

TRABAJO FINAL DE MÁSTER

Título: Impacto de las noticias sobre la volatilidad de Bitcoin

Autoría: Fèlix Badosa Tapia

Tutoría: Samer Ajour El Zein

Curso académico: 2021-2022



UNIVERSITAT DE
BARCELONA

Facultat d'Economia
i Empresa

Màster
**de Ciències
Actuarials
i Financeres**

Facultad de Economía y Empresa

Universidad de Barcelona

Trabajo Final de Máster

Máster en Ciencias Actuariales y Financieras

Impacto de las noticias sobre la volatilidad de Bitcoin

Autoría:

Fèlix Badosa Tapia

Tutoría:

Samer Ajour El Zein

El contenido de este documento es de exclusiva responsabilidad del autor, quien declara que no ha incurrido en plagio y que la totalidad de referencias a otros autores han sido expresadas en el texto.

RESUMEN

El presente trabajo consiste en un análisis del impacto de las noticias de prensa sobre la volatilidad de Bitcoin. Se realiza un análisis gráfico tomando una base de datos de noticias importada de un importante periódico económico nacional, y se observa el impacto de ciertas palabras clave sobre la serie de precios de Bitcoin. El análisis se complementa con un análisis estadístico basado en los modelos GARCH, y concretamente utilizando el modelo multivariante DCC. Este modelo muestra que las variables de estudio se correlacionan con la variable principal, concluyendo que sí es posible estimar el impacto que pueden tener las noticias sobre esta criptomoneda.

Palabras Clave: Bitcoin, noticias, GARCH, DCC, Correlación.

ABSTRACT

This paper consists of an analysis of the impact of press news on Bitcoin volatility. A graphical analysis is performed by taking a news database imported from a major national economic newspaper, and observing the impact of certain keywords on the Bitcoin price series. The analysis is complemented with a statistical analysis based on GARCH models, and specifically using the multivariate DCC model. This model shows that the study variables are correlated with the main variable, concluding that it is possible to estimate the impact that news about this cryptocurrency can have.

KeyWords: Bitcoin, news,

Índice

1. INTRODUCCIÓN	6
1.1. LAS CRYPTOMONEDAS Y EL BITCOIN	6
2. DATOS Y METODOLOGÍA	8
2.1. DATOS.....	8
2.2. METODOLOGÍA.....	9
3. IMPACTO DE LAS NOTICIAS SOBRE BITCOIN.....	10
3.1. CONTEXTO	10
3.2. ANÁLISIS GRÁFICO.	14
3.2.1. <i>Periodo 1 [01/01/2018 – 31/12/2018]</i>	14
3.2.2. <i>Periodo 2 [01/01/2019 – 31/12/2019]</i>	15
3.2.3. <i>Periodo 3 [01/01/20120 – 31/12/2020]</i>	16
3.2.4. <i>Periodo 4 [01/01/2021 – 31/12/2021]</i>	17
4. MODELIZACIÓN DE LA VARIANZA CON GARCH.	18
4.1. CONTEXTO	18
4.2. ANÁLISIS DE LAS SERIES.	18
4.3. ANÁLISIS INDIVIDUAL DE ESTACIONARIEDAD.....	21
4.4. ESTIMACIÓN DEL MODELO GARCH.	22
5. RESULTADOS DEL MODELO MULTIVARIANTE DCC	26
5.1. BTC-GLD.....	26
5.2. BTC-GSPC.....	28
5.3. BTC-DJI.....	29
5.4. BTC-N225.....	31
5.5. BTC-STOXX.....	32
5.6. BTC-EURODOL.....	34
5.7. BTC-EUROCNV.....	35
5.8. BTC-EUROGBP	37
6. FACTOR DE INFLACIÓN DE LA VARIANZA (FIV)	38
7. CONCLUSIONES, LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN	41
8. ANEXOS	42
8.2. CÓDIGO R	42
9. BIBLIOGRAFÍA	71

1. Introducción

1.1. Las cryptomonedas y el Bitcoin

Las cryptomonedas son divisas digitales que utilizan cifrados criptográficos para garantizar su titularidad, asegurar las transacciones financieras y controlar la creación de nuevas unidades. Estas divisas digitales están descentralizadas, por lo que carecen de control por parte de autoridades centrales o gobiernos. Son muchas las cryptomonedas existentes en el mercado hoy por hoy, pero podríamos considerar que las más trascendentes son Bitcoin y Ethereum. En este trabajo analizaremos el Bitcoin, la primera y por ende mas antigua cryptomoneda y la más popular internacionalmente.

Una de las particularidades que tiene Bitcoin es el fenómeno denominado “Halving”. El halving es un proceso automático que reduce a la mitad los Bitcoin que reciben los mineros como recompensa por la creación de un bloque. El objetivo es el de controlar el flujo de las nuevas cryptomonedas que llegan al mercado. Este proceso en el caso del Bitcoin se produce cada 4 años y sus efectos han sido foco de numerosos estudios. El halving se produce debido a que la cantidad de Bitcoins que pueden existir está determinada en 21 millones y aún faltan muchos por minar. Cada 10 minutos se liberan nuevos Bitcoin en el mercado, en forma de recompensa a los mineros que crean los bloques para validar cada una de las transacciones. Pero estas recompensas no son permanentes en el tiempo y aquí entra el proceso del halving.

Las primeras recompensas otorgadas a los mineros por su trabajo estaban determinadas en 50 BTC. Tras el primer halving en 2012, estas recompensas pasaron a ser de 25 BTC, de 12.5 BTC en 2016 y de 6.25 tras el último halving ocurrido en mayo de 2020. Si bien es cierto que tras estos procesos de reducción a la mitad se pueden comprobar acusadas subidas de precio en el BTC, al menos durante el primer periodo, modelizar su impacto y de la volatilidad es una tarea complicada. Y aquí entramos en el apartado más destacable de Bitcoin y de las cryptomonedas en general: su volatilidad. Pero para entender la funcionalidad de las cryptomonedas primero debemos conocer las tres propiedades básicas del dinero, e indicar que, de modo general, estas propiedades no suelen ser aplicables a estos activos.

El dinero tradicional, para ser considerado como tal, cumple tres propiedades básicas: es una unidad de cuenta, permite saber el precio que se le da a cualquier bien o servicio; es un medio de cambio, aceptado por todos en el momento de realizar transacciones económicas por un producto; depósito de valor, conservando su valor en el tiempo permitiendo así su acumulación y/o transacciones futuras. Bitcoin y las cryptomonedas en general no se considera que posean estas cualidades a priori, motivo por el que no se considera dinero real. El principal obstáculo de Bitcoin para actuar como medio de cambio o depósito de valor es su volatilidad. Las cryptomonedas no están respaldadas por ninguna entidad gubernamental de modo que su estabilidad depende directamente de la confianza de sus inversores. La volatilidad pues sigue una relación lineal negativa con la adopción masiva de la cryptomoneda: a mayor adopción, menor volatilidad. De todos modos, si

ampliamos el horizonte al largo plazo la volatilidad de la cryptomoneda se reduce en gran medida y aquí entra su papel como activo de cobertura, como medio de cambio o como depósito de valor.

La inestabilidad inherente a estos activos provoca que no sean un medio comúnmente aceptado para la determinación de precios, y por ende no sirvan como medio de cambio para transacciones ni estén considerados como activos con capacidad de depositar valor. La carencia de regulaciones y de entidades que las respalden, así como la no aceptación masiva de las cryptomonedas conllevan altas volatilidades, percibidas como inestabilidad para el inversor. El caso de Bitcoin pero, es un caso distinto al de las demás cryptomonedas. Si bien es cierto que en sus inicios Bitcoin fue extremadamente volátil, a lo largo de su vida han ido ocurriendo un conjunto de sucesos que han reducido en gran medida su volatilidad y ha empezado a ser considerado por algunos como medio de cambio o, sobretodo, como depósito de valor. Tal como explican Karl Oton Rudolf, Samer Ajour El Zein y Nicola Jackman Lansdowne en su publicación “Bitcoin as an Investment and Hedge Alternative. A DCC MGARCH Model Analysis”, Bitcoin empezó a ganar popularidad en 2011 cuando Wikileaks empezó a aceptar donaciones con este activo. Posteriormente, entre los años 2011 y 2012, se publicaron numerosos artículos y conferencias sobre Bitcoin dando publicidad a la cryptomoneda y coincidiendo con la ocurrencia de numerosos escándalos financieros. También en ese periodo, se crearon las primeras carteras digitales para almacenar cryptomonedas, lo que despertó el interés del público. De todos modos, Bitcoin no fue masivamente reconocido hasta 2013. Ese año, y a raíz de la crisis financiera en Chipre, el gobierno no tuvo más remedio que aceptar el rescate de UE y el FMI y lo financió imponiendo una tasa bancaria sobre todos los depósitos. Hay que tener en cuenta que la demanda de Bitcoin también se vio impulsada por las actividades ilegales debido a su factor de anonimato. Otros factores que influyeron es que varios minoristas empezaron a aceptar Bitcoin y en 2014 el IRS clasificó Bitcoin como un activo y no una moneda. Finalmente, el hecho más relevante y con más impacto sobre esta cryptomoneda ha sido la pandemia de 2020 que, coincidiendo con el “halving”, demostraron una mayor adopción masiva y una menor volatilidad en comparación con los halvings históricos.

En resumen, para que Bitcoin pudiera ser aceptado como medio de cambio, debería ser aceptado como método de pago en una red suficientemente extensa de bienes y activos. Como ya hemos dicho, una aceptación masiva al nivel de poder considerarlo como instrumento de cambio reduciría enormemente su volatilidad, disipando así su mayor obstáculo. Como las cryptomonedas no cuentan con el respaldo de autoridades institucionales esto solo podría suceder por la credibilidad y expectativa de los agentes privados. Un contexto similar se encuentra BTC en cuanto a ser considerado como depósito de valor. A largo plazo ha demostrado tener un crecimiento sostenido con una menor volatilidad, motivo por el cual se plantea la posibilidad de utilizar el Bitcoin como sustitutivo del oro para realizar coberturas. Además, los rendimientos que otorga están por encima de los rendimientos generados por el oro, por lo cual una adopción masiva, acompañada de una reducción en gran medida de la volatilidad, afianzaría la

criptomoneda como depósito de valor y probablemente alcanzaría la condición de método de cambio, y se convertiría también en un sustitutivo rentable y fiable para operaciones de cobertura de todo tipo.

2. Datos y Metodología

2.1. Datos

El principal objetivo de este trabajo descubrir si las noticias de prensa pueden tener impacto sobre la volatilidad de la criptomoneda más conocida internacionalmente: el Bitcoin. Con el fin de analizar este impacto se han obtenido datos acordes a las partes diferenciadas de este trabajo. La principal herramienta utilizada para la realización de este estudio ha sido el software R, utilizando el entorno RStudio.

La primera parte del trabajo consiste en un análisis gráfico donde se comprobará si la coincidencia de palabras clave buscadas dentro de una base de datos de noticias concuerda con los movimientos en el precio de Bitcoin Para ello, y con la ayuda del programa gratuito Octoparse, hemos descargado una base de datos de noticias de prensa publicadas en Expansión - uno de los periódicos económicos nacionales con más audiencia - en su apartado “Bolsas y Mercados”. Las noticias recogidas son todas las pertenecientes al apartado mencionado para el periodo comprendido entre enero de 2018 y diciembre de 2021, un total de 4 años. Estas noticias se han exportado como base de datos en un Excel y posteriormente importadas a R y trabajadas con la ayuda principalmente del paquete “data_table”, una versión mejorada del “data_frame”. Las palabras clave seleccionadas para la búsqueda no son palabras al azar, sino que son palabras que refieren a variables financieras que se cree pueden tener impacto en la volatilidad de la criptomoneda, siendo ésta la principal hipótesis del trabajo.

La segunda parte del trabajo requiere un análisis econométrico de las variables mencionadas. El paquete “quantmod” de R permite importar directamente de el sitio web “Yahoo Finance” los precios de las variables de estudio. Para este caso se han obtenido los precios de cierre ajustado de las variables Bitcoin (BTC), oro (GLD), S&P500 (GSPC), Dow Jones (DJI), Nikkei225 (N225), EuroStoxx50 (STOXX), y los tipos de cambio euro-dólar (EUR_DOL), euro-yuan (EUR_CNY) y euro-libra esterlina (EUR_GBP). En este segundo apartado del trabajo de analizará de forma conjunta Bitcoin con el principal activo refugio existente, el oro, con los principales mercados de valores internacionales y con 3 de los tipos de cambio mas importantes a nivel internacional. Se estimará un modelo GARCH para cada una de ellas para finalmente realizar el análisis dos a dos con la serie de Bitcoin mediante un modelo DCC. Esto se ha trabajado a partir de las librerías “rugarch” y “rmgarch”.

Para finalizar el trabajo se realiza un análisis del VIF para estudiar las futuras líneas de investigación que podría tener el trabajo. Este análisis estadístico se realiza a partir de la librería “car” en R.

2.2. Metodología

La principal utilidad de los modelos GARCH (Generalized Autoregressive Conditionally Heteroscedastic) es la modelización de la varianza de una serie temporal. Estos modelos son de gran utilidad cuando se trabaja con series de alta volatilidad como son las series financieras. Pero para entender en qué consisten estos modelos, hay que referirse primero al modelo más básico propuesto por Robert Engle, en 1982: el modelo ARCH. Este modelo implica la hipótesis de una volatilidad no constante en el tiempo, teniendo en cuenta los datos existentes de periodos anteriores.

El modelo ARCH(1,1) se define como:

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2$$

Donde

σ_t^2 : varianza condicional

α_0 : constante

r_{t-1}^2 : rendimientos al cuadrado de periodo anterior

Como se puede ver, la varianza condicional es una función lineal que depende positivamente de los rendimientos al cuadrado. Para que el modelo sea válido debe cumplir las condiciones de positividad,

$$\alpha_0 > 0$$

Y estacionariedad,

$$\alpha_1 < 1$$

El principal problema que tienen estos modelos ARCH es que no tienen en cuenta la persistencia de la volatilidad frente a los shocks del mercado.

Los modelos GARCH son los solucionan este problema con incorporación de un nuevo parámetro a la ecuación:

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

Donde

α_1 : parámetro que mide la reacción en la volatilidad de los eventos del mercado.

β_1 : parámetro que mide la persistencia en la volatilidad condicional independientemente de los eventos del mercado.

Finalmente, los modelos DCC GARCH son una evolución de los GARCH. Los modelos DCC son modelos GARCH multivariantes que permiten aplicar una estructura dinámica a la matriz de varianzas y covarianzas condicionales. La principal innovación de estos modelos multivariantes implica que la volatilidad no dependa exclusivamente de su pasado, sino que también depende de la volatilidad pasada de otras series temporales.

$$H_t = D_t R_t D_t$$

Donde H_t es la matriz de varianzas y covarianzas

$$R_t = (\text{diag}(Q_t))^{-\frac{1}{2}} Q_t (\text{diag}(Q_t))^{-\frac{1}{2}}$$

Donde

$$Q_t = (1 - \alpha - \beta)\bar{Q} + \alpha\eta_{t-1} - 1\eta'_{t-1} + \beta Q_{t-1}$$

Con

\bar{Q} : matriz de varianza incondicional de η_t

η_t : residuos estandarizados.

