

Identificación de factores de influencia en el precio de las criptomonedas: evidencia para *bitcoin* y *ethereum*

Identifying Influencing Factors on Cryptocurrency Price: Evidence for Bitcoin and Ethereum

Prosper Lamothe Fernández
Universidad Autónoma de Madrid

Prosper Lamothe López
Rho Finanzas

Manuel A. Fernández Gámez
Sergio M. Fernández Miguélez
Universidad de Málaga

Resumen

El presente estudio tiene como objetivo el desarrollo de nuevos modelos para determinar con alta precisión los factores que explican el precio de las principales criptomonedas. Para ello se ha utilizado una amplia base de datos de variables relacionadas con el bitcoin y el ethereum, y se han aplicado técnicas de redes neuronales artificiales. Los resultados obtenidos han permitido identificar que los aspectos relacionados con el número de publicaciones en foros, el volumen de transacciones en blockchain y la tasa de hash proporcionan una excelente estrategia para predecir el precio del bitcoin. También, que el volumen de transacciones, el tamaño de los bloques, las comisiones de mineros y los precios del petróleo son los mejores predictores del valor de mercado del ethereum.

Palabras clave: bitcoin, ethereum, redes neuronales artificiales, criptomonedas, blockchain.

JEL: C63, D46, E47, F37, G12

Abstract

The present study aims to develop new models to determine with high precision the factors that explain the price of the main cryptocurrencies. To do this, a large database of variables related to bitcoin and ethereum has been used, and artificial neural network techniques have been applied. The results obtained have made it possible to identify the following factors: the number of posts in social networks, the volume of transactions on blockchain and the hash rate provide an excellent strategy to predict the price of bitcoin. Also, that the volume of transactions, the size of the blocks, the commissions of miners and the prices of oil are the best predictors of the market value of ethereum.

Keywords: bitcoin, ethereum, neural networks, cryptocurrencies, blockchain

JEL: C63, D46, E47, F37, G12.

1. Introducción

Actualmente la tecnología *blockchain* promueve interacciones entre partes sin la necesidad de una autoridad central y no sólo se utiliza para transacciones monetarias, sino también en un dominio de aplicaciones más amplio tales como los contratos inteligentes (Pierro y Rocha, 2019; Ethereum Foundation, 2018). En este contexto, las criptomonedas están marcando una tendencia cada vez más fuerte en todos los mercados financieros, y la literatura financiera está dedicando más atención a su estudio (Liu *et al.*, 2020; Nasir *et al.*, 2019; Grinberg, 2012). Investigaciones recientes han identificado diferentes factores que afectan al precio de las criptomonedas, especialmente al *bitcoin* y al *ethereum* (Sovbetov, 2018; Al-Khazali *et al.*, 2018; Civitarese, 2018). Estos factores están relacionados principalmente con la demanda y la oferta, con el atractivo en redes sociales, y con variables macroeconómicas y financieras. Sin embargo, la importancia de estos factores varía de un estudio a otro y los resultados existentes demandan modelos de medición con altos niveles de precisión (Lamothe *et al.*, 2020; Sin y Wang, 2017). Para arrojar luz sobre la importancia de los factores que explican el precio de las principales criptomonedas, este estudio ha construido una amplia base de datos sobre *bitcoin* y *ethereum* para el periodo 2015-2020 que incluye todas las variables que han sido relacionadas con las monedas en la literatura previa. Posteriormente se han aplicado técnicas de redes neuronales artificiales para estimar la sensibilidad de las variables respecto a los precios del *bitcoin* y del *ethereum*. Concretamente, se ha desarrollado un modelo perceptrón multicapas (PMC), que ha sido una de las técnicas de inteligencia artificial que mejores resultados de predicción han proporcionado en ingeniería y finanzas debido a su capacidad de realizar tareas complejas, como clasificación, patrón de reconocimientos y predicciones (Alessandretti *et al.*, 2018; Gupta y Wang, 2010). Los resultados obtenidos con PMC han permitido estimar, con una precisión superior al 93%, dos conjuntos inéditos de variables con un alto impacto en los precios del *bitcoin* y del *ethereum*. De este modo, los resultados proporcionan importantes contribuciones teóricas y prácticas a la literatura sobre criptomoneda, especialmente indicando nuevas perspectivas de investigación que pueden ser consideradas en los modelos sobre su valoración.

El resto del estudio se organiza como sigue. Tras esta introducción se presenta un análisis de la literatura previa sobre las variables relacionadas con el precio del *bitcoin* y del *ethereum*. A continuación, se deja constancia de los aspectos metodológicos de la investigación. Posteriormente se presentan las especificaciones de las variables y de los datos utilizados. El estudio finaliza con la exposición de los resultados obtenidos y de las principales conclusiones.

2. Revisión de la literatura

En la literatura financiera sobre criptomonedas destacan los estudios que tratan de determinar las variables que afectan al valor las mismas. Este problema ha sido objeto de varias líneas de investigación, que han abordado el análisis de diferentes tipos de variables. En primer lugar, los modelos basados en variables sobre la dinámica entre la demanda y oferta (Civitarese, 2018; Poyser, 2017; Balcilar *et al.*, 2017). En segundo lugar, los estudios que relacionan el valor con el atractivo que la misma ofrece en redes sociales a los inversores (Nasir *et al.*, 2019; Hayes, 2017). Y en tercer lugar, los que relacionan el valor del *bitcoin* con variables macroeconómicas y financieras (Al-Khazali *et al.*, 2018; Poyser, 2017).

Respecto a las variables relacionadas con la demanda y la oferta, la literatura previa ha tratado de determinar las variables que impactan directamente en las curvas de demanda, pues existe un límite en la cantidad de criptomonedas ofrecidas en el mercado. En este contexto destacan las variables relacionadas con el tamaño del mercado (Liu *et al.*, 2020). La creciente realización de transacciones tiende a estimular su adopción por otros agentes económicos, impulsando la demanda de criptomonedas. El uso del dinero digital y el comercio electrónico también ayudan al desarrollo y adopción de monedas virtuales impulsando su demanda (Kristoufek, 2015; Polasik *et al.*, 2015). En este sentido, el número de criptomonedas disponibles se asocia con efecto negativo en el valor de las monedas (Ciaian, 2016a). Igualmente, el número de direcciones (carteras virtuales) se asocia con un efecto directo y positivo en el precio (Civitarese, 2018; Ciaian, 2016a). Y del mismo modo, las variables de volumen de transacciones diarias y transferencias por los usuarios de la red también han demostrado tener un impacto directo en los precios (Sovbetov, 2018; Buchholz *et al.*, 2012). En estos estudios subyacen los postulados de la teoría cuantitativa del dinero (Lucas, 1980). Esta teoría postula que el valor de las transacciones que se realizan en una economía ha de ser igual a la cantidad de dinero existente por el número de veces que el dinero cambia de manos, variable que se denomina velocidad de circulación del dinero. De su aplicación al ámbito de las criptomonedas se deduce que el precio del cryptoactivo está asociado a medidas de volumen tales como número de transacciones diarias y número de direcciones. Y por otra parte, también es interesante considerar la influencia de la velocidad de circulación de la criptomoneda, que tiene una relación inversa con el valor de la misma (Chen *et al.*, 2020). En este contexto, el papel de los denominados *holders*¹ es muy importante ya que su existencia y capacidad financiera contribuyen a reducir la velocidad de circulación al «atesorar» criptomonedas reduciendo las posibilidades de transmisión de las mismas.

