

El mercado de criptomonedas. Un análisis de red

Carlos Jaureguizar Francés *

Pilar Grau-Carles

Universidad Rey Juan Carlos

Diego Jaureguizar Arellano

Universidad Pontificia de Comillas

Resumen

En este trabajo se estudian las características de las series de precios diarios de 16 diferentes criptomonedas entre julio de 2017 y febrero de 2018. Las metodologías utilizadas para el análisis son el llamado *Minimum Spanning Tree* (MST) y el análisis jerárquico a través del dendograma, obtenidos ambos a partir de las correlaciones de Pearson entre los rendimientos diarios. Esta metodología permite visualizar las relaciones de mercado entre los activos analizados identificando una alta correlación entre los movimientos de los precios de todas las monedas. Además, se ha podido identificar la posición de Ethereum como moneda de referencia en el mercado de criptomonedas, en lugar de Bitcoin, como cabría esperar por su popularidad y volumen de cotización.

Palabras clave: criptomoneda; Minimum Spanning Tree; correlaciones; clúster; topología.

Códigos JEL: G12, G41.

* Autor de correspondencia. e-mail: c.jaureguizar@alumnos.urjc.es

1. Introducción

Los mercados de *criptomonedas* están siendo objeto de creciente interés tanto por los medios como por los inversores y reguladores. Algunas de las características que se les atribuyen son su simplicidad, transparencia y variedad de usos potenciales, que van desde medio de pago, hasta la posibilidad de ser utilizadas para el desarrollo de aplicaciones. Katsiampa *et al.* (2018) definen la criptodivisa como “un activo digital diseñado para ser utilizado como medio de cambio utilizando criptografía para asegurar las transacciones sin estar sujeto a ninguna intervención gubernamental”. Aunque el Bitcoin es la moneda con mayor nivel de capitalización (un 56% en 2018), existen más de 1.900 criptomonedas según puede consultarse en el sitio web coinmarketcap.com. De ellas, más de 300 superan los 10 millones de dólares de capitalización, 66 los 100 millones y 16 los 1.000 millones de dólares.

A pesar del creciente interés por estos activos financieros, la información académica es insuficiente y en su mayoría está centrada en el análisis de la criptomoneda más popular y más antigua, el Bitcoin, que es de la que existen series temporales más largas de precio y volumen de transacciones.

Este es el caso de algunos de los recientes estudios centrados en el análisis de la volatilidad. Baek *et al.* (2015) analizan la volatilidad relativa entre el Bitcoin y el índice SP500. Katsiampa (2017) y Chu *et al.* (2017) intentan estudiar la volatilidad del Bitcoin utilizando modelos GARCH. Por otra parte, Urquhart (2017) estudia el agrupamiento de precios (*Price clustering*) de Bitcoin. Algunos otros estudios buscan relaciones entre algunas criptomonedas, Huynh (2017) utiliza modelos con GARCH-Cópula entre tres monedas, y Bouoiyour y Selmi (2017) buscan explicar si existe asociación entre Ether y Bitcoin mediante modelos GARCH-Cópula. Osterrieder *et al.* (2017) examinan la relación entre algunas criptodivisas mediante diversos modelos entre los que también se incluyen los GARCH-Cópula. Por otro lado, Phillip *et al.* (2017) estudian la volatilidad de las series de rendimientos de precios de diversas criptomonedas y Gkillas *et al.* (2018) y Feng *et al.* (2018) utilizan la teoría de valores extremos para modelizar los comportamientos de dichas series. Asimismo, Balcilar *et al.* (2017) y Katsiampa *et al.* (2018) examinan la relación entre volumen y rendimientos, para Bitcoin y para una muestra mayor de monedas, respectivamente.