3. Impacto de las noticias sobre Bitcoin

3.1. Contexto

La volatilidad de las criptomonedas tal y como se ha explicado, se debe principalmente a dos factores: la credibilidad que le otorguen sus inversores y la carencia de una entidad reguladora. La motivación de este trabajo surge a raíz de estas dos características de las criptomonedas, planteando la siguiente hipótesis :¿es posible que las noticias de prensa aguarden una reacción directa con la volatilidad del Bitcoin?

Esta es una pregunta difícil de responder debido a la existencia de multitud de factores. El primer factor a tener en cuenta es el periódico, digital o escrito, a escoger. El periódico o periódicos escogidos son de suma importancia para este análisis por el público al que van dirigidos y el tipo de noticias que publiquen. Para este trabajo hemos decidido utilizar el periódico económico Expansión por dos motivos. Este es uno de los periódicos especializados mas consumidos en España, por lo que nos aseguramos de que las noticias publicadas puedan tener un impacto notable en la sociedad española. Se supone también que la gente que recibe y consume Expansión, podría ser una muestra representativa de la actuación de la población de otros países frente a periódicos de las mismas

características. El segundo factor clave es la disposición de hemeroteca gratuita y accesible. Es importante escoger un periódico que tenga audiencia, pero también lo es poder acceder a las bases de datos de noticias anteriormente publicadas.

Ciertamente, para obtener un análisis lo más fiable y acertado posible lo mejor sería poder seleccionar los periódicos más relevantes a nivel internacional y descargar toda la hemeroteca de éstos para el horizonte temporal estudiado, o incluso poder realizar un estudio sociológico previo para saber qué características comparten las personas que deciden invertir en ésta clase de activo pero ni es viable la primera opción por la cantidad de medios internacionales existentes y la cantidad de datos que se manejarían, ni la segunda por el coste que representaría un estudio de éstas características y que fuera representativo para todos los continentes. Es por este motivo que se ha decidido trabajar con un periódico nacional especializado de gran audiencia y suponer que el impacto que tiene sobre la sociedad española en cuanto a tomar decisiones de inversión basadas en las noticias de prensa publicadas es similar en el resto de países.

Otro factor a tener en cuenta es el horizonte temporal. Éste debe ser lo suficientemente extenso como para ser representativo, siendo la situación ideal para el caso de Bitcoin considerar el periodo de tiempo completo desde su creación hasta día de hoy. Debido a la imposibilidad de relizar el trabajo para un periodo de tiempo tan extenso, para este trabajo se decide utilizar un horizonte temporal de 4 años, desde el 01 de enero de 2018, hasta el 31 de diciembre de 2021.

Finalmente, otro factor a tener en cuenta son las palabras clave escogidas para realizar la búsqueda dentro de las noticias. El impacto de las noticias sobre Bitcoin se identificará a partir de palabras clave buscadas con la ayuda R, motivo por el cual es muy importante que la selección de palabras a extraer dentro de las noticias sea representativa de la noticia en sí misma. La idea es encontrar dentro de cada una de las noticias descartadas, las palabras clave previamente declaradas y montar una base de datos diaria con el conjunto de palabras coincidentes para cada día dentro del horizonte temporal en el que trabajamos.

El primer paso para realizar este análisis es descargar todas las noticias para el periodo comprendido entre 01/01/2018 y 31/12/2020. Para ello lo primero ha sido filtrar las noticias por apartados, dando especial importancia a las noticias de “Bolsas y Mercados”. Gracias a la hemeroteca disponible hemos obtenido todas las noticias publicadas en dicho periodo y relacionadas con el apartado mencionado con la ayuda del programa “Octoparse”. Octoparse es una herramienta que permite la extracción de datos de cualquier tipo de páginas web y los convierte automáticamente a Excel, es decir, permite aplicar la técnica de “web scrapping” pero sin necesidad alguna de codificar o programar. Esta herramienta dispone de dos funcionalidades principales, que son el rastreo automático o manual. Para la extracción de las noticias se ha utilizado la extracción manual, y tras varias pruebas, aplicando parámetros concretos para optimizar la descarga.

Como la hemeroteca de este periódico se divide en diferentes direcciones, es decir, no dispone de comandos para pasar a las páginas siguientes, sino que cada conjunto de noticias del día en cuestión está dispuesto en una URL diferente, el primer paso para la

ejecución del programa consiste en la preparación de un archivo Excel que contenga la información de las páginas a rastrear. Se crea una columna con todas las fechas a nivel diario del horizonte temporal seleccionado y, con las funciones “AÑO(), MES() y DIA()”, extraemos en columnas contiguas el año el mes y el día de cada fecha. Por último creamos una función para construir la URL, que consiste en concatenar el inicio de la URL del periódico Expansión, con los datos del día, mes y año extraídos y aplicando dos condicionales (SI(valor lógico; valor si verdadero; valor si falso)) para obtener el formato adecuado para que la herramienta pueda acceder sin problemas al sitio web. La fórmula final quedaría así :

```
= "https://www.expansion.com/hemeroteca/" & B2 & SI(C2 < 10; "/" & 0; "/" & "") & C2 & SI(D2 < 10; "/" & 0; "/" & "") & D2 & "/"
```

 □ siendo B,C y D las columnas que contienen el año, mes y día de cada fecha.

Una vez realizada la base de datos que contiene todos los vínculos a las páginas web deseadas, se prepara el programa mediante la aplicación Octoparse. Primero se abre la página base para el rastreo y se seleccionan los datos que se quieren extraer en bucle. Para este caso hemos seleccionado el titular de la noticia en una columna, el cuerpo de ésta en otra columna, y una tercera columna que indique la fecha de cada noticia extraída. Por último, se indica cómo quiere realizarse el rastreo, cargando el Excel creado previamente con todas las páginas web a rastrear, introducimos un tiempo de espera de carga de la URL de 2 segundos para evitar posibles errores y se ejecuta el programa. Tras varias horas de ejecución, finalmente obtenemos nuestra base de datos de noticias en varios archivos en formato XLSX. Ya que toda la parte técnica de este trabajo se hace en el software R, preparamos el output obtenido de Octoparse para poder trabajarlo en R fácilmente. Agrupamos todos los Excel en una pestaña de un único archivo y creamos una nueva pestaña que contenga las columnas “Titular”, “Campo” y “Fecha” con el formato deseado.

Apoyándonos básicamente en los paquetes de R “read_xlsx” y “data_table”, importamos los datos a R y los almacenamos en formato “data table”. “Data table” es una versión mejorada del “data frame” que tiene una sintaxis propia, aunque también se puede utilizar la sintaxis de “data frame”. Con ya toda la información importada, damos formato de fecha al campo “Fecha” con la función “as_date()” y convertimos en minúsculas todo el texto de las variables “Campo” y “Titular” para evitar la pérdida de información. Con la información importada y estructurada comenzamos el análisis que constará de tres partes diferenciadas. La primera es la selección de palabras clave a buscar y creación de las diferentes columnas con valor igual a 0 de cada una de las palabras dentro de la base de datos:

```

bbdd_noticias$CRISIS <- 0
bbdd_noticias$BITCOIN <- 0
bbdd_noticias$ETHEREUM <- 0
bbdd_noticias$BOLSA <- 0
bbdd_noticias$FED <- 0
bbdd_noticias$BCE <- 0
bbdd_noticias$CRIPTO <- 0
bbdd_noticias$MUSK <- 0
bbdd_noticias$DOLAR <- 0
bbdd_noticias$EURO <- 0
bbdd_noticias$YUAN <- 0
bbdd_noticias$TIPOS <- 0
bbdd_noticias$MERCADOS <- 0
bbdd_noticias$LIQUIDEZ <- 0
bbdd_noticias$DIGITAL <- 0
bbdd_noticias$ORO <- 0
bbdd_noticias$IBEX <- 0
bbdd_noticias$SP500 <- 0
bbdd_noticias$JONES <- 0
bbdd_noticias$NIKKEI <- 0
bbdd_noticias$DAX <- 0
bbdd_noticias$EUROSTOXX <- 0

```

Ilustración 1. Fuente: Elaboración propia.

El segundo paso consiste en contar, por cada día dentro del horizonte temporal, el número de palabras que coinciden en el mismo día utilizando un método de ceros y unos. Es decir, lo que se hace es básicamente un recuento de las palabras clave escogidas de modo que si la palabra clave aparece en alguna noticia de ese día se computará como un 1 en la fila, mientras que, si no aparece, se computará como 0. Este método es útil ya que, una vez realizado todo el recuento, se puede saber la cantidad de palabras que coinciden el mismo día simplemente haciendo una suma por filas de las columnas. A continuación, se muestra una imagen del código de R utilizado para encontrar las palabras en la base de datos, tomando como ejemplo la palabra “bitcoin”, y otra imagen con un sumario del resultado final obtenido:

```

bbdd_noticias$BITCOIN <- case_when(grepl("bitcoin",bbdd_noticias$TITULAR)~ 1,
                                   grepl("bitcoin",bbdd_noticias$CAMPO)~ 1,
                                   TRUE~0)

```

Ilustración 2. Fuente: Elaboración propia.

```

> table(bbdd_noticias$TABLA)

```

	0	1	2	3	4	5	6	7	8
	4919	5194	2378	1021	325	81	15	1	1

Tabla 1. Fuente: Elaboración propia. Resultados de la búsqueda de palabras clave en la base de datos.

En la segunda imagen vemos el resumen de todas las palabras contabilizadas en la base de datos de noticias, indicando cuántas veces coinciden un mismo día las palabras clave determinadas, de modo que hay 4,919 días que no se encuentra ninguna de las palabras, 5,194 días donde existe solamente 1 de las palabras, 2,378 días donde coinciden dos palabras, etc. Teniendo esta información, nos centramos en los días en que coinciden 5 o más palabras y los analizamos con la intención de encontrar posibles correlaciones con los datos de Bitcoin. A partir del portal web “Yahoo Finanzas” obtenemos los precios a

cierre ajustado del Bitcoin para el intervalo comprendido entre el 01/01/2018 y 31/12/2021 y lo graficamos. Para poder analizar con mayor precisión y detalle los datos, graficaremos los datos de Bitcoin por periodos de 1 año.

3.2. Análisis gráfico.

3.2.1. Periodo 1 [01/01/2018 – 31/12/2018]

	FECHA	TABLA
1:	2018-01-04	5
2:	2018-02-27	5
3:	2018-03-07	5
4:	2018-06-08	5
5:	2018-06-11	5
6:	2018-06-12	5
7:	2018-06-14	6
8:	2018-08-15	5
9:	2018-09-25	5
10:	2018-09-26	5
11:	2018-10-18	5
12:	2018-11-08	5
13:	2018-12-13	5
14:	2018-12-19	6
15:	2018-12-20	5

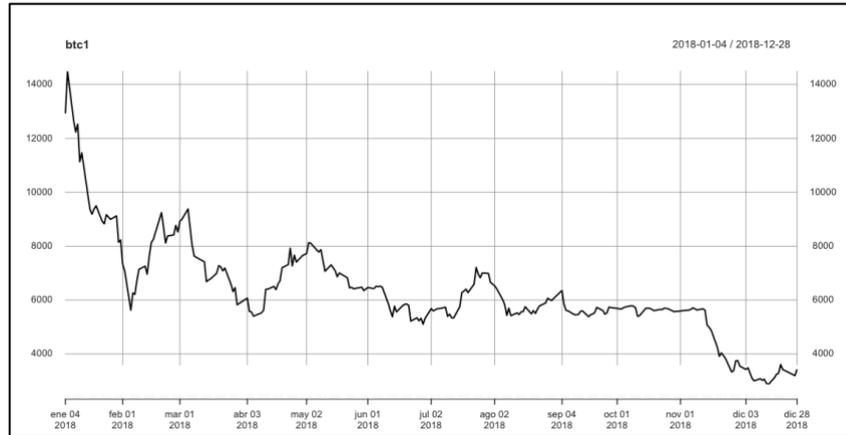


Gráfico 1. Fuente: Elaboración propia. Serie de precios de Bitcoin para el primer periodo.

Tabla 2. Fuente: Elaboración propia.

Para el primer año del periodo estudiado obtenemos una tabla con 15 fechas distintas donde coinciden 5 o más palabras clave en cada una de las fechas. Observando el gráfico no se puede obtener una conclusión clara debido a que hay periodos en los que sí parece haber una relación entre las noticias publicadas en esas fechas con los movimientos del activo digital en cuestión, pero también hay momentos en los que la volatilidad del Bitcoin no parece responder a las noticias de esos días. El primer caso lo vemos sobretodo al inicio y al final de la serie, que también son los dos periodos con mayor volatilidad. Las tres primeras fechas que vemos en la tabla corresponden a los meses de enero, febrero y marzo, donde observamos una altísima volatilidad en el precio de la cryptomoneda. Las siguientes fechas mostradas hacen referencia a la mitad del periodo de estudio, donde observamos también una alta volatilidad de los precios, aunque no tan alta como en los primeros meses del año. Este impacto se observa también al final del periodo, donde vemos que el precio de Bitcoin se desploma entre noviembre y diciembre y se mantiene inestable hasta el final del periodo. Por el contrario, las coincidencias de palabras en las fechas entre octubre y noviembre no parece que tengan ningún tipo de relación con el activo, ya que tal como vemos, es el periodo donde más estabilidad se observa en su precio.

3.2.2. Periodo 2 [01/01/2019 – 31/12/2019]

	FECHA	TABLA
1:	2019-01-30	6
2:	2019-03-06	5
3:	2019-03-07	7
4:	2019-03-08	5
5:	2019-03-20	6
6:	2019-03-27	5
7:	2019-05-02	5
8:	2019-06-05	5
9:	2019-06-06	5
10:	2019-06-18	6
11:	2019-06-20	6
12:	2019-06-26	5
13:	2019-07-09	5
14:	2019-07-10	5
15:	2019-07-19	5
16:	2019-08-19	5
17:	2019-09-12	5
18:	2019-09-18	5
19:	2019-09-19	5
20:	2019-10-24	5
21:	2019-10-31	5
22:	2019-11-18	5

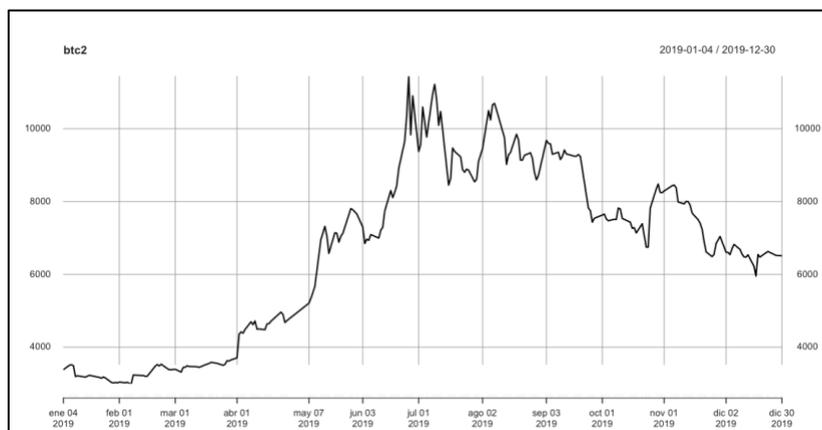


Gráfico 2. Elaboración propia. Serie de precios de Bitcoin para el segundo periodo.