Otros estudios encuentran resultados que matizan las anteriores conclusiones. Por ejemplo, Bouoiyour y Selmi (2015) indican que el volumen del mercado afecta a los precios sólo a corto plazo. Y por su parte, Balcilar *et al.* (2017) encontraron que los

¹ Los *holders* o *hodlers* son aquellos inversores que mantienen posiciones a medio y largo plazo de criptomonedas con la expectativa de obtener plusvalías en su inversión.

efectos del tamaño del mercado no se verifican en periodos de precios ascendentes o descendentes que coinciden con situaciones de estrés. Finalmente, otras variables técnicas y económicas también han sido relacionadas con la demanda y oferta de criptomonedas. Entre ellas aparecen la denominada tasa de hash, la dificultad de minar un nuevo bloque para *blockchain* y las comisiones percibidas por los mineros (Poyser, 2017; Matonis, 2012).

De otra parte, y como hemos expuesto anteriormente, un modelo alternativo para explicar el precio de las criptomonedas es la denominada economía de redes. Bajo esta teoría, la literatura previa ha detectado que las variables relacionadas con el atractivo en redes sociales tienen un impacto significativo en el valor de las criptomonedas. Por ejemplo, las búsquedas en medios electrónicos para obtener información sobre el funcionamiento del *bitcoin* y del *ethereum* han sido unas de las variables de atractivo más referenciadas (Sovbetov, 2018). Estudios basados en metodologías de autorregresión vectorial y corrección de errores vectoriales indicaron que la cantidad de búsquedas en Google y Wikipedia tiene una fuerte asociación temporal con los precios de las criptomonedas, y que el interés del público en aumentar el conocimiento sobre la operatoria de estos activos mostró una relación directa con los precios (Kristoufek 2015). También Nasir *et al.* (2019), Davies (2014) y Polasik *et al.* (2015) encontraron una relación directa y significativa entre el historial de búsqueda del término *bitcoin* en Google, Twitter, Wikipedia y los precios. Sin embargo, los estudios de Ciaian *et al.* (2016a) y Hayes (2017) encontraron que el factor de atractivo, aunque significativo, ha perdido relevancia a través del tiempo, debido a la consolidación de las criptomonedas y a la difusión del conocimiento sobre las mismas. Además, Bouoiyour y Selmi (2015) tampoco encontraron evidencias del impacto de las búsquedas de Google en el precio en el largo plazo.

Finalmente, diferentes factores macroeconómicos y financieros tales como los tipos de cambio del dólar USA, el precio del oro y los índices bursátiles han demostrado tener también un impacto significativo en el precio de las criptomonedas a través del tiempo. Zhu *et al.*, (2017), Dyhrberg (2016) y Van Wijk (2013) señalaron que había evidencias de causalidad entre el precio del dólar USA y el precio del *bitcoin*, indicando que el *bitcoin* podría usarse como cobertura para el riesgo de exposición al dólar a corto plazo. Por su parte, Zhu *et al.* (2017) encontraron una relación directa y significativa del precio del oro en el valor del *bitcoin*. Bouoiyour y Selmi (2015) y Van Wijk (2013) comprobaron que índices bursátiles tales como Dow Jones y Shanghai Stock Exchange parecían estar positivamente correlacionado a corto y largo plazo con el precio de las criptomonedas, y Kristoufek (2015) destacó el impacto general de las variables macroeconómicas en el precio de las mismas.

Las conclusiones anteriores sobre el impacto de las variables macroeconómicas y financieras no están tampoco fuera de controversia. Algunos autores han verificado que las variables macroeconómicas y financieras no tienen una influencia estadísticamente significativa en los precios del *bitcoin* y del *ethereum* a largo plazo (Sovbetov, 2018; Bouri *et al.*, 2017; Chao *et al.*, 2019; Ciaian *et al.*, 2016a; Polasik *et al.*, 2015). Por ejemplo, Dyhrberg (2016) encontró que el *bitcoin* no tienen correlación con las

100 compañías más grandes que cotizan en la bolsa de Londres. Por su parte, Ciaian *et al.* (2016b) señalaron que no hubo relevancia estadística significativa respecto a factores tales como el índice Dow Jones y los precios del petróleo. Polasik *et al.* (2015) concluyeron que la correlación entre los retornos de *bitcoin* y las fluctuaciones de las monedas soberanas fueron débiles y estadísticamente insignificantes. Al-Khazali *et al.* (2018) argumentaron que el *bitcoin* está débilmente relacionado con variables macroeconómicas debido a la volatilidad del *bitcoin* después de noticias macroeconómicas sorpresa. Sovbetov (2018) concluyó que el índice SP500 parece tener un débil impacto positivo a largo plazo en *bitcoin* y en *ethereum*. Y según Bouoiyour y Selmi (2015) y Kristoufek (2015), el precio del oro tampoco parece estar relacionado con la fijación de los precios de estas criptomonedas.

3. Métodos de contrastación empírica

Las técnicas de redes neuronales artificiales (RNA) han sido utilizadas en numerosos estudios empíricos recientes potenciados por los buenos resultados obtenidos, mejorando en muchos casos a los modelos estadísticos existentes (Alaminos *et al.*, 2018). Las ventajas de los modelos RNA residen en la solución de problemas independientemente de su complejidad, no requiriendo, como si necesitan otros modelos estadísticos, de una relación lineal (Hecht-Nielsen, 1990). Además, Nuñez de Castro y Von Zuben (1998) y Faris *et al.* (2016) confirmaron que el aprendizaje en RNA constituye una aproximación funcional en la que no existe ninguna hipótesis previa sobre el modelo subyacente a los datos analizados.