El presente trabajo tiene como objetivo analizar el mercado de las criptomonedas y sus dependencias utilizando dos técnicas diferentes. La primera consiste en la creación del MST (Minimum Spanning Tree), que es una gráfica cuyos elementos o nodos serán las criptodivisas y cuyos enlaces se construyen a partir de la matriz de correlaciones de Pearson, siguiendo la técnica propuesta por Mantegna (1999). Esta técnica ha proporcionado resultados sólidos en el estudio de mercados financieros, permitiendo clasificaciones jerarquizadas y significativas de los activos en clústeres [véase Bonano *et al.* (2000), McDonald *et al.* (2005), Naylor *et al.* (2007), Kwapien *et al.* (2009), Aste *et al.* (2010), Song *et al.* (2011), Vizgunov *et al.* (2014) y Wang *et al.* (2018), entre otros]. Además, esta metodología es robusta a la hora de solucionar el problema empírico del ruido en una matriz de correlación histórica

como demuestra Onnela *et al.* (2003) en su análisis. Asimismo, este tipo de análisis implica la construcción de una red en la cual unos nodos interaccionan y afectan a los otros, por lo que esta técnica permite analizar el grado de movimientos entre las criptodivisas e identificar aquellas monedas que ejercen una mayor influencia en las fluctuaciones en los precios y en mercado en su conjunto.

La segunda técnica consiste en el análisis de la estructura jerárquica de la red mediante la elaboración de un dendograma, agrupando las monedas en clústeres según su comportamiento en el mercado.

El trabajo es novedoso porque propone una red completa de conexiones basadas en correlaciones para el mercado de criptodivisas. Cabe destacar que el análisis de las correlaciones no es infrecuente en finanzas. De hecho, su uso es generalizado en los modelos de selección de carteras, en los de gestión del riesgo. Así, el análisis de correlación ha desempeñado un papel importante en el establecimiento de la relación entre los beneficios de diversificación y la volatilidad del mercado. Por ello, el conocimiento de las correlaciones en un mercado financiero y en las criptomonedas en particular puede ayudar a los inversores a entender los mecanismos de formación de precios y además servirles de guía en diversificación de sus carteras.

Este trabajo se estructura de la siguiente forma: en el siguiente apartado se describen los datos utilizados. El punto 3 describe la metodología para la construcción del MST. En el apartado 4 se exponen los principales resultados obtenidos y el trabajo finaliza resumiendo las principales conclusiones obtenidas.

2. Material y metodología

Del total de las más de 1.500 criptomonedas que aparecen referenciadas en la principal fuente de datos de precios de las mismas, la web www.coinmarketcap.com, que a su vez recoge los datos de los distintos mercados (en septiembre de 2018 son 400 los mercados o *exchanges* donde se cotiza Bitcoin frente a, por ejemplo, tan solo 5 en una moneda de baja capitalización como el ZClassic), se han seleccionado las 16 cuyo volumen total resulta representativo. En la fecha de comienzo de este estudio, octubre de 2017, se eligieron las 16 de mayor volumen en ese momento, aunque algunas de ellas hayan variado en el ranking con posterioridad.

Debemos mencionar que para poder incluir en el estudio criptomonedas que en 2018 eran relevantes por su capitalización bursátil, se eligió como fecha para el comienzo del estudio julio de 2017. Concretamente, como puede observarse en coinmarketcap.com, de donde se han extraído los datos, EOS cotiza desde el 1 de julio y Bitcoin Cash, una de las criptomonedas más grandes, desde el 23 de julio de 2017. Se eligió febrero de 2018 para finalizarlo para incluir tanto el mercado, fuertemente alcista, del segundo semestre de 2017, como la gran crisis de finales de año y principios de 2018.

La tabla 1 muestra las criptomonedas seleccionadas para el estudio, junto a su codificación y el volumen de las mismas a fecha 23 de julio de 2017 medido en dólares.

Tabla 1. Criptomonedas seleccionadas para el estudio y su volumen en fecha 23 de julio de 2017 medido en dólares

NOMBRE	CÓDIGO	VOLUMEN
Bitcoin	BTC	1.072.840.000
Ethereum	ETH	649.614.976
Ripple	XRP	195.682.000
Dash	DASH	31.110.400
Neo	NEO	29.915.100
Lisk	LSK	4.576.990
Stellar	XLM	10.264.600
Eos	EOS	60.205.000
Litecoin	LTC	219.256.992
Nem	XEM	5.915.450
Monero	XMR	8.634.060
Ethereum-classic	ETC	76.647.400
Bitcoin-cash	BCH	85.013
OmiseGO	OMG	15.198.100
Iota	IOTA	3.065.860
Bitconnect	BCC	2.132.900

Fuente: Coinmarketcaps.