Tabla 3. Elaboración propia.

El segundo periodo empieza con precios notablemente estables entre los 3 primeros meses del año, y es a partir de abril cuando se observa un aumento exponencial del precio de Bitcoin, con una volatilidad elevada. Si observamos la tabla que obtenemos de R, vemos como durante enero y febrero, en una sola ocasión hay coincidencia de 5 o más palabras, reflejando la estabilidad en los precios que observamos en el gráfico. Es a partir de marzo donde en 5 ocasiones existen coincidencias de palabras en las noticias, y como se puede observar en el gráfico, tras este periodo la volatilidad aumenta enormemente. A partir de ese punto aún se puede ver más claro el reflejo de las noticias en los precios de la cryptomoneda. De las 22 fechas que se alertan en el output de la base de datos, 16 se distribuyen entre mayo y noviembre del año en cuestión, periodo donde se puede ver una alta volatilidad en el gráfico. Concretamente, el periodo que se corresponde entre junio septiembre, es el que muestra una volatilidad más alta, y también una mayor acumulación de fechas con palabras coincidentes: 12 de las 22 filas se concentran en estos 3 meses, mientras que en diciembre, donde parece que los precios se empiezan a estabilizar, no se obtiene ninguna coincidencia en la tabla de noticias, lo que nos puede indicar una correlación positiva entre las noticias y los movimientos del gráfico.

3.2.3. Periodo 3 [01/01/20120 – 31/12/2020]

FECHA	TABLA
1: 2020-01-27	5
2: 2020-01-28	5
3: 2020-01-29	5
4: 2020-02-02	6
5: 2020-02-05	5
6: 2020-02-17	5
7: 2020-02-18	5
8: 2020-02-24	6
9: 2020-02-27	5
10: 2020-03-03	5
11: 2020-03-04	6
12: 2020-03-10	5
13: 2020-03-11	8
14: 2020-03-11	6
15: 2020-03-12	5
16: 2020-03-12	6
17: 2020-03-12	5
18: 2020-03-13	5
19: 2020-03-16	5
20: 2020-03-18	5
21: 2020-03-19	5
22: 2020-03-20	5
23: 2020-03-24	5
24: 2020-03-26	5
25: 2020-03-29	5
26: 2020-03-31	5
27: 2020-04-06	5
28: 2020-04-14	6
29: 2020-04-20	5
30: 2020-04-28	5
31: 2020-05-04	5
32: 2020-05-13	5
33: 2020-06-05	5
34: 2020-06-18	5
35: 2020-07-01	5
36: 2020-07-16	5
37: 2020-10-26	5
38: 2020-10-30	5
39: 2020-11-20	5
40: 2020-11-24	5
41: 2020-12-09	5
42: 2020-12-10	5
43: 2020-12-22	5

Tabla 4. Fuente: Elaboración propia.

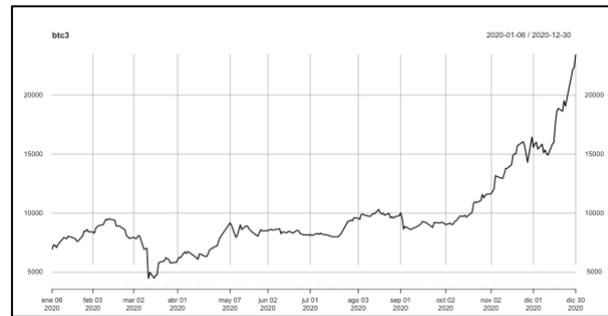


Gráfico 3. Fuente: Elaboración propia. Serie de precios de Bitcoin para el tercer periodo.

El tercer periodo de estudio como se puede ver en el gráfico de precios es el que presenta una mayor volatilidad hasta ahora. Hay que tener en cuenta que en este caso el margen de las “y” triplica su precio desde el punto 0, al punto más alto. Esto concuerda también con la tabla que se ha obtenido a partir de la base de datos de noticias, que en este caso es en 43 ocasiones donde se observa una concordancia en las palabras clave. Durante los dos primeros meses del año se obtiene un total de 9 filas en la tabla y el gráfico muestra este impacto con una volatilidad notable. Durante el mes de marzo, momento en el que se declara oficialmente la pandemia del COVID-19, se acumulan la mayor parte de fechas en la tabla, un total de 17 ocasiones. En el gráfico este impacto lo vemos reflejado en la caída exponencial del precio de Bitcoin en cuestión de días y en los movimientos posteriores durante este mismo mes, que muestran una volatilidad muy alta. El mes siguiente también es uno de los que mayor volatilidad presenta en este periodo y coincide con las 4 filas que se muestran en la tabla. La primera mitad del mes de mayo obtiene también 2 fechas en la tabla y el gráfico actúa en consecuencia, mientras que a partir de la segunda mitad del mes y hasta mediados de julio, los precios se estabilizan notablemente. Desde julio hasta octubre no se muestra ningún dato en la tabla, pero a partir de octubre la tabla comienza a mostrar alertas de coincidencias en la base de datos que se mantienen hasta diciembre. Este hecho lo vemos también en el gráfico, con un aumento elevadísimo del precio del activo en un periodo de tiempo muy corto, y con oscilaciones en el precio que, si bien la media parece estabilizarse al alza, la volatilidad sigue siendo elevada.

3.2.4. Periodo 4 [01/01/2021 – 31/12/2021]

	FECHA	TABLA
1:	2021-01-26	5
2:	2021-01-27	5
3:	2021-03-12	6
4:	2021-04-05	6
5:	2021-04-06	5
6:	2021-04-13	5
7:	2021-04-24	5
8:	2021-06-10	5
9:	2021-06-17	5
10:	2021-07-05	5
11:	2021-07-26	5
12:	2021-08-04	5
13:	2021-09-22	5
14:	2021-10-13	5
15:	2021-11-04	5
16:	2021-11-15	5
17:	2021-11-23	5
18:	2021-12-16	6

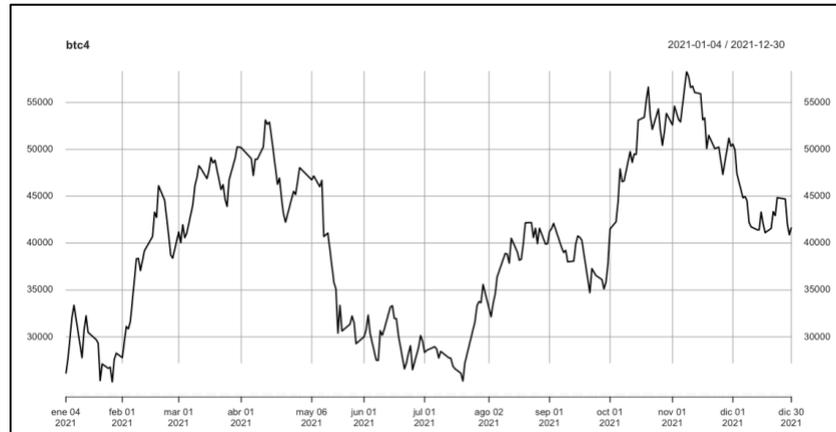


Gráfico 4. Elaboración propia. Serie de precios de Bitcoin para el cuarto periodo.

Tabla 5. Fuente: Elaboración propia.

El aumento del precio visto en el tramo final del periodo anterior sigue la misma tendencia durante los primeros meses del horizonte entre enero de 2021 y diciembre de este mismo año, así como su volatilidad. En enero, donde se obtienen datos en dos ocasiones en la tabla, se puede observar una caída del precio del activo por debajo de los 30,000€. Durante el mes de febrero el precio sube hasta llegar a un máximo por encima de los 45,000€ pero termina el mes cayendo por debajo de los 40,000. En abril se obtienen 4 fechas repartidas a lo largo del mes mostrando un periodo de alta volatilidad observado también en el gráfico. Los siguientes avisos de la tabla se muestran en junio donde la caída del precio parece menguar y entra en otro periodo de alta volatilidad que se mantiene hasta finales del mes siguiente, donde se observan otras dos filas en la tabla. Finalmente, las últimas filas que se obtienen en la tabla representan los meses de octubre a diciembre, poniendo especial foco a en noviembre, el mes con mayor volatilidad del último trimestre.

Tras analizar gráficamente y en detalle todo el periodo de estudio con el output obtenido de la base de datos de noticias no se puede llegar a una conclusión clara, pero sí se pueden señalar indicadores que marcarán el siguiente paso del trabajo. En los gráficos se ha podido comprobar que, en su mayor parte, las tablas parecían mostrar los movimientos del precio del Bitcoin, pero también se ha visto alguna fecha que parecía no tener un impacto notable. Esto no tendría por qué indicar ni que la hipótesis inicial fuera correcta, ya que un análisis gráfico no sería suficiente para validar el impacto de las noticias, pero tampoco podría asegurarse la situación contraria. Para ello procedemos con la segunda parte del trabajo, consistente en la modelización de la varianza de Bicoín y el análisis de la correlación de éste con distintas variables financieras que también encontramos múltiples veces en las noticias.

4. Modelización de la varianza con GARCH.

4.1. Contexto

En vista de los resultados tras el análisis gráfico del primer apartado, se procede a modelizar la varianza de Bitcoin y las variables estudiadas para encontrar posibles correlaciones. Las palabras clave seleccionadas en las noticias se correspondían con variables económicas que se cree podrían tener relación con los movimientos del precio de Bitcoin y de ahí la necesidad de este segundo análisis econométrico. Para realizarlo, se han obtenido los datos a través del portal Yahoo Finance de los precios al cierre ajustado sobre Bitcoin (BTC); algunos de los principales mercados internacionales como S&P 500 (GSPC), DOWJONES (DJI), NIKKEI (N225) y Euro Stoxx50(STOXX); y los tipos de cambio Euro-Dólar, Euro-Yuan y Euro-GBP. Los tipos de interés se consideran una variable exógena constante debido a que la variación de éstos durante el periodo de estudio es mínima o inexistente. Las series están valoradas en distintas divisas, aunque eso no supone un problema ya que para el análisis estadístico se trabajará con rendimientos. La idea es comparar las series dos a dos para identificar las posibles correlaciones, a través de modelos multivariante GARCH DCC. Escogemos este método ya que la particularidad de los GARCH es que permiten modelizar la varianza de una manera dinámica, es decir, dejando atrás la hipótesis de una varianza constante. Los modelos GARCH DCC tienen gran utilidad en las series econométricas del tipo financiero, y son una evolución de los GARCH que permiten también hacer predicciones dinámicas sobre la varianza, la covarianza y correlación sobre dos series.

4.2. Análisis de las series.

En este apartado realizaremos un análisis preliminar sobre las 9 series.



Gráfico 5. Fuente: Elaboración propia. Serie de precios de Bitcoin.

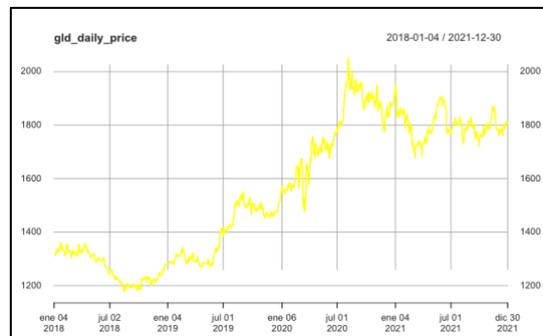


Gráfico 6. Fuente: Elaboración propia. Serie de precios del oro.

Para contextualizar la serie de rendimientos de Bitcoin, en el periodo inmediatamente anterior a 2018 esta cryptomoneda sufre una enorme caída en su precio que lo reduce a la mitad. Posteriormente, podemos observar como se mantiene más o menos estable (aunque con unos márgenes de volatilidad muy amplios) desde ese punto hasta prácticamente 2021, donde incrementa su precio exponencialmente. En julio de 2021 sufre de nuevo otra acusada caída que en pocos meses se compensa con otra brutal subida, anotando un máximo histórico 6 meses después. Finalmente, BTC termina el año con otra gran caída, mostrando que si bien puede parecer converger con el oro como veremos a continuación, su riesgo es más elevado también. En cuanto al oro, vemos que la tendencia es similar a la del Bitcoin, pero con una volatilidad mucho menor, con subidas/bajadas de precio más leves, pero durante periodos más largos. Esta primera similitud parece indicar que podrían tener propiedades en común, aún y siendo Bitcoin mucho más inestable. De todos modos, es incuestionable que el activo que más ha crecido en este periodo ha sido el Bitcoin.



Gráfico 7. Fuente: Elaboración propia. Serie de precios de GSPC.

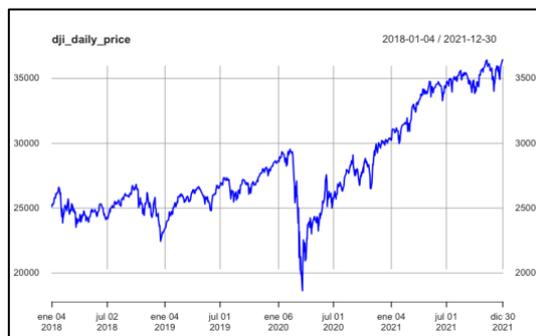


Gráfico 8. Fuente: Elaboración propia. Serie de precios de DJI.

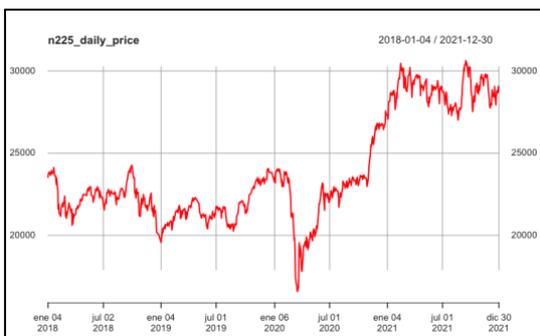


Gráfico 9. Fuente: Elaboración propia. Serie de precios de N225.

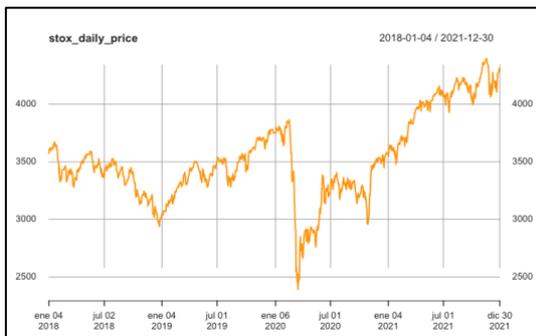


Gráfico 10. Fuente: Elaboración propia. Serie de precios de STOXX.

