiendo de si la etiqueta calculada al comienzo de cada día de negociación es positiva o negativa. Ambas estrategias cierran sus posiciones al final de cada día de negociación. Los resultados operativos de Bellocca *et al.* (2022) muestran que las estrategias basadas en el aprendizaje automático abren menos posiciones que la estrategia heurística, con un mayor porcentaje de operaciones rentables y, por lo tanto, reduciendo las pérdidas. Estos valores confirman que el método de detección basado en el aprendizaje automático es más eficaz para evitar la generación excesiva de señales, a pesar de que solo tiene datos anteriores al día operativo actual. Además, el rendimiento total y el rendimiento medio por operación obtenidos por las estrategias de aprendizaje automático son más altos. Esto se debe a que el aprendizaje automático permite abrir posiciones desde el comienzo de cada día de reacción excesiva, sin esperar a que el precio alcance uno de los dos niveles umbral. De esta manera es posible entrar en el mercado desde una mejor posición que la estrategia heurística, pudiendo así aprovechar no sólo el efecto *momentum*, sino también la reacción excesiva de precio que se manifiesta en ese día específico, aumentando los beneficios. Los mejores resultados operativos de las tres criptomonedas se obtienen mediante el uso de los algoritmos *KNN* y *SVC*, con rendimientos totales superiores al doble de los obtenidos con la estrategia heurística.

5.2. Nuevos resultados

Los resultados que se presentan a continuación se obtienen con nuevas pruebas a lo largo de dos fases diferentes del mercado: mercado alcista y mercado bajista. En las pruebas del primer período contemplado se incluyeron seis criptomonedas diferentes: BTC, ETH, LTC, XRP, TRX y XMR. Dado que los datos sobre las monedas más pequeñas (TRX y XMR) todavía no están disponibles para el segundo período, desafortunadamente, para estas últimas monedas no se pueden presentar los resultados durante el mercado bajista. Al igual que con el trabajo anterior, se prueban diferentes valores de W y k para generar umbrales, obteniendo nuevamente los mejores resultados con $W=50$ y $k=1$. A continuación se comentan los resultados obtenidos con esta configuración.

5.2.1. Predicción de reacciones excesivas

Los cuadros 2 y 3 muestran los resultados de la predicción de reacciones excesivas durante los dos períodos considerados. En cuanto al rendimiento en el mercado alcista (cuadro 2), se puede observar que la puntuación F1 está en línea con los valores registra-

dos para el año 2020 (>0.70), excepto en algunos casos. De hecho, GNB, SVC y LG muestran poca eficacia en la predicción de reacciones excesivas para BTC, ETH y TRX, con una drástica disminución en el valor ponderado de F1. En los demás casos, comparando el método heurístico con los algoritmos de clasificación se encuentran puntuaciones similares sin un mejor global. De lo contrario, si se observan los resultados en el mercado bajista (cuadro 3), se puede observar que estos son mucho mejores, con la puntuación F1 más alta obtenida siempre mediante el uso del aprendizaje automático. La caída de las puntuaciones en la fase alcista (2021) se debe a la diferente situación del mercado en el período de entrenamiento y evaluación. De hecho, antes de 2021, el mercado de criptomonedas nunca había alcanzado los niveles de precios y volatilidad como en ese año. Esta situación de volatilidad sólo se observó en 2017, cuando el mercado de las criptomonedas todavía estaba escasamente

Cuadro 2.

Valores de F1 ponderadas para cada modelo de clasificación por el mercado alcista

<i>Modelo</i>	<i>BTC</i>	<i>ETH</i>	<i>LTC</i>	<i>XRP</i>	<i>TRX</i>	<i>XMR</i>
<i>HE</i>	0,72	0,78	0,75	0,78	0,76	0,77
GNB	0,02	0,01	0,70	0,68	0,17	0,75
KNN	0,74	0,64	0,78	0,77	0,74	0,78
LG	0,48	0,37	0,77	0,79	0,14	0,80
MLP	0,59	0,58	0,68	0,76	0,45	0,73
MNB	0,75	0,77	0,78	0,80	0,76	0,78
RFC	0,74	0,72	0,76	0,80	0,72	0,79
SVC	0,24	0,01	0,70	0,75	0,20	0,75

Nota: Los mejores resultados para cada criptomoneda se indican en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Cuadro 3.