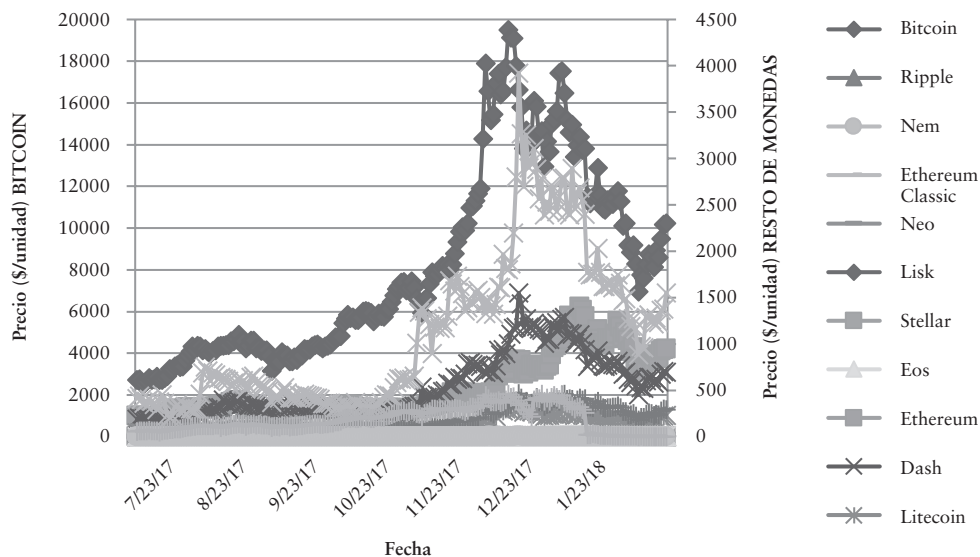
Para el estudio se han tomado precios diarios de cierre de cotización desde el 23 de julio de 2017 hasta 16 de febrero de 2018, lo que implica un total de 209 observaciones para cada una de las criptomonedas.

La figura 1 muestra la evolución de los precios de las monedas seleccionadas durante todo el período. Como puede observarse, es la moneda Bitcoin, seguida de Bitcoin Cash, la que alcanza precios más altos.

Para el estudio de las correlaciones, se ha calculado la tasa de retorno diario de cada una de las monedas definido como $r_i(t) = \ln P_i(t) - \ln P_i(t-1)$ donde $P_i(t)$ y $P_i(t-1)$ son los precios de las criptomonedas en t y $t-1$, respectivamente.

La tabla 2 muestra el resumen estadístico de los retornos para cada una de las monedas. Según puede observarse en dicha tabla, la media de los rendimientos diarios es negativa, menos en el caso de BBC, y muy reducida, situándose para el caso de las pérdidas entre el $-0,38\%$ y el $-1,46\%$. De nuevo, exceptuando el caso de BCC, que presenta un rendimiento máximo diario del $258,6\%$, el rendimiento máximo obtenido por las demás monedas se sitúa entre el 20% y el $44,6\%$, mientras que las pérdidas, en este caso para el total de las monedas, pueden situarse entre el $22,5\%$ y el $99,6\%$, siempre con valores negativos. La dispersión de signos en los coeficientes de asimetría relativamente elevados muestra que las distribuciones no son simétricas, pero tanto hacia la derecha como hacia la izquierda. Finalmente la curtosis de las distribuciones de rendimientos diarios difiere entre las monedas estudiadas.

Figura 1. Evolución del precio diario de las criptomonedas entre 23/7/2017 y 16/2/2018




Fuente: Coinmarketcaps y elaboración propia.