En cuanto a las bolsas de valores estudiadas, vemos que presentan gráficas muy similares, siendo la bolsa de valores de Japón, NIKKEI, la que presenta una mayor diferencia con las demás. Al inicio de la serie, parece que los mercados seguían una tendencia alcista hasta finales de 2018, excepto el EUROSTOXX, que se mantiene más o menos estable. En ese punto las 4 series muestran caídas de los precios hasta enero de 2019 momento en el que todos los mercados presentan tendencia al alza. A partir de ahí, vemos

perfectamente los efectos de la Pandemia causada por el COVID19 en todas las series de manera clara: los precios en las bolsas de valores se desploman a principios de 2020 y se entra en una espiral clara de alta volatilidad en los mercados. En ese punto destacan los movimientos tanto del Bitcoin como del oro en verso a las bolsas de valores, ya que las caídas que sufren estos activos son mucho menos pronunciadas mostrando la capacidad de ambos activos de actuar como activos refugio. A partir de este periodo vemos que todos los mercados se recuperan, con tendencias alcistas hasta el final del horizonte estudiado. El mercado japonés es el único que difiere, mostrando una caída durante el año 2021, que curiosamente coincide con los movimientos tanto del Bitcoin como del oro. Estos dos mencionados vemos que se recuperan rápidamente después de la pandemia, pero especialmente destaca la enorme subida que presenta el Bitcoin hasta mediados de 2021, que parece indicar una creciente aceptación de ésta por parte de los inversores.

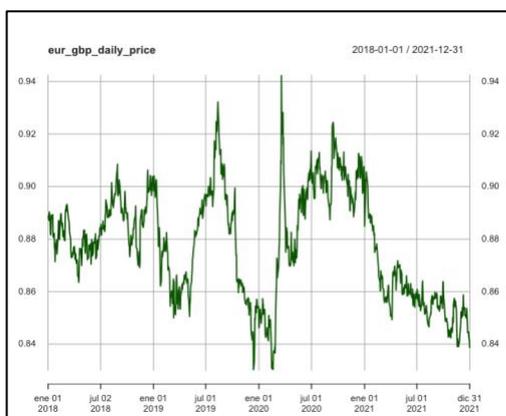


Gráfico 11. Fuente: Elaboración propia. Serie de precios EUR_GBP.

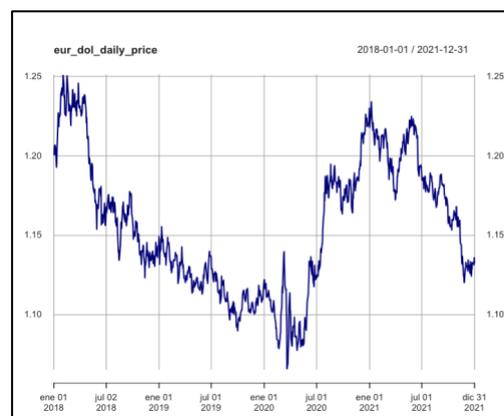


Gráfico 12. Fuente: Elaboración propia. Serie de precios de EUR_DOL.

de

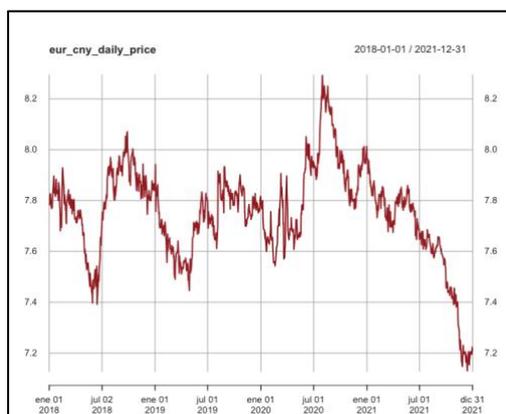


Gráfico 13. Fuente: Elaboración propia. Serie de precios EUR_CNY.

Así como las series del mismo tipo anteriores presentaban muchas similitudes, vemos que las series de tipos de cambio del dólar, libra esterlina y yuan chino son notablemente distintas entre si. El tipo de cambio euro-dólar muestra tres tramos diferenciados: un primer tramo desde el inicio de la serie hasta inicios del año 2020; un segundo tramo

desde el punto anterior hasta principios de 2021; y un último tramo desde enero de 2021 hasta el final de la serie. Durante el primer tramo, este gráfico presenta una tendencia claramente bajista. El gráfico euro-gbp podría presentar una tendencia mas o menos similar, aunque en este caso no es ni mucho menos tan clara. Por el contrario, para el mismo periodo el gráfico euro-yuan muestra una serie de picos alrededor de una media parecida, pero sin una tendencia clara. A partir del año 2020, año de entrada de la pandemia, se puede observar como las tres gráficas parecen converger en cuanto a tendencias. En los tres casos se puede observar tendencias al alza hasta inicios de 2021 y un decrecimiento sostenido hasta el final del periodo (en el gráfico euro-yuan parece que la tendencia alcista termina unos meses antes que las demás series, momento en el que empieza a caer el tipo de cambio).

4.3. Análisis individual de estacionariedad.

Tras un primer análisis del precio de las series nos disponemos a realizar los análisis individuales de estacionariedad para poder trabajar con ellas. En el informe explicaremos los pasos seguidos para realizar este análisis sobre el Bitcoin, pero este proceso se repetirá para las demás series.

Primero de todo realizaremos los análisis pertinentes para encontrar el modelo adecuado para modelizar la volatilidad del Bitcoin.

Analizamos los gráficos de autocorrelación y autocorrelación parcial de la serie donde se ve que la FAS decrece lentamente y la FAP muestra un pico de valor 1, indicando que la serie no es estacionaria. El L-Jung Box test nos confirma esta conclusión, ya que el p-value para 1,5,10 y 15 retardos es inferior a 0.05 en todos los casos, rechazando así la hipótesis nula (H_0 =la serie es estacionaria).

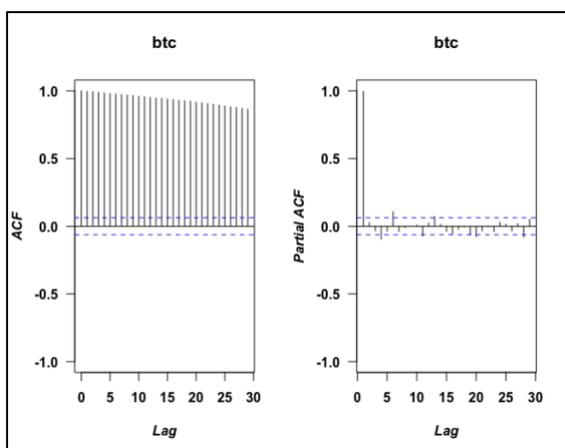


Ilustración 3. Fuente: Elaboración propia. Correlograma FAS-FAP.

Tras diferenciar y aplicar logaritmos sobre la serie conseguimos que esta sea estacionaria, tal como podemos ver a continuación:

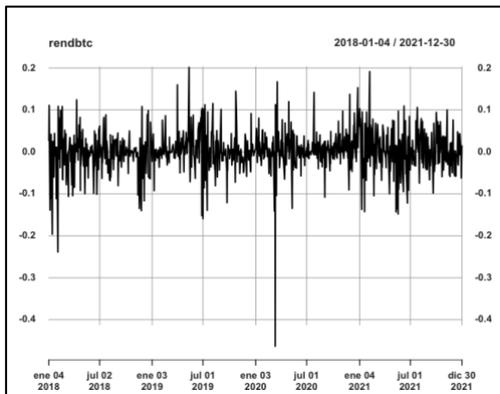


Gráfico 14. Fuente: Elaboración propia. Serie de rendimientos tras diferenciar y aplicar logaritmos.

Vemos en el gráfico de los rendimientos como la serie se ha estabilizado alrededor del 0, aunque presentando algún pico, por lo que concluimos que la serie ahora si es estacionaria y podemos ponernos a trabajar con ella estimando un modelo GARCH para luego estimar el DCC con los pares de series.

4.4. Estimación del modelo GARCH.

Previamente a la estimación del modelo DCC para cada par de series, debemos modelizar un modelo GARCH para cada una de ellas. Para ello, estimamos un GARCH(1,1), un EGARCH(1,1) y un GJR-GARCH(1,1) con distribución Normal y con distribución t-Student para cada modelo para ver cual se adapta mejor, para cada una de las series. Tras estimar todos los modelos para BTC, el resultado del criterio de información de Akaike es, respectivamente:

```
> akaike <- c(Infocriterio(m1)[1],
+           Infocriterio(m2)[1],
+           Infocriterio(m3)[1],
+           Infocriterio(m4)[1],
+           Infocriterio(m5)[1],
+           Infocriterio(m6)[1])
> akaike
[1] -3.244607 -3.515746 -8.170191 -3.237439 -3.529167 -3.249611
```

Ilustración 4. Fuente: Elaboración propia. Resultados del criterio de información de Akaike.

Como se puede ver en el output de R, el valor mínimo del criterio de información de Akaike es el que refiere al modelo 4, EGARCH(1,1) según t-Student. De todas maneras, la diferencia entre los valores de Akaike es muy pequeña por lo que se procede a analizar los residuos estandarizados y residuos estandarizados al cuadrado.

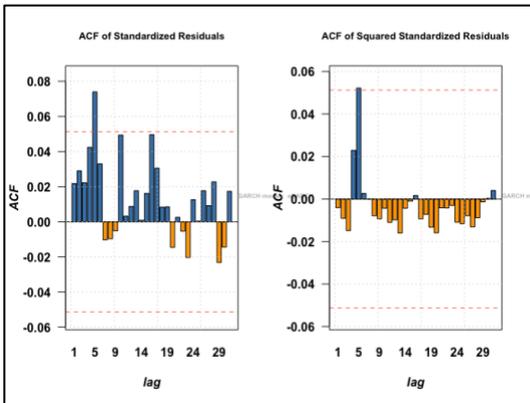
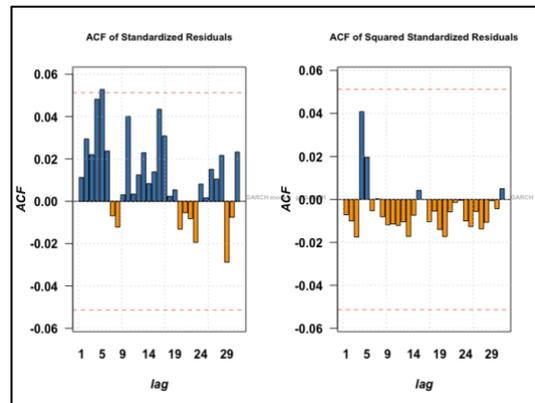


Ilustración 6. Fuente: Elaboración propia. EGARCH t-Student.



7. Fuente: Elaboración propia. GJR- GARCH t-Student.

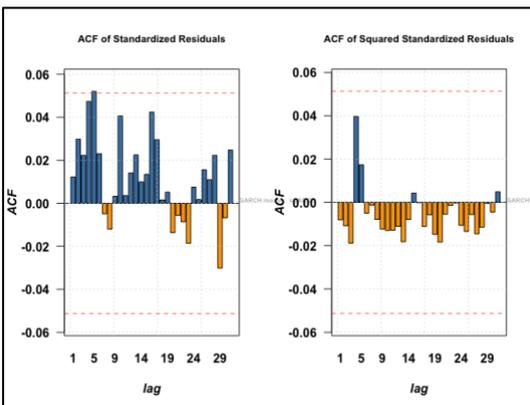


Ilustración 5. Elaboración propia. GARCH t-Student.

En la primera figura se muestra la función de autocorrelación de los residuos estandarizados para el EGARCH. Analizando el gráfico de los residuos estandarizados comprobamos que todos los retardos se encuentran dentro de los niveles de significación excepto el retardo 5, que se va fuera del intervalo, por lo que lo damos por bueno. En el gráfico de la función de auto correlación de los residuos estandarizados al cuadrado se da la misma situación con el retardo 5.

En la segunda imagen se muestra el resultado para el modelo GJR-GARCH. Se puede ver que la función de auto correlación de los residuos mejora con respecto al anterior modelo, aunque el retardo numero 5 sigue estando levemente fuera del intervalo. En el gráfico de los residuos estandarizados al cuadrado también se observa una mejora, mostrando ahora el retardo 5 dentro del intervalo.

Finalmente, en la última imagen se muestra el modelo GARCH según t-Student. Este es el que parece presentar mejor función de auto correlación de los residuos estandarizados, mejorando levemente la del GJR-GARCH. El segundo gráfico, igual que en el caso del GJR-GARCH, todos los retardos se encuentran dentro del intervalo, mostrando una mejoría respecto al EGARCH.

Para escoger el mejor modelo, atendiendo al criterio de información de Akaike, nos quedaríamos con el modelo EGARCH, que es el modelo que presenta un menor valor. En cambio, sin nos guiamos por la auto correlación que presentan los residuos y residuos al cuadrado, el modelo que escogeremos es el modelo GARCH(1,1), ya que como hemos visto mejoraba la auto correlación del retardo 5 respecto al modelo EGARCH y también, aunque de forma mucho mas leve, respecto al modelo GJR-GARCH. De manera que, considerando que el criterio que prevalece es el criterio de la auto correlación de los residuos, nos quedamos finalmente con el modelo GARCH(1,1). Este, y para evitar discrepancias en el modelo multivariante DCC, será el modelo utilizado para todas las series.

```

*-----*
*           GARCH Model Fit           *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : sGARCH(1,1)
Mean Model       : ARFIMA(0,0,0)
Distribution      : std

Optimal Parameters
-----
      Estimate  Std. Error  t value  Pr(>|t|)
mu         0.001142  0.000636  1.7973  0.072292
omega      0.000010  0.000010  1.0220  0.306772
alpha1     0.077024  0.012395  6.2139  0.000000
beta1      0.921976  0.015374  59.9710  0.000000
shape      3.362475  0.262894  12.7902  0.000000

Robust Standard Errors:
      Estimate  Std. Error  t value  Pr(>|t|)
mu         0.001142  0.000628  1.82008  0.068747
omega      0.000010  0.000021  0.48493  0.627727
alpha1     0.077024  0.011665  6.60330  0.000000
beta1      0.921976  0.023898  38.57972  0.000000
shape      3.362475  0.318433  10.55946  0.000000

LogLikelihood : 2895.005

Information Criteria
-----
Akaike        -3.9589
Bayes         -3.9408
Shibata       -3.9589
Hannan-Quinn -3.9522

```

Ilustración 8. Fuente: Elaboración propia. Resultados del modelo GARCH t-Student.

Para comprobar que el modelo escogido es válido comprobamos sus parámetros, obtenidos en R. Al ser un modelo que se distribuye según una t-Student nos fijamos en los “Optimal Parameters”. En este modelo tanto alpha como son mayores que 0 y la suma de los dos es inferior a la unidad, así pues comprobamos que se cumplen las condiciones de positividad y estacionariedad, respectivamente. El coeficiente de alpha 1 es 0.077 y el de beta es 0.92; a partir del primer dato deducimos que el modelo reacciona notablemente a los eventos del mercado, y a partir del segundo que la persistencia es elevada. Los parámetros además son significativos al nivel de significación de 0.05 ($p\text{-value} < 0.05$) y el valor del criterio de AIC es de -3.958911, como ya habíamos visto anteriormente.