Valores de F1 ponderadas para cada modelo de clasificación por el mercado bajista

<i>Modelo</i>	<i>BTC</i>	<i>ETH</i>	<i>LTC</i>	<i>XRP</i>
<i>HE</i>	0,75	0,75	0,76	0,74
GNB	0,78	0,79	0,77	0,77
KNN	0,71	0,72	0,78	0,75
LG	0,78	0,77	0,80	0,76
MLP	0,72	0,72	0,76	0,72
MNB	0,78	0,77	0,78	0,76
RFC	0,75	0,78	0,79	0,76
SVC	0,66	0,63	0,78	0,76

Nota: Los mejores resultados para cada criptomoneda se indican en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

poblado. Además, los umbrales se calculan en los 50 días anteriores, actualizando con mucho retraso los valores de media móvil y desviación estándar, a pesar de que el mercado presenta una dinámica muy rápida y una alta volatilidad. En contraste, en el siguiente período de valoración (2022), los modelos pueden contar con un período de entrenamiento que también incluye el período de alta volatilidad del mercado alcista (2021). De este modo, se pueden predecir mejor las reacciones de precios excesivas, incluso en un mercado de tendencia opuesta.

5.2.2. Resultados de las simulaciones de inversión

Los cuadros 4 y 5 presentan los resultados de las simulaciones de inversión correspondientes a los dos períodos considerados. En particular, para cada criptomoneda se proponen los resultados de la estrategia heurística y los dos mejores algoritmos de clasificación, evaluados en términos de operaciones rentables, rendimiento total y rendimiento promedio por operación.

Cuadro 4.

Resultados operativos en el mercado alcista

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
BTC	<i>HE</i>	37	21	55,76	-0,87	-0,02
	KNN	9	6	66,67	17,57	1,95
	SVC	258	134	51,94	58,56	0,23
ETH	<i>HE</i>	33	18	54,55	27,01	0,82
	MLP	137	73	53,28	124,06	0,91
	MNB	27	14	51,85	-14,71	-0,54
LTC	<i>HE</i>	33	19	57,58	0,73	0,02
	KNN	1	1	100,00	19,36	19,36
	SVC	74	47	63,51	100,68	1,36
XRP	<i>HE</i>	30	18	60,00	23,04	0,77
	MLP	35	24	68,57	89,21	2,55
	SVC	70	39	55,71	69,61	0,99
TRX	<i>HE</i>	34	16	47,06	4,08	0,12
	KNN	27	19	70,37	15,75	0,58
	SVC	271	157	57,93	104,36	0,39
XMR	<i>HE</i>	31	15	48,39	-18,19	-0,59
	KNN	8	6	75,00	16,75	2,09
	MLP	19	15	78,95	41,01	2,16

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Los resultados del período alcista (cuadro 4) muestran cómo la estrategia de aprendizaje automático puede lograr mejores resultados en las tres métricas analizadas. Además, los mejores algoritmos de clasificación son siempre KNN, SVC y MLP. Los dos primeros ya habían demostrado ser los mejores también en las simulaciones de inversión realizadas sobre

Cuadro 5.

Resultados operativos en el mercado bajista

<i>Moneda</i>	<i>Modelo</i>	<i>Inversiones</i>	<i>Inversiones rentables</i>	<i>Inversiones rentables %</i>	<i>Rendimiento total %</i>	<i>Rendimiento medio %</i>
BTC	<i>HE</i>	35	24	68,57	37,21	1,06
	KNN	66	30	45,45	10,02	0,15
	GNB	24	13	54,17	-10,27	-0,43
ETH	<i>HE</i>	43	26	60,47	48,22	1,12
	KNN	47	27	57,45	55,04	1,17
	LG	11	5	45,45	-4,17	-0,38
LTC	<i>HE</i>	36	21	58,33	39,41	1,99
	KNN	11	7	63,64	16,67	1,52
	SVC	12	9	75,00	23,67	1,97
XRP	<i>HE</i>	38	18	47,37	8,91	0,23
	GNB	20	11	55,00	23,43	1,17
	SVC	52	29	55,77	21,91	0,42