Tabla 2. Resumen estadístico de los rendimientos de las criptomonedas ($n=209$)

	Media	Máximo	Mínimo	Desv. est.	Coef. Asimetría	Curtosis
BTC	-0.0064	0.2075	-0.2251	0.0599	0.1698	1.7324
ETH	-0.0069	0.2589	-0.2347	0.0641	0.3826	2.7059
XRP	-0.0085	0.3533	-0.6069	0.1014	-1.6264	9.5210
DASH	-0.0062	0.2432	-0.4377	0.0795	-0.7807	5.4611
LTC	-0.0079	0.3952	-0.3893	0.0854	-0.5673	5.4396
XEM	-0.0059	0.3615	-0.9956	0.1163	-2.9326	26.0569
XMR	-0.0093	0.2932	-0.3524	0.0861	-0.2041	2.1900
ETC	-0.0038	0.4353	-0.2923	0.0929	0.6827	4.6021
NEO	-0.0130	0.3285	-0.5089	0.1095	-0.7106	2.9434
LSK	-0.0131	0.4100	-0.3492	0.1019	0.0252	1.8135
XLM	-0.0146	0.3283	-0.6668	0.1225	-0.9675	4.3752
EOS	-0.0081	0.3850	-0.3473	0.1042	-0.1848	2.0175
BCH	-0.0064	0.4460	-0.4316	0.1212	-0.4931	2.7220
OMG	-0.0119	0.2846	-0.5416	0.1091	-0.6080	3.1269
IOTA	-0.0099	0.3770	-0.3840	0.1054	-0.2215	1.9610
BCC	0.0129	2.5864	-0.5925	0.2175	8.1337	96.0289

Un resumen visual de lo expuesto anteriormente aparece en la figura 2, que muestra utilizando un diagrama de cajas que la mediana de los datos para todas las monedas se sitúa cercana a 0. Pero quizá lo que más destaca es la cantidad de valores extremos que aparecen en todas las monedas, tanto positivos como negativos, reflejando por tanto posibilidad de obtención de ganancias o pérdidas extremas.

Figura 2. Diagrama de cajas de los rendimientos de las criptomonedas



3. Metodología de análisis

El primer paso para construir el Minimum Spanning Tree (MST) consiste en calcular la matriz de correlaciones entre los rendimientos diarios de todas las criptomonedas estudiadas, obteniendo los coeficientes de las correlaciones de Pearson entre cada dos monedas i y j definidos como:

$$C_{ij} = \frac{n(\sum r_i r_j) - (\sum r_i)(\sum r_j)}{\sqrt{[n\sum r_i^2 - (\sum r_i)^2] [n\sum r_j^2 - (\sum r_j)^2]}}$$

Se obtiene una matriz de correlaciones

$$C = \begin{bmatrix} C_{11} & \dots & C_{1N} \\ \vdots & \ddots & \vdots \\ C_{N1} & \dots & C_{NN} \end{bmatrix}$$

Donde C_{ij} toma valores entre -1 y 1 , y N es el número de monedas bajo estudio, que en nuestro caso es 16. Según Mantegna (1999), se pueden convertir los elementos de la matriz de correlación C_{ij} , transformándolos en distancias y obteniendo una matriz de distancias según

$$d_{ij} = \sqrt{2(1 - C_{ij})}$$

de modo que el valor de d_{ij} puede variar de 0 a 2, por lo que si la distancia es corta, la correlación es grande, y viceversa.

Para construir el MTS se unen N nodos, que en nuestro caso son las monedas a estudio con $N - 1$ enlaces, de modo que la suma de todas las distancias de los enlaces sea mínima, lo que en la práctica significa que mediante los $N - 1$ enlaces se extraerá la información más relevante de la matriz de correlación. Seguimos a Mantegna (1999) y Mantegna y Stanley (2000) para la elaboración del MST que proponen la utilización del algoritmo de Kruskal (1956), el cual puede resumirse en los siguientes pasos.