Para analizar la volatilidad estimada a partir del modelo escogido, lo primero que haremos es anualizar la varianza. Tras este paso, graficamos el resultado obtenido y lo comparamos con la serie de rendimientos para ver si la volatilidad que hemos estimado reproduce los movimientos de la serie. Otra manera de corroborar si la volatilidad estimada reproduce fielmente los rendimientos es comparar dicha volatilidad con los rendimientos en valor absoluto. En los siguientes gráficos podemos ver ambas cosas:

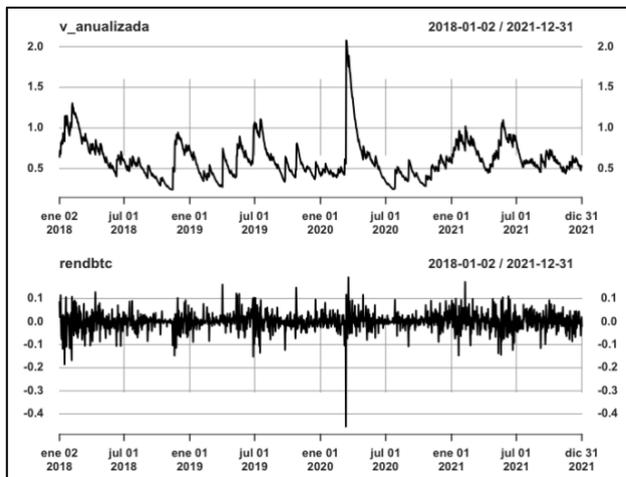


Ilustración 9. Fuente: Elaboración propia. Volatilidad anualizada.

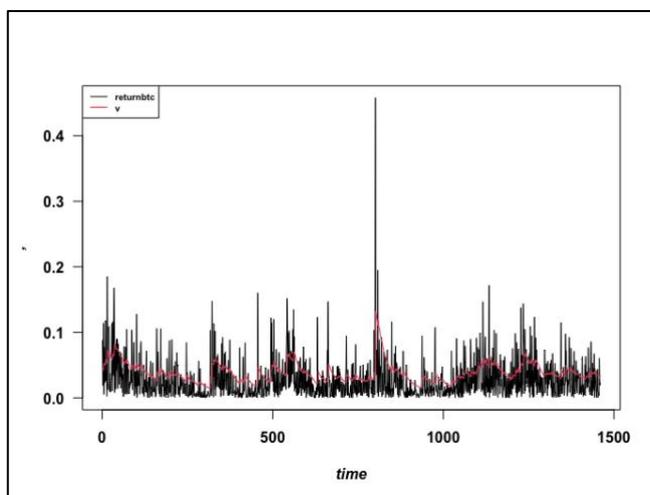


Ilustración 10. Fuente: Elaboración propia. Volatilidad anualizada.

Como podemos ver en el primer gráfico, la volatilidad estimada reproduce de manera muy correcta los movimientos de la serie de rendimientos. Al inicio de la serie de rendimientos la dispersión se ve reflejada en la volatilidad. Lo comprobamos también en los posteriores picos durante los siguientes años y, sobretodo, el pico en marzo de 2020 (coincidiendo con el inicio de la pandemia del COVID) siendo éste además el más claro, se ve descrito perfectamente en el gráfico de la volatilidad estimada. El segundo gráfico muestra como la volatilidad estimada (línea roja) sigue de manera muy aproximada todos los movimientos de la serie de rendimientos.

5. Resultados del modelo multivariante DCC.

Una vez seleccionado el modelo GARCH para las series, se procede a analizar el modelo GARCH DCC multivariado. Con el objetivo de corroborar o desmentir la hipótesis inicial, se analizan las series dos a dos tomando Bitcoin como la serie principal y de referencia, para averiguar si existe correlación entre las variables de estudio y la serie de BTC.

5.1. BTC-GLD

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.        : 1460
Log-Likelihood   : 7540.61
Av.Log-Likelihood : 5.16

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.89657	0.057885
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.52663	0.598453
[BTC.EUR.Adjusted].alpha1	0.077024	0.010573	7.28514	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023187	39.76181	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265653	12.65739	0.000000
[GC.F.Adjusted].mu	0.000226	0.000083	2.71395	0.006649
[GC.F.Adjusted].omega	0.000002	0.000003	0.59162	0.554109
[GC.F.Adjusted].alpha1	0.020070	0.010440	1.92240	0.054556
[GC.F.Adjusted].beta1	0.978930	0.000300	3265.42147	0.000000
[GC.F.Adjusted].shape	2.181063	0.032797	66.50172	0.000000
[Joint]dcca1	0.014290	0.010661	1.34038	0.180123
[Joint]dccb1	0.979643	0.010516	93.15462	0.000000

Ilustración 11. Fuente: Elaboración propia. Resultado del modelo DCC.

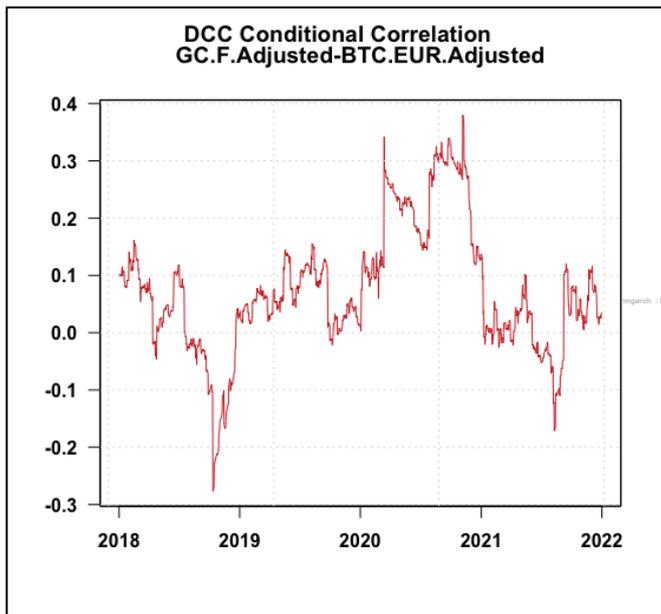


Gráfico 15. Fuente: Elaboración propia. Gráfico de correlacion condicional.

La imagen muestra la correlación condicional entre BTC y GLD. Lo que se puede observar es que en la mayor parte del periodo la correlación entre ambas es positiva, sobretodo durante el primer año de la pandemia. Esto podría significar que Bitcoin fue considerado una alternativa válida al oro como activo refugio durante este periodo. Se puede ver que hay dos tramos, al inicio y al final de la serie donde no hay correlación entre las variables, lo que implica que para estos periodos de tiempo no existiría afección de una variable sobre la otra.

5.2. BTC-GSPC

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 7629.491
Av.Log-Likelihood : 5.23

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000603	1.89436	0.058177
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.52665	0.598435
[BTC.EUR.Adjusted].alpha1	0.077024	0.010516	7.32466	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023183	39.76967	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265249	12.67670	0.000000
[GSPC.Adjusted].mu	0.000551	0.000124	4.45829	0.000008
[GSPC.Adjusted].omega	0.000003	0.000005	0.59195	0.553885
[GSPC.Adjusted].alpha1	0.130266	0.019200	6.78455	0.000000
[GSPC.Adjusted].beta1	0.868734	0.061942	14.02495	0.000000
[GSPC.Adjusted].shape	2.538757	0.153309	16.55977	0.000000
[Joint]dcca1	0.017733	0.009935	1.78499	0.074262
[Joint]dccb1	0.974091	0.017295	56.32177	0.000000

Ilustración 12. Fuente: Elaboración propia. Resultado del modelo DCC.

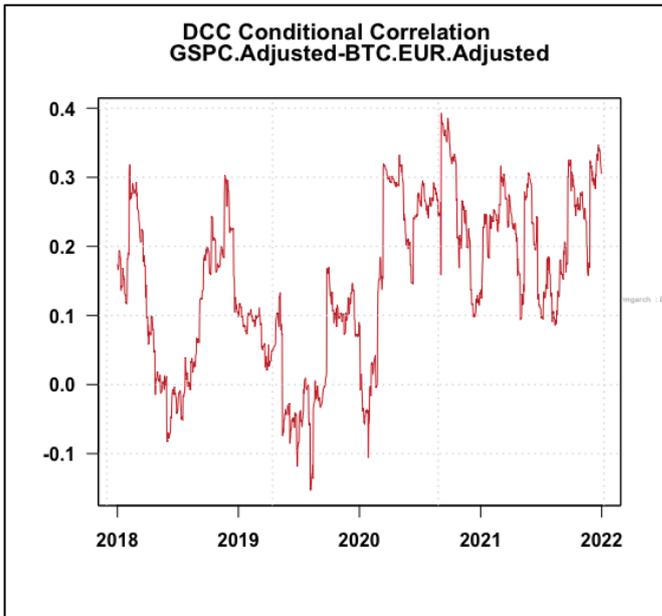


Gráfico 16. Fuente: Elaboración propia. Gráfico de correlación condicional.

La imagen anterior muestra el gráfico de correlación condicional entre Bitcoin y el mercado S&P500. Se puede ver que, hasta la mitad del horizonte temporal estudiado la correlación fluctúa bastante, existiendo periodos con correlación positiva y periodos con correlación negativa entre ambos activos. Es a partir de 2020 cuando la correlación aumenta significativamente y se mantiene positiva y alta hasta el final de la serie. Una interpretación posible es que el público confió más en la cryptomoneda que en el S&P500 como inversión durante el periodo de pandemia. De todos modos, la tendencia general que muestra el gráfico es la existencia de correlación entre las variables.

5.3. BTC-DJI

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.        : 1460
Log-Likelihood   : 7572.389
Av.Log-Likelihood : 5.19

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000603	1.89523	0.058062
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.52667	0.598426
[BTC.EUR.Adjusted].alpha1	0.077024	0.010506	7.33121	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023177	39.77915	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265642	12.65793	0.000000
[DJI.Adjusted].mu	0.000429	0.000222	1.93043	0.053554
[DJI.Adjusted].omega	0.000004	0.000020	0.19403	0.846153
[DJI.Adjusted].alpha1	0.119400	0.019892	6.00234	0.000000
[DJI.Adjusted].beta1	0.879600	0.216485	4.06309	0.000048
[DJI.Adjusted].shape	2.448874	0.464243	5.27498	0.000000
[Joint]dccal	0.019058	0.008670	2.19829	0.027928
[Joint]dccbl	0.971838	0.013516	71.90213	0.000000

Ilustración 13. Fuente: Elaboración propia. Resultado del modelo DCC.

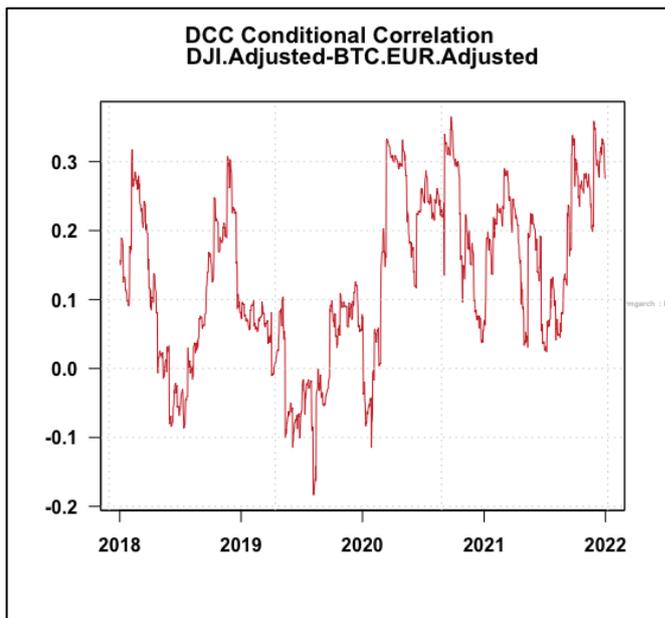


Gráfico 16. Fuente: Elaboración propia. Gráfico de correlacion condicional.

El gráfico, que muestra la correlación condicional entre Bitcoin y el Dow Jones, muestra una situación muy parecida al anterior par de variables. Durante la primera mitad del periodo hay pequeños tramos donde parece no existir correlación entre las variables, pero la mayor parte del tiempo la correlación es positiva entre ambas. También, igual que en el caso anterior, es a partir de 2020 cuando la correlación condicional entre las dos series aumenta significativamente y se mantiene positiva y alta hasta el final del periodo. Además, la tendencia parece indicar que esta correlación es creciente.