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

el año 2020, superando siempre los resultados de la estrategia heurística y abriendo menos posiciones totales y más rentables. Al contrario, durante el mercado alcista, las simulaciones que emplea el clasificador abren más posiciones que la heurística, con la excepción de KNN, que logra alcanzar porcentajes de operaciones rentables y rendimientos medios muy elevados. SVC y MLP en cambio abren un mayor número de posiciones, aumentando enormemente los beneficios totales. En concreto, estas dos técnicas no obtienen buenos resultados de clasificación, sino altas ganancias cuando se aplican al mercado. Esto se debe a que clasifican erróneamente muchos días normales como días de reacción excesiva positiva, disminuyendo su puntuación de F1 y aumentando el número de señales largas. De esta manera, pueden aprovechar las numerosas subidas diarias que caracterizan el mercado alcista en el que operan, acumulando una alta ganancia total. En el período bajista (cuadro 5) la situación cambia ligeramente. La caída de los precios frena los rendimientos de todas las estrategias. KNN y SVC siguen siendo los mejores, aunque con resultados menos brillantes que en el período anterior. El número de posiciones abiertas también disminuye, lo que demuestra que la formación adicional en un período de alta volatilidad (2021) permite a los algoritmos de aprendizaje automático mejorar sus capacidades predictivas, como ya se ha mencionado anteriormente comentando los resultados de la clasificación.

5.2.3. Resultados de las simulaciones de inversión cruzada

Dado el alto dominio del mercado mostrado por bitcoin, se proponen más simulaciones de compraventa basadas en una estrategia cruzada. Específicamente, se utilizan predicciones generadas por clasificadores entrenados en datos de bitcoin para generar señales de mercado

para otras criptomonedas. Las simulaciones se limitan a los mejores clasificadores en términos de rentabilidad para bitcoin, es decir, KNN y SVC para el período alcista y KNN para el período bajista.

Cuadro 6.

Resultados operativos en el mercado alcista con predicción cruzada

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
ETH	<i>HE</i>	33	18	54,55	27,01	0,82
	MLP _{BTC}	9	7	77,78	31,92	3,55
	MNB _{BTC}	258	147	56,98	175,54	0,68
LTC	<i>HE</i>	33	19	57,58	0,73	0,02
	KNN _{BTC}	9	7	77,78	20,71	2,30
	SVC _{BTC}	258	137	53,10	83,89	0,33
XRP	<i>HE</i>	30	18	60,00	23,04	0,77
	KNN _{BTC}	9	6	66,67	6,67	1,85
	SVC _{BTC}	258	133	51,55	198,64	0,77
TRX	<i>HE</i>	34	16	47,06	4,08	0,12
	KNN _{BTC}	9	7	77,78	8,14	0,90
	SVC _{BTC}	258	134	51,94	137,12	0,53
XMR	<i>HE</i>	31	15	48,39	-18,19	-0,59
	KNN _{BTC}	9	7	77,78	26,70	2,97
	SVC _{BTC}	258	149	57,75	86,33	0,33

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Los cuadros 6 y 7 muestran los resultados obtenidos comparándolos con la estrategia heurística clásica utilizada en cada criptomoneda. En cuanto al mercado alcista, las predicciones realizadas sobre el bitcoin son efectivas para predecir movimientos de precios de otras criptomonedas. Esto demuestra una fuerte correlación de estas últimas con la principal y más antigua criptomoneda en el mercado. KNN_{BTC} se muestra nuevamente eficiente en reportar

Cuadro 7.

Resultados operativos en el mercado bajista con predicción cruzada

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
ETH	<i>HE</i>	43	26	60,47	48,22	1,12
	MNB _{BTC}	66	33	50,00	0,96	0,01
LTC	<i>HE</i>	36	21	58,33	39,41	1,09
	KNN _{BTC}	66	34	51,52	33,85	0,51
XRP	<i>HE</i>	38	18	47,37	8,91	0,23
	KNN _{BTC}	66	34	51,52	22,17	0,34

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

operaciones rentables, obteniendo también altos rendimientos medios. SVC_{BTC} genera un gran número de señales a expensas de la precisión, permitiendo maximizar los beneficios. El mercado bajista vuelve a ser más difícil para las estrategias basadas en el aprendizaje automático, con el modelo heurístico obteniendo mejores resultados que KNN_{BTC} .