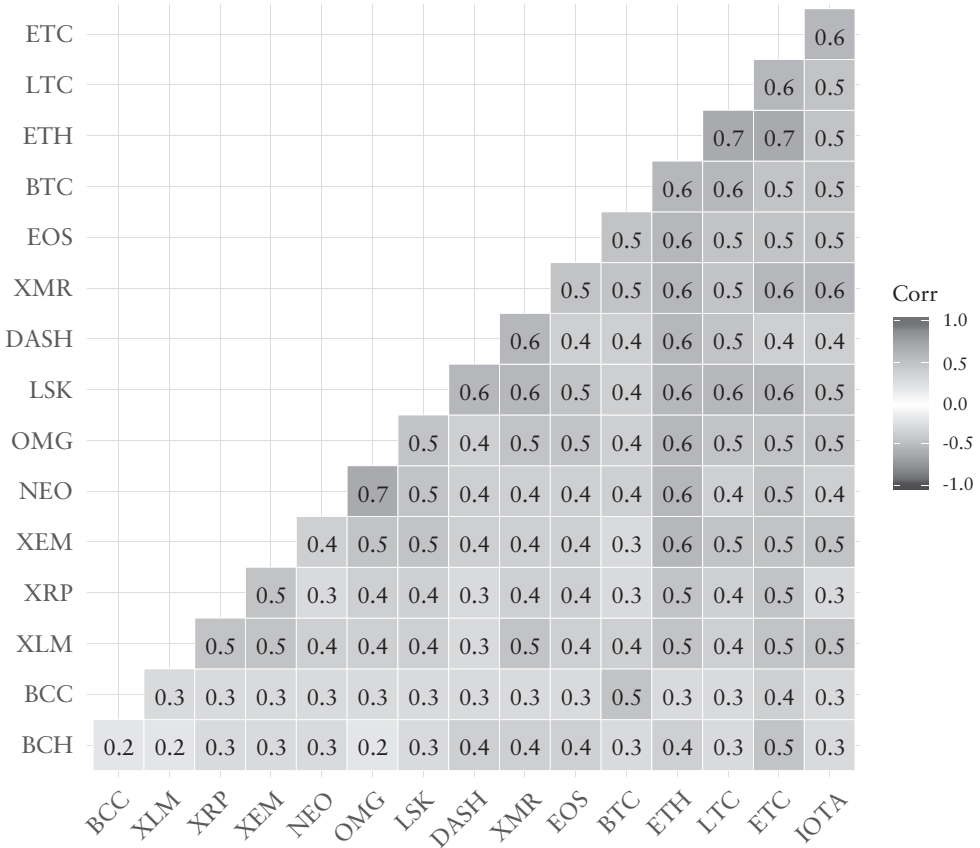
- (i) Tomamos $N(N - 1)/2$ elementos de la matriz de distancias en orden creciente.
- (ii) Seleccionamos el par de criptomonedas con la menor distancia y añadimos el enlace en el gráfico.
- (iii) Seleccionamos el siguiente par de criptomonedas con menor distancia y añadimos el siguiente enlace.
- (iv) Repetimos (iii) hasta que todas las monedas están unidas en el gráfico.

4. Resultados

4.1. Correlaciones entre criptomonedas

Antes de mostrar el MST obtenido mediante el algoritmo explicado anteriormente, se comparan los descriptores estadísticos de los $N(N - 1)/2$ elementos de la matriz de correlaciones obtenida. Dicha matriz aparece representada de forma gráfica en la figura 3. Como puede observarse, todas las correlaciones son positivas oscilando entre un valor máximo de 0,7 y un valor mínimo de 0,1, aunque su valor medio se sitúa en 0,4, lo que implica que hay una correlación moderada entre todos ellos. Además, se ha contrastado la significatividad de los valores de los coeficientes de correlación.

Figura 3. Matriz coeficientes de correlación de Pearson entre las criptomonedas



4.2. Resultados de la red

En la figura 4 se muestra el MST de las 16 criptomonedas estudiadas. La figura 4a permite visualizar la estructura de red de las criptodivisas, mientras que la figura 4b representa el mismo MST, pero en este caso la longitud del enlace muestra la distancia relativa entre cada dos monedas dependiendo de su correlación, de modo que cuanto más cerca estén dos nodos implicará una mayor correlación entre los mismos.