PMC es un modelo de RNA con una capa de unidades de entrada, una capa de unidades de salida y un determinado número de capas intermedias, llamadas *capas ocultas* y sin conexión con el exterior. Las unidades de la capa de entrada están conectadas a las unidades de la capa oculta y éstas a su vez con las unidades de la capa de salida. El objetivo de la red PMC es conseguir una correspondencia entre un conjunto de datos de entrada y un conjunto de salidas deseadas, determinando una función que represente correctamente los patrones de aprendizaje y permita un proceso de generalización para datos no analizados durante dicho aprendizaje (Heidari *et al.*, 2019).

PMC utiliza la expresión [1] para calcular un ajuste de pesos W de un conjunto de datos que minimicen el error de aprendizaje, $E(W)$.

$$\min_W E(W) = \min_W \sum_{i=1}^p \varepsilon(W, x_i, y_i) \quad [1]$$

donde $\{(x_1, y_1), (x_2, y_2), \dots, (x_p, y_p)\}$ representan el conjunto de pares de patrones de aprendizaje y $\varepsilon(W, X, Y)$ es la función de error.

Como complemento al modelo PMC, el presente estudio aplica un análisis de sensibilidad de las variables independientes. Este análisis de sensibilidad tiene como objetivo cuantificar el impacto de las variables en la explicación del problema objeto

de estudio. En este sentido, una variable se considera más significativa que otra si aumenta la varianza en comparación con el conjunto de variables. Para ello se utiliza el método Sobol (1993), que descompone la varianza de la salida total $V(Y)$ conforme con las ecuaciones expresadas en [2].

$$\begin{aligned}
 V(Y) &= \sum_i + \sum_i \sum_{j>1} V_{ij} + \dots + V_{1,2,\dots,k} \\
 V_i &= V(E(Y|X_i)) \\
 V_{ij} &= V(E(Y|X_i, X_j)) - V_i - V_j
 \end{aligned}
 \tag{2}$$

Los índices de sensibilidad están determinados por $S_i = V_i/V$ y $S_{ij} = V_{ij}/V$, siendo S_{ij} el efecto de la interacción entre dos factores.

4. Variables y datos

El presente estudio utiliza un conjunto de variables seleccionadas de la literatura previa sobre *bitcoin* y *ethereum* (Pierro y Rocha, 2019; Sovbetov, 2018; Balcilar *et al.*, 2017; Nasir *et al.*, 2019; Zhu *et al.*, 2017; Poyser, 2017). La información correspondiente a las variables está referida a datos medios diarios del periodo comprendido entre agosto 2015 y septiembre 2020. Las variables dependientes son los precios del *bitcoin* y del *ethereum* en dólares USA. Por su parte, las variables independientes hacen referencia a tres aspectos relacionados con el valor estas criptomonedas. En primer lugar, los de demanda y oferta (incluyendo variables de volumen, costes de transacción y tecnología). En segundo lugar, variables sobre el atractivo (foros y noticias *online*). Y en tercer lugar un grupo de variables relacionadas con factores macroeconómicos y financieros (petróleo, oro, índices bursátiles y tipos de cambio). La descripción de las variables utilizadas en la presente investigación aparece en el Cuadro 1.

Los datos de las variables relacionadas con la demanda y oferta provienen de la información suministrada por las *web* blockchain.com, etherscan.io y Quandl.com. Por su parte, la información sobre atractivo ha sido obtenida de las *web* bitcoin-talk.org. y bitinfocharts.com, y la de variables macroeconómicas y financieras de Eurostat, New York Stock Exchange y *web* goldprice.org para tipos de cambio, precios del petróleo y oro, respectivamente. Finalmente, se han utilizado el 80 % de los datos para entrenamiento del modelo PMC y se ha reservado el 20 % de los mismos para el testeo del modelo.

CUADRO 1
VARIABLES DE POSIBLE INFLUENCIA EN LOS PRECIOS DE BITCOIN Y ETHEREUM

Variables	Descripción
<i>a) Demanda y oferta</i>	
Valor de las transacciones de bitcoin	Valor en \$ de las transacciones diarias de bitcoin
Valor de las transacciones de ethereum	Valor en \$ de las transacciones diarias de ethereum
Número de bitcoins	Número de bitcoins que circulan actualmente en la red
Número de ethereums	Número de ethereums que circulan actualmente en la red
Direcciones de bitcoins	Número de direcciones únicas de bitcoin utilizadas por día
Direcciones de ethereums	Número de direcciones únicas de ethereum utilizadas por día
Volumen de transacciones bitcoin	Número de transacciones por día bitcoin
Volumen de transacciones ethereum	Número de transacciones por día ethereum
Transacciones de blockchain	Número de transacciones en blockchain
Direcciones de blockchain	Número de direcciones únicas usadas en blockchain
Tamaño del bloque bitcoin	Promedio del tamaño del bloque bitcoin expresado en megabytes
Tamaño del bloque ethereum	Promedio del tamaño del bloque ethereum expresado en megabytes
Recompensa mineros bitcoin	Recompensas por bloque pagados a mineros bitcoin
Recompensa mineros ethereum	Recompensas por bloque pagados a mineros ethereum
Comisiones mineros bitcoin	Promedio de las comisiones por transacción bitcoin (en USD)
Comisiones mineros ethereum	Promedio de las comisiones por transacción ethereum (en USD)
Dificultad	Dificultad de minar un nuevo bloque para blockchain
Hash bitcoin	Veces que una función hash puede ser calculada por segundo (bitcoin)
Hash ethereum	Veces que una función hash puede ser calculada por segundo (ethereum)
<i>b) Atractivo</i>	
Publicaciones en foros bitcoin	Número de nuevos miembros en foros online de bitcoin
Publicaciones en foros ethereum	Número de nuevos miembros en foros online de ethereum
Miembros de foros de bitcoin	Nuevas publicaciones en foros online de bitcoin
Miembros de foros de ethereum	Nuevas publicaciones en foros online de ethereum
<i>c) Macroeconómicas y financieras</i>	
Petróleo Texas	Precio del petróleo (West Texas)
Petróleo Brent	Precio Petróleo (Brent, Londres)
Tipo de cambio dólar	Tipo de cambio entre el dólar estadounidense y el euro
Dow Jones	Índice Dow Jones de la bolsa de New York
Oro	Precio del oro (en USD por onza troy)

FUENTE: Elaboración propia.