5.4. BTC-N225

```

*-----*
*          DCC GARCH Fit          *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 7154.116
Av.Log-Likelihood : 4.9

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.89624	0.057928
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.52586	0.598984
[BTC.EUR.Adjusted].alpha1	0.077024	0.010502	7.33434	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023179	39.77554	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.263765	12.74800	0.000000
[N225.Adjusted].mu	0.000194	0.000111	1.74867	0.080347
[N225.Adjusted].omega	0.000015	0.000006	2.49566	0.012572
[N225.Adjusted].alpha1	0.109766	0.048253	2.27479	0.022918
[N225.Adjusted].beta1	0.889234	0.055192	16.11160	0.000000
[N225.Adjusted].shape	2.188825	0.078511	27.87929	0.000000
[Joint]dcca1	0.003423	0.010626	0.32208	0.747390
[Joint]dccb1	0.973332	0.016271	59.82132	0.000000

Ilustración 14. Fuente: Elaboración propia. Resultado del modelo DCC.

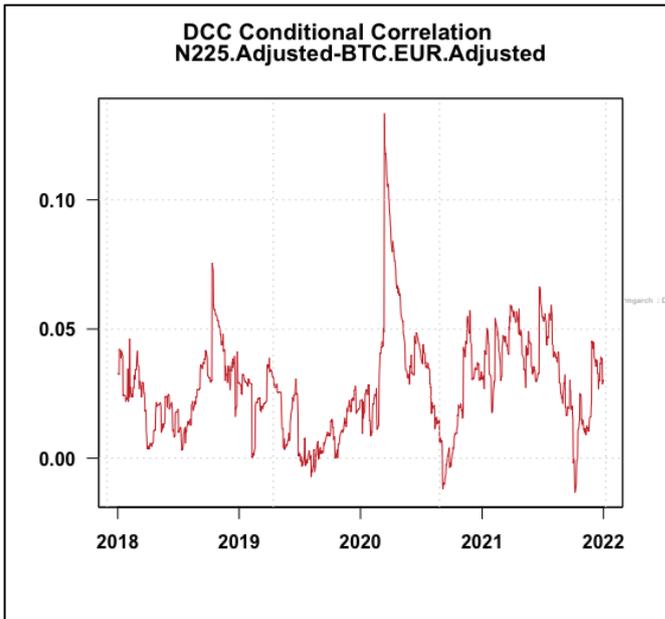


Gráfico 17. Fuente: Elaboración propia. Gráfico de correlación condicional.

En el gráfico 17 se muestra el gráfico de correlación condicional entre Bitcoin y el mercado de valores japonés Nikkei225. En este caso sorprende ver que la correlación es positiva y significativamente alta durante todo el periodo, a excepción de algunos picos de corta duración en los que la correlación se sitúa ligeramente por debajo de 0. Se puede ver como al igual que en los casos anteriores, la entrada de la pandemia propicia una correlación creciente, con un pico exponencialmente alto justo al inicio de esta. Tras este pico la correlación condicional desciende en picado llegando a ser negativa para posteriormente seguir la tendencia del periodo y estabilizarse por encima de 0. En este caso se ve una clara correlación entre ambas variables.

5.5. BTC-STOXX

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 7424.771
Av.Log-Likelihood : 5.09

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.89726	0.057794
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.52574	0.599071
[BTC.EUR.Adjusted].alpha1	0.077024	0.010501	7.33476	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023197	39.74614	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265173	12.68032	0.000000
[STOXX50E.Adjusted].mu	0.000437	0.000108	4.03167	0.000055
[STOXX50E.Adjusted].omega	0.000008	0.000001	5.39954	0.000000
[STOXX50E.Adjusted].alpha1	0.126683	0.020977	6.03911	0.000000
[STOXX50E.Adjusted].beta1	0.872317	0.034976	24.94038	0.000000
[STOXX50E.Adjusted].shape	2.291205	0.081608	28.07564	0.000000
[Joint]dccal	0.008285	0.006695	1.23748	0.215910
[Joint]dccbl	0.964138	0.021949	43.92535	0.000000

Ilustración 15. Fuente: Elaboración propia. Resultado del modelo DCC.

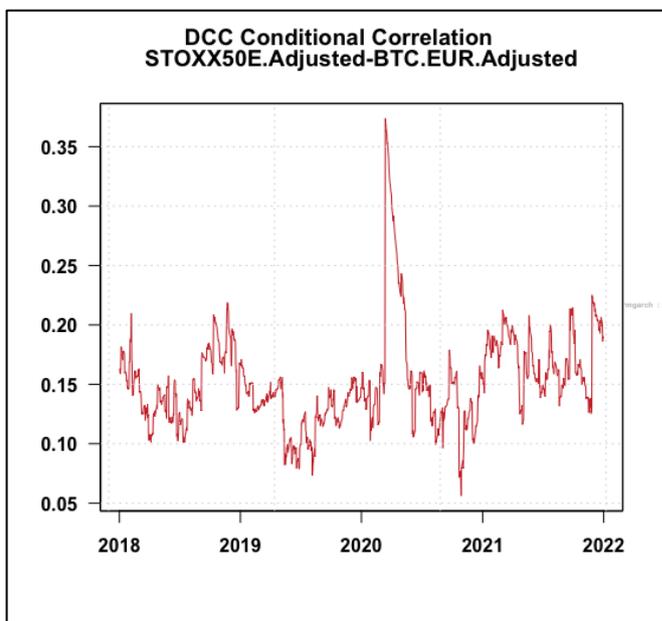


Gráfico 18. Fuente: Elaboración propia. Gráfico de correlación condicional.

El caso de la correlación entre el mercado de valores europeo Eurostoxx50 y la serie de Bitcoin es el mas claro hasta el momento. Presenta una correlación notablemente alta, que se mantiene durante todo el periodo. En este caso no hay ningún momento en el que la correlación pase a ser negativa. También se observa un máximo a inicios de 2020, tras el

cual la correlación cae y se mantiene en niveles sobre el 0.15 hasta el final del periodo. Este caso es el que muestra de manera más clara la correlación entre las variables.

5.6. BTC-EURODOL

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 8873.005
Av.Log-Likelihood : 6.08

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.897900	0.057709
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.520510	0.602708
[BTC.EUR.Adjusted].alpha1	0.077024	0.010505	7.332260	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023327	39.524480	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.267249	12.581813	0.000000
[EURUSD.X.Adjusted].mu	-0.000014	0.000055	-0.257883	0.796497
[EURUSD.X.Adjusted].omega	0.000000	0.000002	0.067867	0.945891
[EURUSD.X.Adjusted].alpha1	0.022128	0.015316	1.444806	0.148512
[EURUSD.X.Adjusted].beta1	0.976255	0.006059	161.131679	0.000000
[EURUSD.X.Adjusted].shape	2.673855	0.975143	2.742014	0.006106
[Joint]dcca1	0.040733	0.034479	1.181394	0.237446
[Joint]dccb1	0.638523	0.176378	3.620200	0.000294

Ilustración 16. Fuente: Elaboración propia. Resultado del modelo DCC.

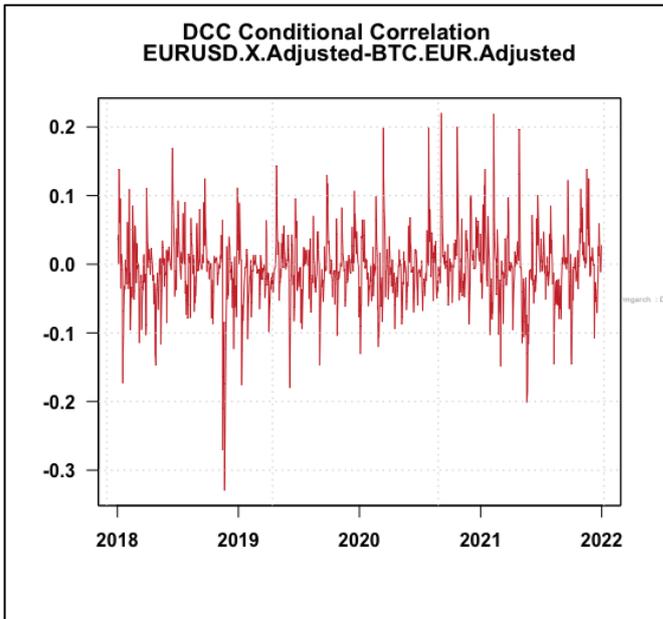


Gráfico 19. Fuente: Elaboración propia. Gráfico de correlacion condicional.

Tras analizar los mercados de valores y la serie del oro, empezamos el análisis de correlaciones con los tipos de cambio. Curiosamente, entre el tipo de cambio EURO-USD y BTC no parece haber correlación. Se puede observar que la tendencia se sitúa claramente sobre el 0, con cantidad de valores positivos y negativos durante el periodo. Tampoco se ve que en los inicios de 2020 hubiera cambios en la tendencia de la correlación, ni tampoco ningún pico significativo. Descartaríamos pues que hubiese correlación entre estas variables.

5.7. BTC-EUROCNV

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 8321.28
Av.Log-Likelihood : 5.7

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.896560	0.057886
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.526240	0.598721
[BTC.EUR.Adjusted].alpha1	0.077024	0.010503	7.333237	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023188	39.760883	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265268	12.675756	0.000000
[EURCNY.X.Adjusted].mu	-0.000035	0.000049	-0.719808	0.471643
[EURCNY.X.Adjusted].omega	0.000041	0.000006	6.326633	0.000000
[EURCNY.X.Adjusted].alpha1	0.999000	0.182032	5.488039	0.000000
[EURCNY.X.Adjusted].beta1	0.000000	0.096464	0.000000	1.000000
[EURCNY.X.Adjusted].shape	2.151197	0.023031	93.404925	0.000000
[Joint]dcca1	0.000000	0.000137	0.000115	0.999908
[Joint]dccb1	0.954366	0.176148	5.417984	0.000000

Ilustración 17. Fuente: Elaboración propia. Resultado del modelo DCC.

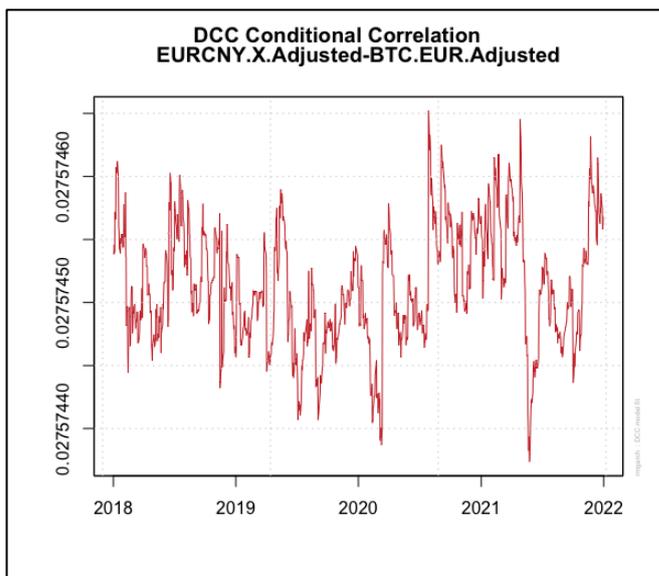


Gráfico 20. Fuente: Elaboración propia. Gráfico de correlacion condicional.

En esta imagen se muestra la correlación condicional entre BTC y el tipo de cambio EUR-YUAN. Contrariamente al caso anterior, la tendencia ahora se mantiene ligeramente por encima de 0 durante todo el periodo. Si bien parece existir correlación entre estas variables, ésta es leve. Se observa en este caso un cambio en la tendencia a partir de la entrada de la pandemia, donde pasa de seguir una tendencia ligeramente decreciente a creciente. A mediados de 2021 se observa el pico más bajo de correlación, aunque vuelve al seguir la tendencia anterior al final de la serie.

5.8. BTC-EUROGBP

```

*-----*
*           DCC GARCH Fit           *
*-----*

Distribution      : mvnorm
Model            : DCC(1,1)
No. Parameters   : 13
[VAR GARCH DCC UncQ] : [0+10+2+1]
No. Series       : 2
No. Obs.         : 1460
Log-Likelihood   : 8390.432
Av.Log-Likelihood : 5.75

Optimal Parameters
-----

```

	Estimate	Std. Error	t value	Pr(> t)
[BTC.EUR.Adjusted].mu	0.001142	0.000602	1.896564	0.057886
[BTC.EUR.Adjusted].omega	0.000010	0.000020	0.526216	0.598738
[BTC.EUR.Adjusted].alpha1	0.077024	0.010503	7.333668	0.000000
[BTC.EUR.Adjusted].beta1	0.921976	0.023188	39.761227	0.000000
[BTC.EUR.Adjusted].shape	3.362475	0.265261	12.676088	0.000000
[EURGBP.X.Adjusted].mu	-0.000044	0.000050	-0.883736	0.376839
[EURGBP.X.Adjusted].omega	0.000002	0.000000	7.122707	0.000000
[EURGBP.X.Adjusted].alpha1	0.073873	0.008490	8.701285	0.000000
[EURGBP.X.Adjusted].beta1	0.925127	0.021859	42.321670	0.000000
[EURGBP.X.Adjusted].shape	2.159310	0.049586	43.546437	0.000000
[Joint]dcca1	0.000000	0.000095	0.000161	0.999872
[Joint]dccb1	0.929485	0.250587	3.709228	0.000208

Ilustración 18. Fuente: Elaboración propia. Resultado del modelo DCC.

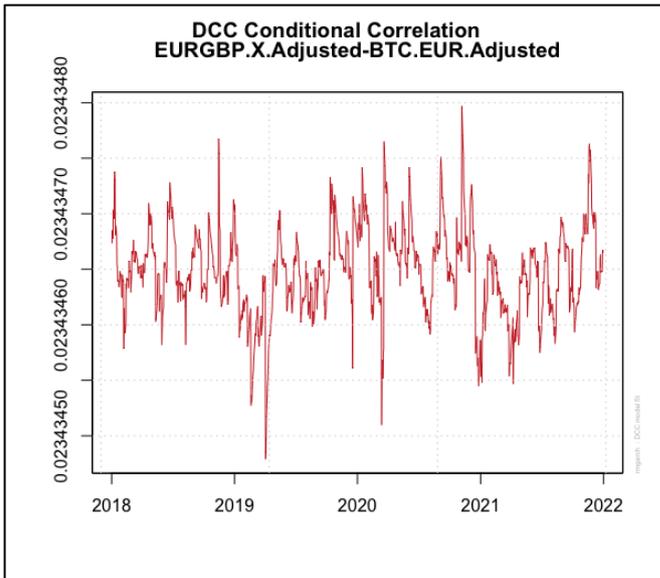


Gráfico 21. Fuente: Elaboración propia. Gráfico de correlación condicional.

En el caso de la correlación condicional entre el euro y la libra esterlina, sigue un patrón similar al caso de la moneda china. Se observa una correlación positiva a lo largo de todo el periodo, pero esta vez lo parece que exista una tendencia creciente o decreciente, sino que parece mantenerse notablemente estable. No parece que la pandemia haya afectado mucho a la correlación condicional entre ambas variables, manteniéndose en niveles constantes hasta el final del horizonte temporal. Existe pues correlación entre las variables.

6. Factor de Inflación de la Varianza (FIV)

El Factor de Inflación de la varianza FIV (comúnmente conocido como VIF por sus siglas en inglés) es una herramienta estadística que permite encontrar multicolinealidad entre las variables de un modelo de regresión. La multicolinealidad ocurre cuando dos o más predictores se correlacionan entre sí, alterando los resultados del modelo. Para finalizar el trabajo aplicaremos este método estadístico para ver si, teniendo en cuenta los análisis previos, sería posible crear un modelo predictivo sobre la volatilidad de Bitcoin teniendo en cuenta las variables anteriormente analizadas. Esto proporcionaría futuras líneas de investigación para ampliar este trabajo y aportar un componente predictivo, y no solo analítico.

Para este análisis, primero es necesario crear el modelo conjunto con Bitcoin como variable principal, y todas las demás series estudiadas como variables explicativas de la primera. Los parámetros obtenidos en R del modelo se muestran en la tabla siguiente. Tras aplicar la función `vif()` de R se obtiene el siguiente output.