Se observa que la moneda más central es ETH (Ethereum), teniendo más conexiones que ninguna otra y actuando a su vez como conector del resto de monedas. Es sorprendente que la criptomoneda más popular, BTC (Bitcoin), no aparece como central, y sí lo hace su rival más conocido, ETH (Ethereum). Alrededor del Ethereum, como núcleo, se forman 4 grupos de criptomonedas, mientras que otras están vinculadas de manera dependiente pero aislada. Este modelo, centralizado en

Ethereum, puede explicarse tanto por la evolución de la su cotización (en 2017, con más de un 4.000% de revalorización, Ethereum se convirtió en la segunda criptomoneda de mayor capitalización del mundo) como por la naturaleza de las ICO (Initial Coin Offering), puesto que una gran mayoría no despliega código propio, sino que emplea la plataforma Ethereum, con lo que se crea una vinculación entre esta moneda y una amplia mayoría de criptomonedas que la sitúan en la zona central, a diferencia de lo que ocurre con Bitcoin, que no presenta dicha vinculación ni operativa ni en la red topológica.


Observando la figura 4b se observa que la moneda central se encuentra relativamente cercana, lo que implica alta correlación, a la mayoría de las monedas con las que está directamente conectada, excepto con OMG (OmiseGo) y con XMR (Monero). Esto puede explicarse por la naturaleza específica de estas dos criptomonedas, que las hace distintas al resto. Concretamente, Monero no emplea el protocolo estándar del Blockchain de Bitcoin, sino el protocolo CriptoNote, centrado en una privacidad absoluta, lo cual hace sospechar que presenta un elevado sesgo hacia actividades opacas. Por su parte, OmiseGo pretende actuar no tanto como medio de pago, sino como plataforma de intercambio *online* descentralizado, frente a las plataformas centralizadas actuales, convirtiéndose en una alternativa financiera.

Figura 4. (a) MST obtenido a partir de la matriz de correlaciones de todas las matrices que muestra la relación entre las 16 criptomonedas estudiadas, y figura 4 (b) MST obtenido a partir de la matriz de correlaciones de todas las matrices que muestra la relación entre las 16 criptomonedas estudiadas. Cuanto menor sea la distancia entre dos nodos, mayor es la correlación entre ellos

a)



b)




La clasificación de las monedas en clúster mediante el análisis jerárquico, a través de la representación del dendograma que se muestra en la figura 5. Para su cálculo se ha utilizado el método conocido como “simple” o “vecino más cercano” por ser el que está más relacionado con el cálculo del MST. Este método se basa en formar clúster de forma ascendente (agrupación aglomerativa) combinando aquellos grupos que contienen el par más cercano de elementos que no pertenezcan al mismo clúster. En este tipo de gráfico cuanto mayor es la diferencia en altura, mayor disimilitud. Observando el gráfico puede concluirse que se si se elige una agrupación en 7 clústeres¹, cada uno representado por un color, el grupo 6 contendría 10 monedas dentro de un mismo clúster. Además, la escasa distancia en el eje entre los primeros clústeres indica la existencia de poca heterogeneidad entre los grupos propuestos, sin embargo la distancia entre las monedas más cercanas ETH (Ethereum) y LTC (Litecoin), a las que se les une ETC (Ethereum-classic) evidencian un comportamiento diferencial de este grupo

Destaca que con las dos metodologías utilizadas, MST y dendograma, la criptomoneda más popular no aparece como la más central en el estudio. Esto puede deberse a que el Bitcoin es solo una forma de pago, que en realidad se ha estado intercambiando en gran manera con fines especulativos, mientras que Ethereum constituye, como ya hemos explicado, un proyecto empresarial más amplio.

(1) Se han elegido 7 clústeres para separar el comportamiento de BTC (Bitcoin), la moneda más popular del resto de criptomonedas estudiadas.

Figura 5. Dendograma de las 16 monedas



Conclusiones

En este trabajo se ha mostrado que la utilización de métodos jerárquicos resulta de utilidad para analizar el comportamiento conjunto de las diferentes criptodivisas. En particular, se ha investigado la estructura de la correlación entre 16 criptomonedas diferentes construyendo una red compleja. Utilizando datos diarios de precios entre julio de 2017 y septiembre de 2018 se ha elaborado el MST (Minimum Spanning Tree) que ha permitido situar a la criptomoneda ETH (Ethereum) como central en la red obtenida a partir de las correlaciones, quedando BTC (Bitcoin) en una de las ramas de la red. Por otro lado, el análisis de clúster mediante la construcción del dendrograma reafirma esta conclusión y sitúa a Bitcoin en un clúster diferente al obtenido con otras monedas.