5. Resultados

Modelo PMC

Los Cuadros 2 y 3 y los Gráficos 1 y 2 muestran las características de la arquitectura de los modelos PMC desarrollados en el presente estudio. Los mejores resultados se han obtenido con una estructura de 4 neuronas en la capa oculta para el modelo de *bitcoin* y con 2 neuronas para el de *ethereum*, en ambos casos utilizando la función de activación tangente hiperbólica.

Los resultados de predicción obtenidos con los modelos PMC aparecen en los Cuadros 4 y 5 (véase también Gráficos 3 y 4). En estos resultados destaca el alto nivel de precisión de la estimación tanto con los datos de entrenamiento (97,481% para *bitcoin* y 96,722% para *ethereum*) como con los de testeo (94,190% y 93,081% para *bitcoin* y *ethereum*, respectivamente). El resto de indicadores sugieren también un aceptable ajuste del modelo.

CUADRO 2
ARQUITECTURA PMC (BITCOIN)

Parámetros	Descripción
Número de neuronas en la capa de entrada	18
Número de neuronas en la capa oculta	4
Número de neuronas en la capa de salida	1
Método de cambio de escala de las variables independientes	Tipificado
Función de activación de la capa oculta	Tangente hiperbólica
Función de error	Suma de cuadrados

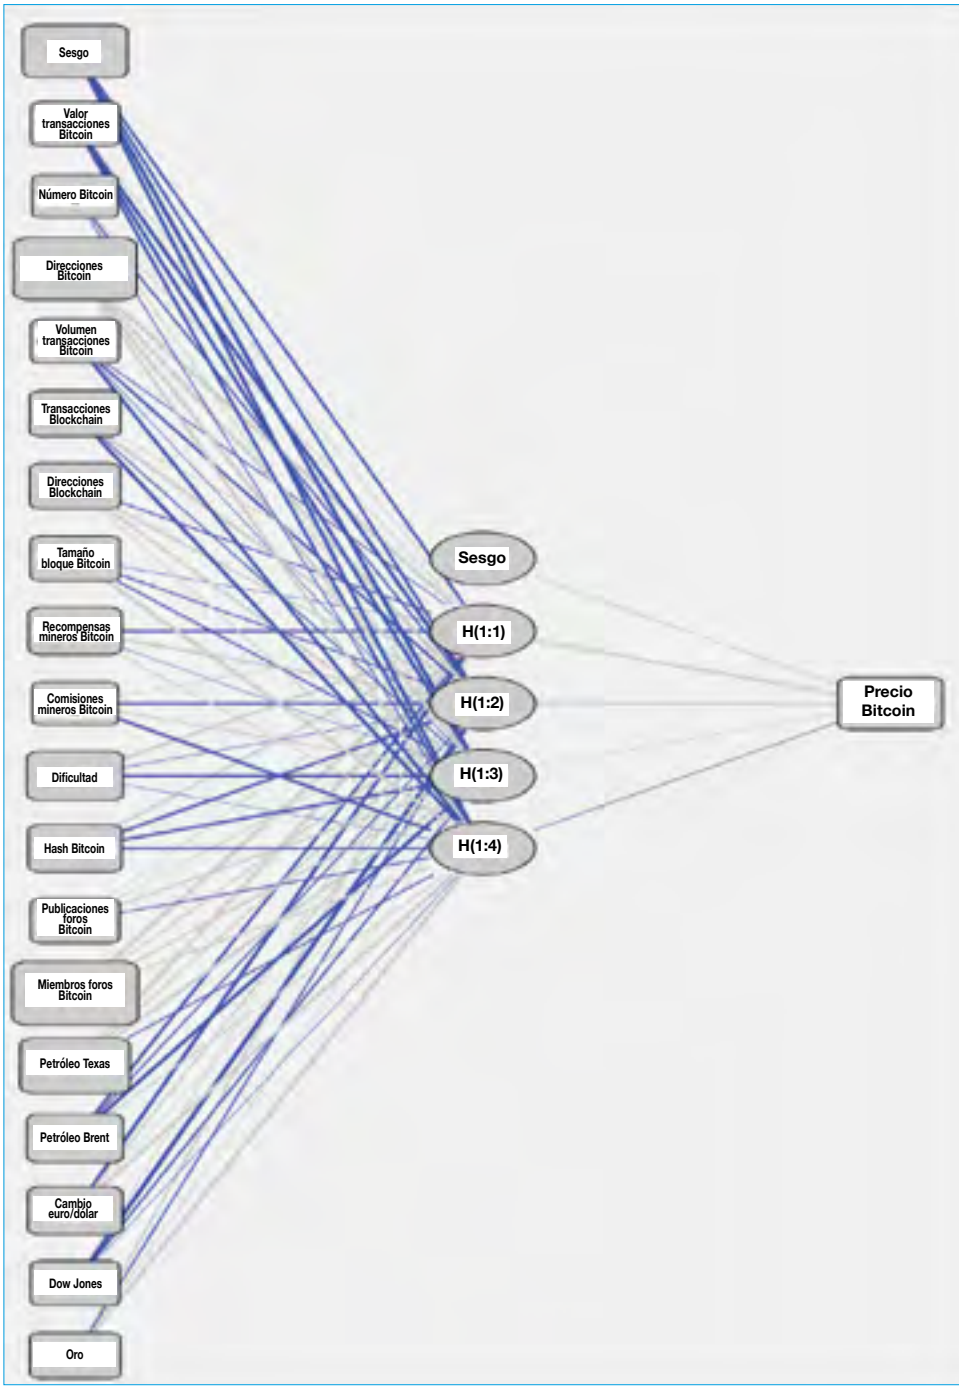
FUENTE: Elaboración propia.