```

> summary(model123)

Call:
lm(formula = rendbtc ~ rendgld + rendgspc + renddji + rendn225 +
    rendstoxx + rendeurdol + rendeurency + rendeurgbp, data = rX123)

Residuals:
    Min       1Q   Median       3Q      Max
-0.33727 -0.01769  0.00072  0.01843  0.16813

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.0004793  0.0010178   0.471  0.63781
rendgld      0.3633078  0.1284116   2.829  0.00473 **
rendgspc     1.1096471  0.3827293   2.899  0.00380 **
renddji      -0.6286470  0.3732212  -1.684  0.09232 .
rendn225     -0.2325657  0.1109615  -2.096  0.03626 *
rendstoxx    0.5850917  0.1323154   4.422 1.05e-05 ***
rendeurdol  -0.6006422  0.4261804  -1.409  0.15894
rendeurency  0.3190679  0.3818751   0.836  0.40356
rendeurgbp   0.3305278  0.2785339   1.187  0.23555
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.0388 on 1451 degrees of freedom
Multiple R-squared:  0.071,    Adjusted R-squared:  0.06588
F-statistic: 13.86 on 8 and 1451 DF,  p-value: < 2.2e-16

```

Ilustración 19. Fuente: Elaboración propia. Resultado de la regresión.

Para este modelo parece que las variables referidas a los tipos de cambio no son significativas, mientras que tanto el oro, el S&P500, el NIKKEI225 sí lo son. El valor “r cuadrado” del modelo es de 0.071 y el p-value indica que el modelo es válido. Aplicando la función “vif()” se obtiene el resultado:

```

> vif_values
    rendgld  rendgspc  renddji  rendn225  rendstoxx  rendeurdol  rendeurency  rendeurgbp
1.014988  17.732857  18.527080  1.241134  1.910447  2.044851  2.048178  1.097322

```

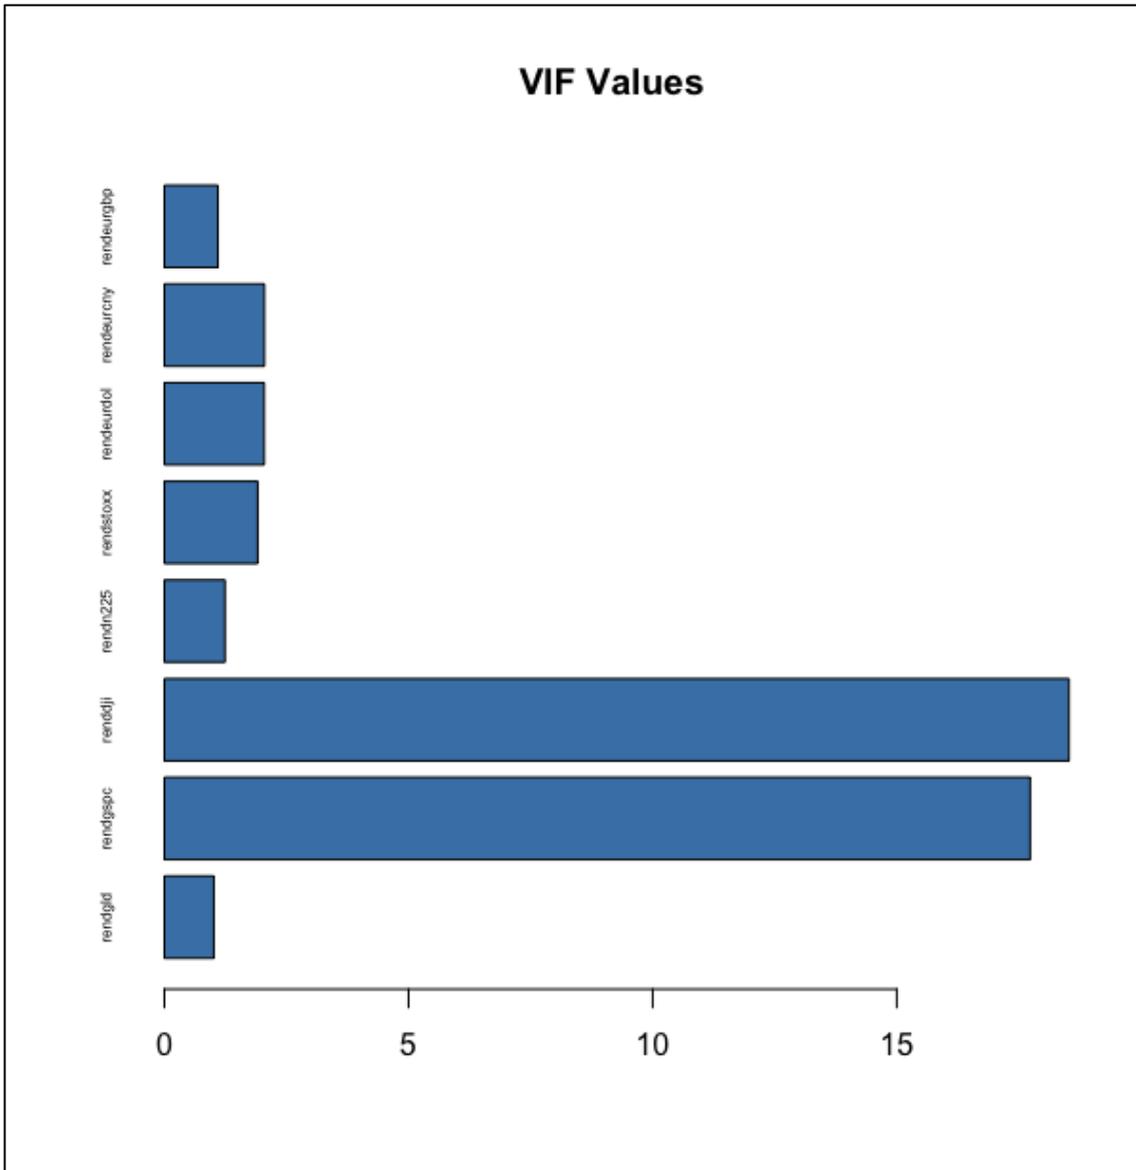


Gráfico 22. Fuente: Elaboración propia. Valores del VIF.

El output de R muestra que los valores de las variables `rendgspc` y `rendji` están por encima de 10, lo que supone un problema serio para el modelo por la presencia notable de correlación de estas variables con las demás. Eso supone que, si no se extraen del modelo, los resultados obtenidos tanto en la regresión como en cálculos posteriores serán de escasa fiabilidad.

7. Conclusiones, limitaciones y futuras líneas de investigación

En la primera parte del trabajo se ha realizado un análisis gráfico sobre el impacto de las noticias en la volatilidad del Bitcoin. Tras analizar por periodos de 1 año la serie, comparándolos con las tablas obtenidas a partir de la base de datos de noticias y las palabras clave seleccionadas, este apartado concluía que efectivamente parecía existir relación entre las noticias y la cryptomoneda estudiada. Se comprobaba gráficamente que, en los días donde varias palabras clave coincidían en las noticias de prensa, la volatilidad de la serie aumentaba notablemente.

Posteriormente, gracias a los modelos DCC-GARCH se ha podido comprobar este hecho estadísticamente. Los gráficos de correlación condicional entre los pares de series muestran que, durante la mayor parte del tiempo y dentro del horizonte temporal de estudio, existe correlación entre ellas. Esto indica un claro impacto de la variable explicativa sobre la volatilidad de la principal, confirmando así la hipótesis inicial. Cabe decir que la mayoría de los resultados de los modelos DCC-GARCH visualizados, muestran que el parámetro “ $dcca1$ ” no es significativo bajo el criterio del p-value, situación que podría arreglarse con una base de dato más amplia.

Finalmente, en el análisis final del VIF se ha creado un modelo conjunto para comprobar si, en caso de querer realizar predicciones con el modelo en estudios posteriores, sería correcto utilizar las variables analizadas en este trabajo. Los valores resultantes del VIF indican que las variables GSPC y DJI muestran problemas de autocorrelación, por lo que habría que eliminarlas del modelo. Esto se debe a que estas dos variables ya están explicadas por las demás, por lo que no solo no es necesario su uso para la predicción, sino que mantenerlas en el modelo generaría errores en los resultados.

8. Anexos

8.2. Código R

```
#####  
  
#Instalacion de packages y libraries#  
  
#####  
  
# install.packages("rmgarch")  
# install.packages("tseries")  
# install.packages("fBasics")  
# install.packages("car")  
# install.packages("urca")  
# install.packages("ggcorrplot")  
# install.packages("corrplot")  
# install.packages("forecast")  
# install.packages("fGarch")  
# install.packages("rugarch")  
# install.packages("quantmod")  
# install.packages("ggplot2")  
# install.packages("lubridate")  
# install.packages("readxl")  
# install.packages("corr")  
# install.packages("rvest")  
# install.packages("httr")  
# install.packages("tidyverse")  
# install.packages("dplyr")  
# install.packages("writexl")  
# install.packages("data.table")
```

```
# install.packages("stringr")

library(readxl)
library(writexl)
library(rmgarch)
library(fBasics)
library(tseries)
library(car)
library(urca)
library(forecast)
library(fGarch)
library(rugarch)
library(quantmod)
library(ggplot2)
library(lubridate)
library(ggcorrplot)
library(corrplot)
library(corr)
library(rvest)
library(httr)
library(tidyverse)
library(dplyr)
library(data.table)
library(stringr)

ruta_tfm <- "/Users/felix/Desktop/TFM"
```

```
#####
```

```
### NOTICIAS ###
```

```
#####
```

```
bbdd_noticias <- read_xlsx(path=paste0(ruta_tfm,"/BBDD_NOTICIAS.xlsx"),sheet="NOTICIAS")  
>%>% as.data.table()
```

```
bbdd_noticias[,FECHA:=as_date(FECHA)]
```

```
bbdd_noticias[,TITULAR:=str_to_lower(TITULAR)]
```

```
bbdd_noticias[,CAMPO:=str_to_lower(CAMPO)]
```

```
class(bbdd_noticias$FECHA)
```

```
bbdd_noticias$CRISIS <- 0
```

```
bbdd_noticias$BITCOIN <- 0
```

```
bbdd_noticias$ETHEREUM <- 0
```

```
bbdd_noticias$BOLSA <- 0
```

```
bbdd_noticias$FED <- 0
```

```
bbdd_noticias$BCE <- 0
```

```
bbdd_noticias$CRIPTO <- 0
```

```
bbdd_noticias$MUSK <- 0
```

```
bbdd_noticias$DOLAR <- 0
```

```
bbdd_noticias$EURO <- 0
```

```
bbdd_noticias$YUAN <- 0
```

```
bbdd_noticias$TIPOS <- 0
```

```
bbdd_noticias$MERCADOS <- 0
```

```
bbdd_noticias$LIQUIDEZ <- 0
```

```
bbdd_noticias$DIGITAL <- 0
```

```
bbdd_noticias$ORO <- 0
```

```
bbdd_noticias$IBEX <- 0
```

```
bbdd_noticias$SP500 <- 0
```

```
bbdd_noticias$JONES <- 0
```

```
bbdd_noticias$NIKKEI <- 0
```

```
bbdd_noticias$DAX <- 0
```

```
bbdd_noticias$EUROSTOXX <- 0
```

```
bbdd_noticias$CRISIS <- case_when(grepl("crisis",bbdd_noticias$TITULAR)~ 1,  
    grepl("recesion",bbdd_noticias$TITULAR)~ 1,  
    grepl("crisis",bbdd_noticias$CAMPO)~ 1,  
    grepl("recesion",bbdd_noticias$CAMPO)~ 1,  
    TRUE~0)
```

```
bbdd_noticias$BITCOIN <- case_when(grepl("bitcoin",bbdd_noticias$TITULAR)~ 1,  
    grepl("bitcoin",bbdd_noticias$CAMPO)~ 1,  
    TRUE~0)
```

```
bbdd_noticias$ETHEREUM <- case_when(grepl("ethereum",bbdd_noticias$TITULAR)~ 1,  
    grepl("ethereum",bbdd_noticias$CAMPO)~ 1,  
    TRUE~0)
```

```
bbdd_noticias$BOLSA <- case_when(grepl("bolsa",bbdd_noticias$TITULAR)~ 1,  
    grepl("bolsa",bbdd_noticias$CAMPO)~ 1,  
    TRUE~0)
```

```
bbdd_noticias$FED <- case_when(grepl("fed",bbdd_noticias$TITULAR)~ 1,  
    grepl("fed",bbdd_noticias$CAMPO)~ 1,  
    TRUE~0)
```

```
bbdd_noticias$BCE <- case_when(grepl("bce",bbdd_noticias$TITULAR)~ 1,
```

```

grepl("bce",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$CRIPTO <- case_when(grepl("cripto",bbdd_noticias$TITULAR)~ 1,
grepl("cripto",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$MUSK <- case_when(grepl("musk",bbdd_noticias$TITULAR)~ 1,
grepl("musk",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$DOLAR <- case_when(grepl("dolar",bbdd_noticias$TITULAR)~ 1,
grepl("dolar",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$EURO <- case_when(grepl("euro",bbdd_noticias$TITULAR)~ 1,
grepl("euro",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$YUAN <- case_when(grepl("yuan",bbdd_noticias$TITULAR)~ 1,
grepl("yuan",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$TIPOS <- case_when(grepl("tipos",bbdd_noticias$TITULAR)~ 1,
grepl("tipos",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$MERCADOS <- case_when(grepl("mercados",bbdd_noticias$TITULAR)~ 1,
grepl("mercados",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$LIQUIDEZ <- case_when(grepl("liquidez",bbdd_noticias$TITULAR)~ 1,
grepl("liquidez",bbdd_noticias$CAMPO)~ 1,
TRUE~0)
bbdd_noticias$DIGITAL <- case_when(grepl("digital",bbdd_noticias$TITULAR)~ 1,

```

```

    grepl("digital",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$ORO <- case_when(grepl("oro",bbdd_noticias$TITULAR)~ 1,
    grepl("oro",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$IBEX <- case_when(grepl("ibex",bbdd_noticias$TITULAR)~ 1,
    grepl("ibex",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$SP500 <- case_when(grepl("poors",bbdd_noticias$TITULAR)~ 1,
    grepl("s&p",bbdd_noticias$TITULAR)~ 1,
    grepl("poors",bbdd_noticias$CAMPO)~ 1,
    grepl("s&p",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$JONES <- case_when(grepl("jones",bbdd_noticias$TITULAR)~ 1,
    grepl("jones",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$NIKKEI <- case_when(grepl("nikkei",bbdd_noticias$TITULAR)~ 1,
    grepl("nikkei",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$DAX <- case_when(grepl("dax",bbdd_noticias$TITULAR)~ 1,
    grepl("dax",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias$EUROSTOXX <- case_when(grepl("stox",bbdd_noticias$TITULAR)~ 1,
    grepl("stox",bbdd_noticias$CAMPO)~ 1,
    TRUE~0)
bbdd_noticias[,TABLA:=CRISIS+BITCOIN+ETHEREUM+BOLSA+FED+BCE+CRIPTO+MUSK+DOLAR
+EURO+YUAN+TIPOS+MERCADOS+LIQUIDEZ+DIGITAL+ORO+IBEX+SP500+JONES+NIKKEI+DAX+
EUROSTOXX]

```

```
table(bbdd_noticias$TABLA)
```

```
#BITCOIN EUR
```

```
getSymbols("BTC-EUR",  
           from="2018-01-01",  
           to="2021-12-31")
```

```
BTC <- `BTC-EUR`[,6]
```

```
class(BTC)
```

```
dim(BTC)
```

```
head(BTC)
```

```
tail(BTC)
```

```
#Por si hay datos non-available, o los sustituimos por la observación anterior
```

```
btc<-na.locf(BTC, fromLast = FALSE)
```

```
length(btc)
```

```
plot(btc)
```

```
btc1 <- btc[0:241]
```

```
btc2 <- btc[242:468]
```

```
btc3 <- btc[469:697]
```

```
btc4 <- btc[698:931]
```

```
plot(btc1)
```

```
plot(btc2)
```

```
plot(btc3)
```

```
plot(btc4)
```

bbdd_noticias[TABLA>=5&FECHA<="2018/12/31",.(FECHA,TABLA)]

bbdd_noticias[TABLA>=5&FECHA>="2019/01/01"&FECHA<="2019/12/31",.(FECHA,TABLA)]

bbdd_noticias[TABLA>=5&FECHA>="2020/01/01"&FECHA<="2020/12/31",.(FECHA,TABLA)]

bbdd_noticias[TABLA>=5&FECHA>="2021/01/01"&FECHA<="2021/12/31",.(FECHA,TABLA)]

bbdd_noticias

bbdd_noticias[,.(sum(CRISIS))]

bbdd_noticias[,.(sum(BITCOIN))]

bbdd_noticias[,.(sum(ETHEREUM))]

bbdd_noticias[,.(sum(BOLSA))]

bbdd_noticias[,.(sum(FED))]

bbdd_noticias[,.(sum(BCE))]

bbdd_noticias[,.(sum(CRIPTO))]

bbdd_noticias[,.(sum(MUSK))]

bbdd_noticias[,.(sum(DOLAR))]

bbdd_noticias[,.(sum(EURO))]

bbdd_noticias[,.(sum(YUAN))]

bbdd_noticias[,.(sum(TIPOS))]

bbdd_noticias[,.(sum(MERCADOS))]

bbdd_noticias[,.(sum(LIQUIDEZ))]

bbdd_noticias[,.(sum(DIGITAL))]

bbdd_noticias[,.(sum(ORO))]

bbdd_noticias[,.(sum(IBEX))]

bbdd_noticias[,.(sum(SP500))]

bbdd_noticias[,.(sum(JONES))]

bbdd_noticias[,.(sum(NIKKEI))]