Los resultados obtenidos mediante este análisis constituyen la primera aproximación no realizada con anterioridad al análisis del comportamiento de las criptomonedas mediante el análisis de redes utilizando correlaciones de Pearson. La red obtenida constituye una herramienta útil para comprender las interrelaciones entre los activos financieros que aparecen en la misma. Los resultados obtenidos en el análisis pueden resultar de ayuda para los inversores a la hora de tomar decisiones sobre sus carteras, máxime si se tiene en cuenta que la correlación entre activos financieros es la base de la teoría de optimización de carteras.

Bibliografía

- Aste, T., Shaw, W. y Di Matteo, T., 2010, "Correlation structure and dynamics in volatile markets". *New Journal of Physics*, 12(8), 085009. <https://doi.org/10.1088/1367-2630/12/8/085009>.
- Baek, C. y Elbeck, M., 2015, "Bitcoins as an investment or speculative vehicle? A first look". *Applied Economics Letters*, 22(1), 30-34. <https://doi.org/10.1080/13504851.2014.916379>.
- Balcilar, M., Bouri, E., Gupta, R. y Roubaud, D., 2017, "Can volume predict Bitcoin returns and volatility? A quantiles-based approach". *Economic Modelling*, 64, 74-81. <https://doi.org/10.1016/j.econmod.2017.03.019>.
- Birch, J., Pantelous, A. A. y Soramäki, K., 2016, "Analysis of correlation based networks representing DAX 30 stock price returns". *Computational Economics*, 47(4), 501-525. <https://doi.org/10.1007/s10614-015-9481-z>.
- Bonanno, G., Vandewalle, N. y Mantegna, R. N., 2000, "Taxonomy of stock market indices". *Physical Review E*, 62(6), R7615. <https://doi.org/10.1103/PhysRevE.62.R7615>.
- Bouoiyour, J. y Selmi, R., 2017, "Ether: Bitcoin's competitor or ally?". *arXiv preprint arXiv:1707.07977*.
- Chu, J., Chan, S., Nadarajah, S. y Osterrieder, J., 2017, "GARCH modelling of cryptocurrencies". *Journal of Risk and Financial Management*, 10(4), 17. <https://doi.org/10.3390/jrfm10040017>.
- Feng, W., Wang, Y. y Zhang, Z., 2018, "Can cryptocurrencies be a safe haven: a tail risk perspective analysis". *Applied Economics*, 1-18. <https://doi.org/10.1080/00036846.2018.1466993>.
- Gkillas, K. y Katsiampa, P., 2018, "An application of extreme value theory to cryptocurrencies". *Economics Letters*, 164, 109-111. <https://doi.org/10.1016/j.econlet.2018.01.020>.
- Huynh, T. L. D., Nguyen, S. P. y Duong, D., 2018, January, "Contagion Risk Measured by Return Among Cryptocurrencies". In *International Econometric Conference of Vietnam* (pp. 987-998). Springer, Cham.
- Kwapieni, J., Gworek, S., Drozd, S. y Gorski, A., 2009, "Analysis of a network structure of the foreign currency exchange market". *Journal of Economic Interaction and Coordination*, 4(1), 55-72. <https://doi.org/10.1007/s11403-009-0047-9>.
- Katsiampa, P., 2017, "Volatility estimation for Bitcoin: A comparison of GARCH models". *Economics Letters*, 158, 3-6. <https://doi.org/10.1016/j.econlet.2017.06.023>.
- Katsiampa, P., Gkillas, K. y Longin, F., 2018, May 01, "Cryptocurrency Market Activity During Extremely Volatile Periods". Available at SSRN: <https://ssrn.com/abstract=3220781> or <http://dx.doi.org/10.2139/ssrn.3220781>.
- Kruskal, J. B., 1956, "On the shortest spanning subtree of a graph and the traveling salesman problem". *Proceedings of the American Mathematical Society*, 7(1), 48-50. <https://doi.org/10.1090/S0002-9939-1956-0078686-7>.