CUADRO 3
ARQUITECTURA PMC (ETHEREUM)

Parámetros	Descripción
Número de neuronas en la capa de entrada	18
Número de neuronas en la capa oculta	2
Número de neuronas en la capa de salida	1
Método de cambio de escala de las variables independientes	Tipificado
Función de activación de la capa oculta	Tangente hiperbólica
Función de error	Suma de cuadrados

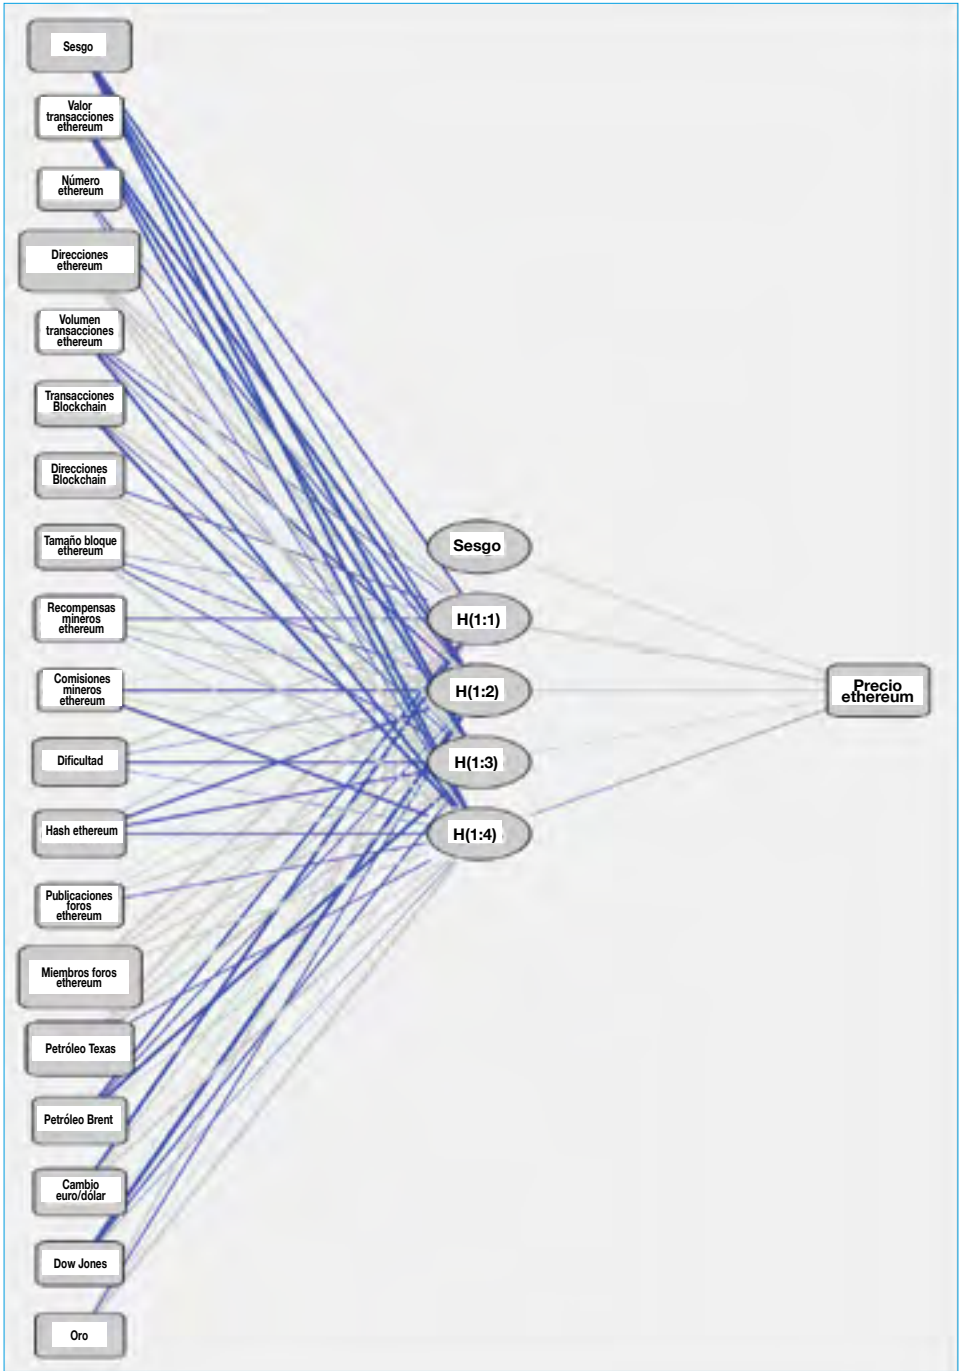
FUENTE: Elaboración propia.

GRÁFICO 1
DISEÑO PMC (BITCOIN)



FUENTE: Elaboración propia.

GRÁFICO 2
DISEÑO PMC (ETHEREUM)



FUENTE: Elaboración propia.

CUADRO 4
RESULTADOS DE LA ESTIMACIÓN (BITCOIN)

Precisión (%)		Error relativo (%)		RMSE	
Entrenamiento	Testeo	Entrenamiento	Testeo	Entrenamiento	Testeo
97,481	94,190	2,519	5,81	0,038	0,055

NOTA: RMSE, raíz cuadrada del error cuadrático medio.

FUENTE: Elaboración propia.

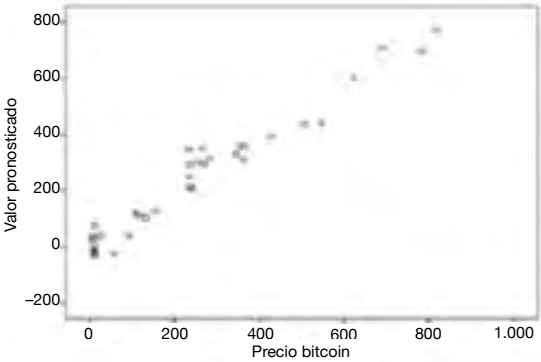
CUADRO 5
RESULTADOS DE LA ESTIMACIÓN (ETHEREUM)

Precisión (%)		Error relativo (%)		RMSE	
Entrenamiento	Testeo	Entrenamiento	Testeo	Entrenamiento	Testeo
96,722	93,081	3,278	6,919	0,041	0,059

NOTA. RMSE: raíz cuadrada del error cuadrático medio.

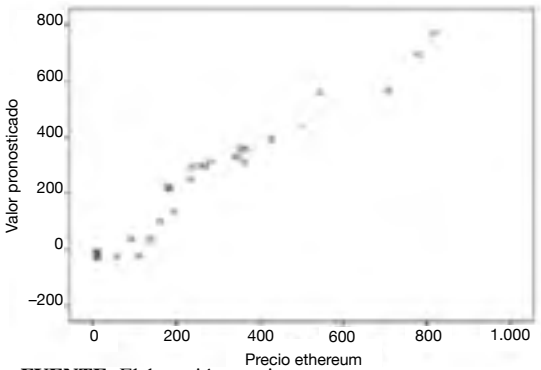
FUENTE: Elaboración propia.

GRÁFICO 3
VALORES PRONOSTICADOS (BITCOIN)



FUENTE: Elaboración propia.