6. CONCLUSIONES

Después de presentar las principales características de la tecnología *blockchain*, este trabajo resume los pasos que llevaron al nacimiento y desarrollo de las criptomonedas y su mercado. Aunque esta versión moderna del dinero digital aporta varios beneficios de seguridad y no necesita una autoridad central, la alta volatilidad de los precios de estos nuevos activos todavía no permite utilizarlos como moneda alternativa a las modernas monedas fiduciarias. La alta frecuencia y la magnitud de las variaciones de precios también han atraído a un gran número de pequeños inversores, que sólo están interesados en las oportunidades de ingresos, lo que hace que el mercado sea extremadamente inestable. Algunos estudios también muestran que este mercado está sujeto a algunas de las anomalías estudiadas por las finanzas conductuales, incluido el efecto *momentum*. La segunda parte de este trabajo se centra precisamente sobre este último, ofreciendo una visión general de cómo se puede predecir el efecto *momentum* en el mercado de las criptomonedas, y cómo se puede aprovechar para generar beneficios mediante la realización de operaciones diarias. Después de presentar dos estrategias de inversión diferentes basadas en un modelo heurístico y otro de aprendizaje automático y los resultados obtenidos por ellos en una fase de mercado de movimiento lateral, se amplía el estudio a un período caracterizado por una alta volatilidad. Aunque la estrategia heurística presentada es rentable, muestra algunas limitaciones. El uso del aprendizaje automático permite aumentar la eficiencia de la estrategia de inversión, haciéndola más rentable, pudiendo procesar más información en forma de indicadores técnicos. Por lo tanto, el aprendizaje automático es una herramienta valiosa para usar en actividades de inversión, aunque tiene algunas desventajas. En primer lugar, la dificultad de predecir los precios reales obliga a utilizar modelos de clasificación, que solamente pueden utilizarse para predecir tendencias, generando así señales de inversión a corto plazo. Además, las tendencias analizadas son atribuibles a la psicología y al comportamiento de los inversores, ya que resulta complicado identificar el valor intrínseco de los activos. El mercado de las criptomonedas acentúa estas limitaciones al ser un mercado poco estructurado y muy volátil, poblado por inversores no institucionales que negocian con activos cuyo valor intrínseco a menudo es imposible de evaluar. Por esta razón, estas estrategias aún requieren un alto control, para poder interceptar grandes cambios o alteraciones del mercado, que podrían socavar su rentabilidad ya que los modelos están entrenados con datos históricos.

Referencias

- ATTANASIO, G., CAGLIERO, L. y BARALIS, E. (2020). Leveraging the explainability of associative classifiers to support quantitative stock trading. En *Proceedings of the Sixth International Workshop on Data Science for Macro-Modeling* (pp. 1-6).