- Mantegna, R. N., 1999, "Hierarchical structure in financial markets". *The European Physical Journal B-Condensed Matter and Complex Systems*, 11(1), 193-197. <https://doi.org/10.1007/s100510050929>.
- Mantegna, R. N. y Stanley, H. E., 1999, *Introduction to econophysics: correlations and complexity in finance*. Cambridge University Press.
- McDonald, M., Suleman, O., Williams, S., Howison, S. y Johnson, N. F., 2005, "Detecting a currency's dominance or dependence using foreign exchange network trees". *Physical Review E*, 72(4), 046106. <https://doi.org/10.1103/PhysRevE.72.046106>.
- Naylor, M. J., Rose, L. C. y Moyle, B. J., 2007, "Topology of foreign exchange markets using hierarchical structure methods". *Physica A: Statistical Mechanics and its Applications*, 382(1), 199-208. <https://doi.org/10.1016/j.physa.2007.02.019>.
- Onnela, J. P., Chakraborti, A., Kaski, K. y Kertesz, J., 2003, "Dynamic asset trees and Black Monday". *Physica A: Statistical Mechanics and its Applications*, 324(1-2), 247-252. [https://doi.org/10.1016/S0378-4371\(02\)01882-4](https://doi.org/10.1016/S0378-4371(02)01882-4).
- Osterrieder, J., Strika, M. y Lorenz, J., 2017, "Bitcoin and cryptocurrencies not for the faint-hearted", *International Finance and Banking*, 4(1) 56. <https://doi.org/10.5296/ifb.v4i1.10451>.
- Phillip, A., Chan, J. y Peiris, S., 2018, "A new look at Cryptocurrencies". *Economics Letters*, 163, 6-9. <https://doi.org/10.1016/j.econlet.2017.11.020>.
- Song, D. M., Tumminello, M., Zhou, W. X. y Mantegna, R. N., 2011, "Evolution of worldwide stock markets, correlation structure, and correlation-based graphs". *Physical Review E*, 84(2), 026108. <https://doi.org/10.1103/PhysRevE.84.026108>.
- Tse, C. K., Liu, J. y Lau, F. C. M., 2010, "A network perspective of the stock market". *Journal of Empirical Finance*, 17(4), 659-667. doi:10.1016/j.jempfin.2010.04.008.
- Urquhart, A., 2017, "Price clustering in Bitcoin", *Economics letters*, 159, 145-148. <https://doi.org/10.1016/j.econlet.2017.07.035>.
- Vizgunov, A., Goldengorin, B., Kalyagin, V., Koldanov, A., Koldanov, P. y Pardalos, P. M., 2014, "Network approach for the Russian stock market". *Computational Management Science*, 11(1-2), 45-55. <https://doi.org/10.1007/s10287-013-0165-7>.
- Wang, G. J., Xie, C. y Stanley, H. E., 2018, "Correlation structure and evolution of world stock markets: Evidence from Pearson and partial correlation-based networks". *Computational Economics*, 51(3), 607-635. <https://doi.org/10.1007/s10614-016-9627-7>.

Datos de los autores

Nombre: Carlos Jaureguizar Francés
Cargo: Estudiante pre-doctoral
Escuela/Facultad: Facultad de Ciencias Jurídicas y Sociales
Universidad: Universidad Rey Juan Carlos
Dirección: Paseo de los Artilleros, s/n. 28032 Madrid
Teléfono: 914959211
Correo electrónico: c.jaureguizar@alumnos.urjc.es

Nombre: Pilar Grau-Carles
Cargo: Catedrático de Universidad
Escuela/Facultad: Facultad de Ciencias Jurídicas y Sociales
Universidad: Universidad Rey Juan Carlos
Dirección: Paseo de los Artilleros, s/n. 28032 Madrid
Teléfono: 914959211
Correo electrónico: pilar.grau@urjc.es

Nombre: Diego Jaureguizar Arellano
Escuela/Facultad: Facultad de Ciencias Humanas y Sociales
Universidad: Universidad Pontificia de Comillas
Dirección: Universidad Pontificia Comillas, 3-5. 28049 Madrid
Correo electrónico: diego.jaureguizar@aasgmail.com