GRÁFICO 4
VALORES PRONOSTICADOS (ETHEREUM)



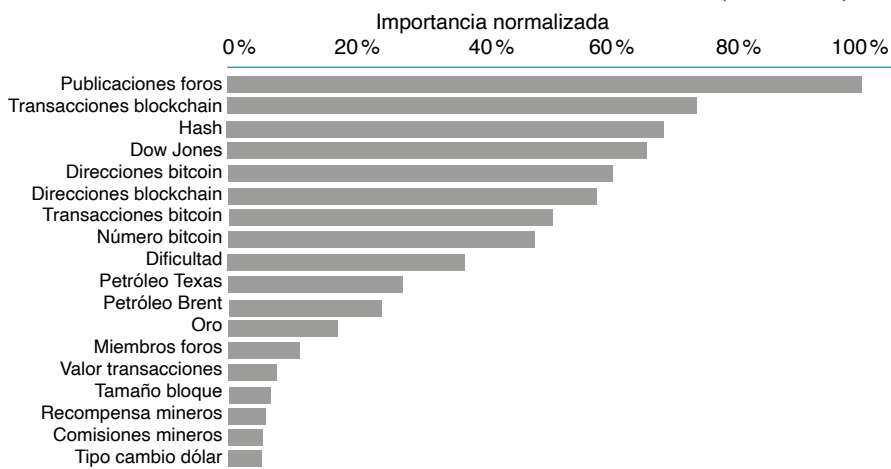
FUENTE: Elaboración propia.

Análisis de sensibilidad

Por su parte, los Gráficos 5 y 6 muestran la sensibilidad de las variables utilizadas en el estudio. En el modelo de *bitcoin*, las variables «Publicaciones foros», «Transacciones blockchain», «Hash», «Dow Jones» y «Direcciones bitcoin» aparecen con los valores de sensibilidad más altos, pues sus coeficientes de sensibilidad superan en todos los casos el 60%. Por su parte, en el modelo de *ethereum*, las variables con mayor sensibilidad son «Transacciones ethereum», «Tamaño bloque», «Petróleo Brent», «Transacciones blockchain» y «Comisiones mineros».

Estos resultados indican que la incorporación de nuevos participantes en los foros relacionados con el *bitcoin* explica en gran medida los niveles del precio de la moneda en el periodo muestral. Además, que los aspectos tecnológicos relacionados con el volumen de operaciones de *blockchain*, la función hash y el número de direcciones, y los aspectos macroeconómicos en relación con la capitalización bursátil son otras variables importantes para explicar las variaciones de precio del *bitcoin*. En el caso del *ethereum*, el aspecto tecnológico relacionado con el volumen de transacciones es la variable que incide de manera especial en su precio. También se confirma la importancia de los aspectos relacionados con la tecnología, dada la alta sensibilidad mostradas por las variables que se refiere al tamaño de los bloques y al volumen de transacciones de *blockchain*. En este modelo de *ethereum*, igualmente aparece con especial significación las condiciones macroeconómicas en relación al precio del petróleo. Sin embargo, y a diferencia del *bitcoin*, el atractivo en redes sociales no muestra una especial importancia en esta criptomoneda.

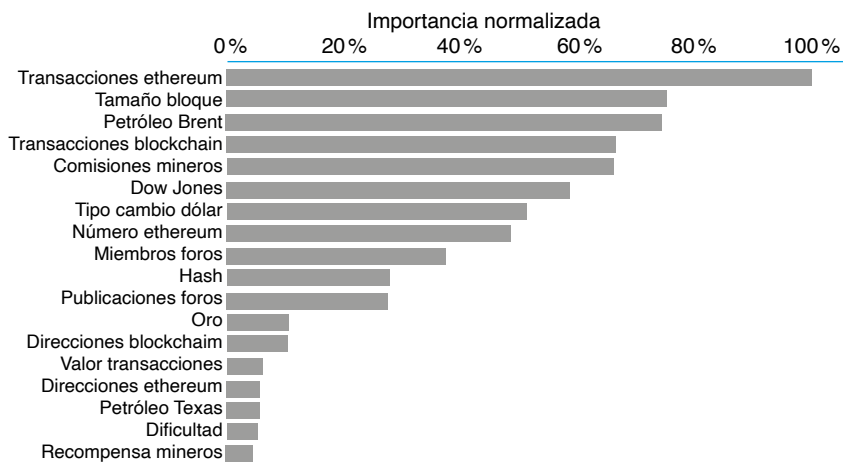
GRÁFICO 5
IMPORTANCIA DE LAS VARIABLES INDEPENDIENTES (BITCOIN)



FUENTE: Elaboración propia.

GRÁFICO 6

IMPORTANCIA DE LAS VARIABLES INDEPENDIENTES (ETHEREUM)



FUENTE: Elaboración propia.

Estos resultados pueden ser muy interesantes porque confirman los principales enfoques teóricos que intentan explicar el valor del *bitcoin* y del *ethereum*. Así, los postulados de la economía de redes quedan plenamente justificados al ser las publicaciones en foros sobre el *bitcoin* la variable con mayor importancia normalizada del modelo. También porque el enfoque basado en la teoría cuantitativa del dinero queda parcialmente validado por el hecho de que la segunda variable por importancia normalizada para *bitcoin* y la primera para *ethereum* sea el volumen de transacciones.

Discusión

En el presente estudio se han desarrollado modelos PMC, lo que ha permitido cuantificar la importancia de un conjunto de variables para explicar el comportamiento del precio de las principales criptomonedas. Los resultados obtenidos indican que el aspecto de mayor sensibilidad para el *bitcoin* es el relacionado con el atractivo que la moneda presenta en las redes sociales. Así, el número de publicaciones en foros de *bitcoin* ha presentado la mayor sensibilidad. Este resultado está en la línea de los obtenidos en los estudios de Kristoufek (2015) y Nasir *et al.* (2019), para los que el interés del público en aumentar el conocimiento sobre el *bitcoin* muestra una relación directa con los precios. Sin embargo, nuestros resultados difieren de los obtenidos por Ciaian *et al.* (2016a) y Hayes (2017), para los que el factor de atractivo parece que ha perdido relevancia. Quizá, el más reciente periodo muestral