- ATTANASIO, G., CAGLIERO, L., GARZA, P. y BARALIS, E. (2019). Quantitative crypto- currency trading: exploring the use of machine learning techniques. En *Proceedings of the 5th Workshop on Data Science for Macro-modeling with Financial and Economic Data- sets, DSMM@SIGMOD 2019, Amsterdam, The Netherlands, June 30, 2019*, 1:1-1:6. ACM. <https://doi.org/10.1145/3336499.3338003>
- BARIVIERA, A. F. (2017). The inefficiency of bitc oin revisited: A dynamic approach. *Economics Letters*, 161, pp. 1-4. ISSN: 0165-1765. (<https://doi.org/10.1016/j.econlet.2017.09.013>). (<https://www.sciencedirect.com/science/article/pii/S0165176517303804>).
- BARTOS, J. (2015). Does bitc oin follow the hypothesis of efficient market? *International Journal of Economic Sciences*, IV (enero), pp. 10-23. <https://doi.org/10.20472/ES.2015.4.2.002>
- BELLOCCA, G. P., ATTANASIO, G., CAGLIERO, L. y FIOR, J. (2022). Leveraging the momentum effect in machine learning-based cryptocurrency trading. *Machine Learning with Applications*, 8:100310. ISSN: 2666-8270. (<https://doi.org/10.1016/j.mlwa.2022.100310>). (<https://www.sciencedirect.com/science/article/pii/S2666827022000329>).
- BUSTOS, O. y POMARES-QUIMBAYA, A. (2020). Stock market movement forecast: A Systematic review. *Expert Syst. Appl*, 156, 113464. (<https://doi.org/10.1016/j.eswa.2020.113464>). (<https://doi.org/10.1016/j.eswa.2020.113464>).
- CAPORALE, G. M. y PLASTUN, A. (2020). Momentum effects in the cryptocurrency market after one-day abnormal returns. *Financial Markets and Portfolio Management*, 34, pp. 251-266.
- CHEVAPATRAKUL, T. y MASCIA, D. V. (2019). Detecting overreaction in the bitc oin market: A quantile autoregression approach. *Finance Research Letters*, 30 (septiembre), pp. 371-377. <https://doi.org/10.1016/j.frl.2018.11.004>
- CORBET, S., LUCEY, B. y YAROVAYA, L. (2018). Datestamping the bitc oin and Ethereum bubbles. *Finance Research Letters*, 26 (C): 81-88. <https://EconPapers.repec.org/RePEc:eee:finlet:v:26:y:2018:i:c:p:81-88>
- DERBENTSEV, V., BABENKO, V., KHRUSTALEV, K., OBRUCH, H. y KHRUSTALOVA, S. (2021). Comparative performance of machine learning ensemble algorithms for forecasting cryptocurrency prices. *International Journal of Engineering*, 34(1), pp. 140-148.
- GANDAL, N. y HALABURDA, H. (2014). Competition in the Cryptocurrency Market. *Working Papers*, 14-17. NET Institute. <https://EconPapers.repec.org/RePEc:net:wpaper:1417>
- GLENSKI, M., WENINGER, T. y VOLKOVA, S. (2019). *Improved Forecasting of Cryptocurrency Price using Social Signals*. arXiv: 1907.00558 [q-fin.ST].
- HUANG, B., HUAN, Y., XU, L. D., ZHENG, L. y ZOU, Z. (2019). Automated trading systems statistical and machine learning methods and hardware implementation: a survey. *Enterprise Information Systems*, 13(1), pp. 132-144. <https://doi.org/10.1080/17517575.2018.1493145>
- JEGADEESH, N. y TITMAN, S. (1993). Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. *The Journal of Finance*, 48(1), pp. 65-91.
- KRAAIJEVELD, O. y DE SMEDT, J. (2020). The predictive power of public Twitter sentiment for forecasting cryptocurrency prices. *Journal of International Financial Markets, Institutions and Money*, 65, 101188. ISSN: 1042-4431. (<https://doi.org/10.1016/j.intfin.2020.101188>). (<https://www.sciencedirect.com/science/article/pii/S104244312030072X>).
- KURIHARA, Y. y FUKUSHIMA, A. (2017). The Market Efficiency of bitc oin: A Weekly Anomaly Perspective. *Journal of Applied Finance & Banking*, 7(3). https://EconPapers.repec.org/RePEc:spt:apfiba:v:7:y:2017:i:3:f:7_3_4
- LAHMIRI, S. y BEKIROS, S. D. (2021). Deep Learning Forecasting in Cryptocurrency High Frequency Trading. *Cogn. Comput.* 13(2), pp. 485-487. <https://doi.org/10.1007/s12559-021-09841-w>
- LANSDORP, S. y JELLEMA, W. (2013). Momentum from underreaction. *White Paper - ROBECO*.
- LIVIERIS, I. E., PINTELAS, E. G., STAVROYIANNIS, S. y PINTELAS, P. E. (2020). Ensemble Deep Learning Models for Forecasting Cryptocurrency Time-Series. *Algorithms*, 13(5), pp. 121. <https://doi.org/10.3390/a13050121>

- MURPHY, J. J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance Series. New York Institute of Finance. ISBN: 9780735200661. https://books.google.it/books?id=5zhXEqr%5C_IcC
- OZBAYOGLU, A. M., GUDELEK, M. U. y SEZER, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. ISSN: 1568-4946. <https://doi.org/10.1016/j.asoc.2020.106384>
- PLASTUN, A., BOURI, E., GUPTA, R. y JI, Q. (2021). Price effects after one-day abnormal returns in developed and emerging markets: ESG versus traditional indices. *The North American Journal of Economics and Finance*, 59 (octubre), 101572. <https://doi.org/10.1016/j.najef.2021.101572>
- ROUWENHORST, K. (1999). Local Return Factors and Turnover in Emerging Stock Markets. *The Journal of Finance*, 54(4), pp. 1439-1464.
- RUNDO, T., DI STALLO, A. L. y BATTIATO, S. (2019). Machine Learning for Quantitative Finance Applications: A Survey. *Applied Sciences*, 9, (24) (diciembre), 5574. ISSN: 2076-3417. (<https://doi.org/10.3390/app9245574>). (<http://dx.doi.org/10.3390/app9245574>).
- SUN, X., LIU, M. y SIMA, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. ISSN: 1544-6123. (<https://doi.org/10.1016/j.frl.2018.12.032>). (<https://www.sciencedirect.com/science/article/pii/S1544612318307918>).
- URQUHART, A. (2016). The Inefficiency of bitcoin. *Economics Letters*, 148 (septiembre). <https://doi.org/10.1016/j.econlet.2016.09.019>