utilizado en nuestro estudio pueda recoger la significación actual del factor atractivo, confirmando la importancia de la economía de redes en la justificación del valor del *bitcoin*. Por otro lado, determinadas variables relacionadas con la demanda y oferta de *bitcoin* también han mostrado gran sensibilidad en nuestros resultados. Así, el volumen de transacciones en *blockchain* y la tasa de hash han alcanzado sensibilidades superiores al 65%. Estos resultados son conformes a los obtenidos por Buchholz *et al.* (2012), en referencia a que el volumen de transacciones diarias por los usuarios de la red también ha demostrado tener un impacto directo en los precios, y a los de Matonis (2012) respecto a la importancia de la tasa de hash. Pero nuestros resultados son distintos a los de Bouoiyour y Selmi (2015), para los que el volumen del mercado afecta sólo al precio del *bitcoin* a corto plazo, y de los obtenidos por Balcilar *et al.* (2017) cuando indican que el tamaño del mercado no tiene efectos significativos en periodos de estrés de la moneda. Así mismo, también hemos podido detectar una relativa importancia de variables macroeconómicas y financieras, sobre todo en relación con el índice bursátil Dow Jones. Otros autores también han resaltado la significatividad de los índices bursátiles (Bouoiyour y Selmi, 2015; Van Wijk, 2013).

Finalmente, otro conjunto de variables relacionadas con el *bitcoin* ha presentado una escasa significatividad en nuestro estudio. Tal es el caso de las recompensas y comisiones a mineros, tamaño del bloque, velocidad y tipo de cambio euro/dólar. Estas variables si han resultado importantes en estudios previos. Por ejemplo, Matonis (2012) señalaba que las comisiones percibidas por los mineros representaban variables con impacto en el precio del *bitcoin*. Nuestros resultados, por el contrario, no han captado esta importancia quizá porque el amplio conjunto de variables explicativas utilizado en el presente estudio han proporcionado una combinación inédita de variables para explicar el valor del *bitcoin* en el mercado.

En referencia al *ethereum*, nuestros resultados han confirmado que el volumen de transacciones es la variable de mayor sensibilidad. Estos resultados coinciden con los obtenidos por Pierro y Rocha (2019) y Poyser (2017), que también han señalado al número de transacciones de *ethereum* entre las variables más significativas. No obstante, nuestros resultados son diferentes a los de la literatura previa, sobre todo en relación con la significatividad del atractivo en redes sociales como variable explicativa del precio del *ethereum*. Por ejemplo, Sovbetov (2018) y Poyser (2017) confirmaron la importancia del citado atractivo, pero en nuestro modelo las variables relacionadas con el número de miembros y publicaciones en foros de *ethereum* presentan una sensibilidad inferior al 40%. Finalmente, nuestros resultados sobre *ethereum* también difieren de los obtenidos en estudios previos al confirmar que las variables «Tamaño bloque» y «Petróleo Brent» han presentado una especial sensibilidad (superior al 70%). Sin embargo, el importante impacto de estas variables no ha sido detectado anteriormente (Pierro y Rocha, 2019).

6. Conclusiones e implicaciones

Los resultados del presente estudio han puesto de manifiesto un set único de variables que impactan de manera significativa en los precios de las principales criptomonedas. Para el *bitcoin*, las variables de mayor sensibilidad están relacionadas con el número de publicaciones en foros, el volumen de transacciones en *blockchain* y la tasa de hash. Además, que otro conjunto de variables también han mostrado una alta sensibilidad a los precios del *bitcoin*. Es el caso del índice bursátil Dow Jones, el número de transacciones diarias y el número de direcciones de *bitcoin* y de *blockchain*. Este conjunto de variables representa un conjunto único de predictores del precio del *bitcoin* que consigue una precisión superior al 94 %.

Para la moneda *ethereum*, las variables más sensibles están relacionadas con el volumen de transacciones, tamaño de los bloques, comisiones de mineros y precios del petróleo Brent. Además, con el conjunto de variables propuesto en el presente estudio, el modelo MLP construido proporciona un nivel de precisión superior al 93 % en la explicación de los precios del *ethereum*.

Nuestro estudio presenta varias contribuciones a la literatura sobre criptomoneda. En primer lugar, y desde una perspectiva teórica, determina las variables de mayor impacto en la formación de los precios de mercado del *bitcoin* y del *ethereum*. Investigaciones anteriores han demostrado que variables relacionadas con la demanda y oferta, con el atractivo y con factores macroeconómicos también han impactado en el precio de las criptomonedas. Sin embargo, este es el primer estudio que incorpora un amplio conjunto de variables y consigue mejorar los resultados de precisión obtenidos en la literatura previa. Estas conclusiones abren nuevas perspectivas de investigación sobre evidencias que pueden ser consideradas en los modelos de valoración de las criptomonedas, especialmente aquellos basados en la teoría cuantitativa del dinero y en la economía de redes.

El presente estudio también presenta importantes implicaciones prácticas para la gestión de carteras. El conjunto de variables de mayor impacto identificado permite adaptar los planes de inversión en función del comportamiento de determinados factores de mercado. También reducir el tiempo de análisis y el riesgo de las operaciones relacionadas con criptomonedas al proporcionar una guía precisa de los aspectos de valoración del *bitcoin* y del *ethereum*. La sensibilidad específica de estas criptomonedas a determinados factores es, pues, una variable clave para su utilización como activos en carteras diversificadas.

Finalmente, los resultados del presente estudio nos sugieren futuras investigaciones. Dado que los modelos de valoración existentes han permitido explicar sólo una parte del comportamiento de los precios de las criptomonedas, futuros estudios podrían comprobar qué otros cuerpos teóricos conseguirían una mayor capacidad predictiva incorporando nuevas variables no exploradas en la actualidad. También, y dado los excelentes resultados conseguidos con PMC para la estimación de los precios del *bitcoin* y del *ethereum*, otros trabajos podrían investigar si otras técnicas de inteligencia artificial serían adecuadas para predecir el comportamiento de las criptomonedas, entre ellas, *ripple*, *tether*, *dash* y *monero*.

Referencias bibliográficas

- Alaminos, D., Becerra-Vicario, R., Fernández-Gámez, M. A., & Cisneros-Ruiz, A. J. (2019). Currency Crises Prediction using Deep Neural Decision Trees. *Applied Sciences*, 9(23), 5227.
- Alessandretti, L., ElBahrawy, A., Aiello, L. M., & Baronchelli, A. (2018). Anticipating Cryptocurrency Prices Using Machine Learning. *Complexity*, ID 8983590, 1-16. <https://doi.org/10.1155/2018/8983590>
- Al-Khazali, O., Bouri, E., & Roubaud, D. (2018). The impact of positive and negative macroeconomic news surprises: gold versus Bitcoin. *Economics Bulletin*, 38(1), 373-382.
- Balcilar, M., Bouri, E., Gupta, R., & Roubaud, D. (2017). Can volume predict bitcoin returns and volatility? A quantiles-based approach. *Economic Modelling*, 64, 74-81.
- Bouoiyour, J., & Selmi, R. (2015). What does bitcoin look like? *Annals of Economics and Finance*, 16(2), 449-492.
- Bouri, E., Jalkh, N., Molnár, P., & Roubaud, D. (2017). Bitcoin for energy commodities before and after the December 2013 crash: diversifier, hedge or safe haven? *Applied Economics*, 49(50), 5063-5073.
- Buchholz, M., Delaney, J., Warren J., & Parker, J. (2012). Bits and Bets, Information, Price Volatility, and Demand for BitCoin. *Economics*, 312, 2-48. <https://www.reed.edu/economics/parker/s12/312/finalproj/Bitcoin.pdf>
- Chao, X., Kou, G., Peng, Y., & Alsaadi, F. E. (2019). Behavior monitoring methods for trade-based money laundering integrating macro and micro prudential regulation: a case from China. *Technological and Economic Development of Economy*, 25(6), 1081-1096.
- Chen, W., Zheng, Z., Ma, M., Wu, J., Zhou, Y., & Yao, J. (2020). Dependence structure between bitcoin price and its influence factors. *International Journal of Computational Science and Engineering*, 21(3), 334-335. <https://doi.org/10.1504/IJCSE.2020.106058>
- Ciaian, P., Miroslava, R., & Kancs, D. (2016a). Can bitcoin become a global currency? *Information Systems and e-Business Management*, 14(4), 883-919.
- Ciaian, P., Miroslava, R., & Kancs, D. (2016b). The economics of bitcoin price formation. *Applied Economics*, 48(19), 1799-1815.
- Civitarese, J. (2018). *Does metcalfe's law explain bitcoin prices? A time series analysis*. <https://ssrn.com/abstract=3107895>
- Conley, J. P. (2017). *Blockchain and the Economics of Crypto-tokens and Initial Coin Offerings* (No. 17-00008). Vanderbilt University Department of Economics.
- Davies, D. C. (2014). *The curious case of bitcoin: is bitcoin volatility driven by online search?* University of Victoria.
- Dyhrberg, A. H. (2016). Hedging capabilities of bitcoin. Is it the virtual gold? *Finance Research Letters*, 16, 139-144.
- Ethereum Foundation (2018). *Solidity documentation. Release 0.4.24*. https://solidity.readthedocs.io/_/downloads/en/v0.4.24/pdf/
- Faris, H., Aljarah, I., Al-Madi, N., & Mirjalili, S. (2016). Optimizing the learning process of feedforward neural networks using lightning search algorithm. *International Journal on Artificial Intelligence Tools*, 25, 1650033.
- Grinberg, R. (2012). Bitcoin: An innovative alternative digital currency. *Hastings Science & Technology Law Journal*, 4(1), 159-208.

- Gupta, S., & Wang, L. P. (2010). Stock Forecasting with Feedforward Neural Networks and Gradual Data Sub-Sampling. *Australian Journal of Intelligent Information Processing Systems*, 11(4), 14-17.
- Hayes, A. (2017). *Cryptocurrency value formation: an empirical analysis leading to a cost of production model for valuing bitcoin*. Telematics Information. <https://ssrn.com/abstract=2648366>
- Hecht-Nielsen, R. (1990). *Neurocomputing*. Addison Wesley.
- Heidari, A. A., Faris, H., Aljarah, I., & Mirjalili, S. (2019). An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*, 23(17), 7941-7958.
- Kristoufek, L. (2015). What Are the Main Drivers of the Bitcoin Price? Evidence from Wavelet Coherence Analysis. *PLoS ONE*, 10(4), e0123923.
- Lamothe-Fernández, Alaminos, D., Lamothe-López, P., & Fernández-Gámez, M. A. (2020). Deep Learning Methods for Modeling Bitcoin Price. *Mathematics*, 8(8), 1245.
- Liu, W., Liang, X., & Cui, G. (2020). Common risk factors in the returns on cryptocurrencies. *Economic Modelling*, 86, 299-305.
- Lucas, L. (1980). Two Illustrations of the Quantity Theory of Money. *The American Economic Review*, 70(5), 1005-1014.
- Matonis, J. (2012). *Top 10 BitCoin Statistics*. Forbes. <https://www.forbes.com/sites/jonmatonis/2012/07/31/top-10-bitcoin-statistics>
- Nasir, M., Huynh, D., Nguyen, P., & Duong, D. (2019). Forecasting cryptocurrency returns and volume using search engines. *Financial Innovation*, 5(1), 2.
- Núñez de Castro, L., & Von Zuben, F. J. (1998). *Optimised Training Techniques for Feedforward Neural Networks*. Technical Report DCA-RT 03/98. Department of Computer Engineering and Industrial Automation. FEE/UNICAMP, Brasil.
- Pierro, G. A., & Rocha, H. (2019). The Influence Factors on Ethereum Transaction Fees. En *2019 IEEE/ACM 2nd International Workshop on Emerging Trends in Software Engineering for Blockchain (WETSEB)*, Montreal (pp. 24-31).
- Polasik, M., Piotrowska, A. I., Wisniewski, T. P., Kotkowski, R., & Lightfoot, G. (2015). Price fluctuations and the use of Bitcoin: an empirical inquiry. *International Journal of Electronic Commerce*, 20(1), 9-49.
- Poyser, O. (2017). *Exploring the determinants of Bitcoin's price: an application of Bayesian Structural Time Series*. Dissertation.
- Sin, E., & Wang, L. (2017). Bitcoin Price Prediction Using Ensembles of Neural Networks. En *2017, 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge*, Guilin (pp.666-671). https://www.ntu.edu.sg/home/elpwang/PDF_web/08393351.pdf
- Sobol, I. M. (1993). Sensitivity estimates for nonlinear mathematical models. *Mathematical Modelling and Computational Experiment*, 1(4), 407-414.
- Sovbetov, Y. (2018). Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litecoin, and Monero. *Journal of Economics and Financial Analysis*, 2(2), 1-27.
- Van Wijk, D. (2013). *What can be expected from the BitCoin?* (No. 345986). Erasmus Rotterdam Universiteit.
- Zhu, Y., Dickinson, D., & Li, J. (2017). Analysis on the influence factors of Bitcoin's price based on VEC model. *Financial Innovation*, 3(1), 3.