```

bbdd_noticias[,.(sum(DAX))]

bbdd_noticias[,.(sum(EUROSTOXX))]

#####
#####

#GOLD USD

getSymbols("GC=F",
           from="2018-01-01",
           to="2021-12-31",)

GLD <- `GC=F`[,6]

class(GLD)

dim(GLD)

head(GLD)

tail(GLD)

#Por si hay datos non-available, o los sustituimos por la observación anterior

gld<-na.locf(GLD, fromLast = FALSE)

length(gld)

plot(gld)

#SP500 USD

getSymbols("^GSPC",
           from="2018-01-01",
           to="2021-12-31",)

GSPC <- `GSPC`[,6]

class(GSPC)

dim(GSPC)

head(GSPC)

tail(GSPC)

```

```
#Por si hay datos non-available, o los sustituimos por la observación anterior
```

```
gspc<-na.locf(GSPC, fromLast = FALSE)
```

```
length(gspc)
```

```
plot(gspc)
```

```
#DOWJONES USD
```

```
getSymbols("^DJI",
```

```
    from="2018-01-01",
```

```
    to="2021-12-31",)
```

```
DJI <- DJI[,6]
```

```
class(DJI)
```

```
dim(DJI)
```

```
head(DJI)
```

```
tail(DJI)
```

```
#Por si hay datos non-available, o los sustituimos por la observación anterior
```

```
dji<-na.locf(DJI, fromLast = FALSE)
```

```
length(dji)
```

```
plot(dji)
```

```
#NIKKEI 225 JPY
```

```
getSymbols("^N225",
```

```
    from="2018-01-01",
```

```
    to="2021-12-31",)
```

```
N225 <- N225[,6]
```

```
class(N225)
```

```
dim(N225)
```

```
head(N225)
```

```
tail(N225)
```

```
#Por si hay datos non-available, o los sustituimos por la observación anterior
```

```
n225<-na.locf(N225, fromLast = FALSE)
```

```
length(n225)
```

```
plot(n225)
```

```
#EUROSTOXX 50 EUR
```

```
getSymbols("^STOXX50E",
```

```
    from="2018-01-01",
```

```
    to="2021-12-31",)
```

```
STOXX <- STOXX50E[,6]
```

```
class(STOXX)
```

```
dim(STOXX)
```

```
head(STOXX)
```

```
tail(STOXX)
```

```
#Por si hay datos non-available, o los sustituimos por la observación anterior
```

```
stoxx<-na.locf(STOXX, fromLast = FALSE)
```

```
length(stoxx)
```

```
plot(stoxx)
```

```
#EURO-DOLAR
```

```
getSymbols("EURUSD=X",
```

```
    from="2018-01-01",
```

```
    to="2021-12-31",)
```

```
EUR_DOL <- `EURUSD=X`[,6]
```

```

class(EUR_DOL)
dim(EUR_DOL)
head(EUR_DOL)
tail(EUR_DOL)

#Por si hay datos non-available, o los sustituimos por la observación anterior
eurdol<-na.locf(EUR_DOL, fromLast = FALSE)

length(eurdol)

plot(eurdol)

```

```
#EURO-YUAN CHINO
```

```

getSymbols("EURCNY=X",
           from="2018-01-01",
           to="2021-12-31",)

```

```
EUR_CNY <- `EURCNY=X`[,6]
```

```

class(EUR_CNY)
dim(EUR_CNY)
head(EUR_CNY)
tail(EUR_CNY)

```

```

#Por si hay datos non-available, o los sustituimos por la observación anterior
eurcny<-na.locf(EUR_CNY, fromLast = FALSE)

length(eurcny)

plot(eurcny)

```

```
#EURO_GBP
```

```

getSymbols("EURGBP=X",
           from="2018-01-01",
           to="2021-12-31",)

```

```

EUR_GBP <- `EURGBP=X`[,6]

class(EUR_GBP)

dim(EUR_GBP)

head(EUR_GBP)

tail(EUR_GBP)

#Por si hay datos non-available, o los sustituimos por la observación anterior

eurgbp<-na.locf(EUR_GBP, fromLast = FALSE)

length(eurgbp)

plot(eurgbp)

BBDD <- merge(btc,gld,gspc,dji,n225,stoxx,eurdol,eurcny,eurgbp)

# delete.na <- function(df, n=0) {
# df[rowSums(is.na(df)) <= n,]
# }

# bbdd <- delete.na(BBDD)

btc <- BBDD[,1]

gld <- BBDD[,2]

gspc <- BBDD[,3]

dji <- BBDD[,4]

n225 <- BBDD[,5]

stoxx <- BBDD[,6]

eurdol <- BBDD[,7]

eurcny <- BBDD[,8]

```

```
eurgbp <- BBDD[,9]
```

```
btc<-na.locf(btc, fromLast = FALSE)
```

```
head(btc)
```

```
tail(btc)
```

```
gld<-na.locf(gld, fromLast = FALSE)
```

```
head(gld)
```

```
tail(gld)
```

```
gld[1] <- gld[2]
```

```
gspc<-na.locf(gspc, fromLast = FALSE)
```

```
head(gspc)
```

```
tail(gspc)
```

```
gspc[1] <- gspc[2]
```

```
dji<-na.locf(dji, fromLast = FALSE)
```

```
head(dji)
```

```
tail(dji)
```

```
dji[1] <- dji[2]
```

```
n225<-na.locf(n225, fromLast = FALSE)
```

```
head(n225)
```

```
tail(n225)
```

```
n225[1:3] <- n225[4]
```

```
stoxx<-na.locf(stoxx, fromLast = FALSE)
```

```
head(stoxx)
```

```
tail(stoxx)
```

```
stoxx[1:2] <- stoxx[3]
```

```
eurdol<-na.locf(eurdol, fromLast = FALSE)
```

```
head(eurdol)
```

```
tail(eurdol)
```

```
eurcny<-na.locf(eurcny, fromLast = FALSE)
```

```
head(eurcny)
```

```
tail(eurcny)
```

```
eurgbp<-na.locf(eurgbp, fromLast = FALSE)
```

```
head(gld)
```

```
tail(gld)
```

```
c(length(btc),length(gld),length(gspc),length(dji),length(n225),
```

```
length(stoxx),length(eurdol),length(eurcny),length(eurgbp))
```

```
plot(btc, col="purple", main="btc_daily_price")
```

```
plot(gld, col="yellow", main="gld_daily_price")
```

```
plot(gspc, col="green", main="gspc_daily_price")
```

```
plot(dji, col="blue", main="dji_daily_price")
```

```
plot(n225, col="red", main="n225_daily_price")
```

```
plot(stoxx, col="orange", main="stoxx_daily_price")
```

```
plot(eurdol, col="dark blue", main="eur_dol_daily_price")
```

```
plot(eurcny, col="brown", main="eur_cny_daily_price")
```

```
plot(eurgbp, col="dark green", main="eur_gbp_daily_price")
```

```
#ESTIMACION DEL MODELO GARCH Y DIAGNOSIS
```

```
#####
```

```
### BTC ###
```

```
#####
```

```
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
```

```
acf(btc,ylim=c(-1,1),main="BTC")
```

```
pacf(btc,ylim=c(-1,1),main="BTC")
```

```
##LA SERIE NO ES ESTACIONARIA, ACF DECRECE LENTAMENTE
```

```
##Y 1 PICO DE VALOR 1 EN LA PACF
```

```
Box.test(btc, lag = 1, type = c("Ljung-Box"))
```

```
Box.test(btc, lag = 5, type = c("Ljung-Box"))
```

```
Box.test(btc, lag = 10, type = c("Ljung-Box"))
```

```
Box.test(btc, lag = 15, type = c("Ljung-Box"))
```

```
Box.test(btc, lag = 20, type = c("Ljung-Box"))
```

```
#COMPROBAMOS CON EL LJUNG-BOX TEST QUE NO ES ESTACIONARIA
```

```
rendbtc=diff(log(btc))
```

```
par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)
```

```
plot(rendbtc) #es estacionaria en media pero existen algunos picos
```

```
rendbtc<-rendbtc[-1] #eliminamos la primera observacion que ahora es NA porque si no, el  
contraste da un error
```

```

rendbtc.df<-ur.df(rendbtc, type = c("trend"), lags=20, selectlags = c("BIC"))

summary(rendbtc.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA

# TESTS GARCH Y FASE1 DE IDENTIFICACION DEL MODELO GARCH

#ruido blanco

model = arima(rendbtc, order = c(0,0,0),include.mean = TRUE)

model

# ACF y PACF de los residuos al cuadrado

residuos=model$residuals

residuos2=residuos^2

par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)

acf(residuos2,ylim=c(-1,1),main="residuos al cuadrado")

pacf(residuos2,ylim=c(-1,1),main="residuos al cuadrado")

#hay bastantes coeficientes por encima del nivel de significación

Box.test(residuos2,lag=1,type='Ljung')

Box.test(residuos2,lag=5,type='Ljung')

Box.test(residuos2,lag=15,type='Ljung')

Box.test(residuos2,lag=20,type='Ljung')

#rechazamos H0 de que la varianza es constante

# RUIDO BLANCO-GARCH(1,1) con distribucion Normal

spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(0,0)), distribution.model = "norm")

m1=ugarchfit(spec=spec1,data=rendbtc)

m1

```

```
#t-Student
```

```
#estimamos el mismo modelo pero ahora con T-Student.
```

```
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),  
mean.model=list(armaOrder=c(0,0)), distribution.model = "std")
```

```
m2=ugarchfit(spec=spec1,data=rendbtc)
```

```
m2
```

```
#Egarch
```

```
#distribuci?n normal
```

```
spec1=ugarchspec(variance.model=list(model="eGARCH", garchOrder =  
c(1,1)),mean.model=list(armaOrder=c(0,0)), distribution.model = "norm")
```

```
m3=ugarchfit(spec=spec1,data=rendbtc)
```

```
m3
```

```
#distribuci?n t-student
```

```
spec1=ugarchspec(variance.model=list(model="eGARCH", garchOrder = c(1,1)),  
mean.model=list(armaOrder=c(0,0)), distribution.model = "std")
```

```
m4=ugarchfit(spec=spec1,data=rendbtc)
```

```
m4
```

```
#GJR-GARCH model
```

```
# distribuci?n normal
```

```
spec1=ugarchspec(variance.model=list(model="gjrGARCH", garchOrder = c(1,1)),  
mean.model=list(armaOrder=c(0,0)), distribution.model = "norm")
```

```
m5=ugarchfit(spec=spec1,data=rendbtc)
```

```
m5
```

```
#distribuci?n student
```

```
spec1=ugarchspec(variance.model=list(model="gjrGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(0,0)), distribution.model = "std")
```

```
m6=ugarchfit(spec=spec1,data=rendbtc)
```

```
m6
```

```
#comparamos akaike
```

```
akaike <- c(Infocriteria(m1)[1],
```

```
  Infocriteria(m2)[1],
```

```
  Infocriteria(m3)[1],
```

```
  Infocriteria(m4)[1],
```

```
  Infocriteria(m5)[1],
```

```
  Infocriteria(m6)[1])
```

```
akaike
```

```
min(akaike)2
```

```
#obtencion de la volatilidad estimada
```

```
par(mfcol=c(1,2))
```

```
plot(m2)
```

```
v = sigma(m2)
```

```
v_anualizada=(250)^0.5*v
```

```
par(mfcol=c(2,1)) # Show volatility and returns
```

```
plot(v_anualizada)
```

```
plot(rendbtc)
```

```
#parece que coincide bastante la varianza estimada con la serie.
```

```
#COMPARACIONN VOLATILIDAD CON LOS RENDIMIENTOS en valor absoluto
```

```

returnsabs=abs(rendbtc)

par(mfcol=c(2,1))

plot(v_anualizada)

plot(returnsabs)

par(mfcol=c(1,1))

time = data.frame(returnsabs, v)

ts.plot(time,gpars= list(xlab="time", ylab="", col = 1:ncol(time)))

legend("topleft", c("returnbtc","v"), lty=c(1,1), col=c("black","red"), cex=0.6)

#la evolucion de la dinamica es la misma

#####

#news impact curve#

#####

ni=newsimpact(z = NULL, m2)

plot(ni$zx, ni$zy, ylab=ni$yexpr, xlab=ni$xexpr, type="l", main = "News Impact Curve")

#los shocks de noticias positivas y negativas afectan a la volatilidad

#####

### gld ###

#####

rendgld=diff(log(gld))

head(rendgld)

tail(rendgld)

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)

```

```

plot(rendgld) #es estacionaria en media pero existen algunos picos

rendgld<-rendgld[-1]

#eliminamos la primera observacion que ahora es NA porque si no, el contraste da un error

rendgld.df<-ur.df(rendgld, type = c("trend"), lags=20, selectlags = c("BIC"))

summary(rendgld.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA

#####

### gspc ###

#####

rendgspc=diff(log(gspc))

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)

plot(rendgspc) #es estacionaria en media pero existen algunos picos

rendgspc<-rendgspc[-1] #eliminamos la primera observacion que ahora es NA porque si no, el
contraste da un error

rendgspc.df<-ur.df(rendgspc, type = c("trend"), lags=20, selectlags = c("BIC"))

summary(rendgspc.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA

#####

### dji ###

#####

renddji=diff(log(dji))

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)

plot(renddji) #es estacionaria en media pero existen algunos picos

renddji<-renddji[-1] #eliminamos la primera observacion que ahora es NA porque si no, el
contraste da un error

renddji.df<-ur.df(renddji, type = c("trend"), lags=20, selectlags = c("BIC"))

```

```
summary(renddji.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA
```

```
#####
```

```
### n225 ###
```

```
#####
```

```
rendn225=diff(log(n225))
```

```
par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)
```

```
plot(rendn225) #es estacionaria en media pero existen algunos picos
```

```
rendn225<-rendn225[-1] #eliminamos la primera observacion que ahora es NA porque si no, el  
contraste da un error
```

```
rendn225.df<-ur.df(rendn225, type = c("trend"), lags=20, selectlags = c("BIC"))
```

```
summary(rendn225.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA
```

```
#####
```

```
### stox ###
```

```
#####
```

```
rendstoxx=diff(log(stoxx))
```

```
par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)
```

```
plot(rendstoxx) #es estacionaria en media pero existen algunos picos
```

```
rendstoxx<-rendstoxx[-1] #eliminamos la primera observacion que ahora es NA porque si no,  
el contraste da un error
```

```
rendstoxx.df<-ur.df(rendstoxx, type = c("trend"), lags=20, selectlags = c("BIC"))
```

```
summary(rendstoxx.df) #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA
```

```
#####
```

```
### eur_dol ###
```

```
#####

rendeurdol=diff(log(eurdol))

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)

plot(rendeurdol) #es estacionaria en media pero existen algunos picos

rendeurdol<-rendeurdol[-1] #eliminamos la primera observacion que ahora es NA porque si
no, el contraste da un error

rendeurdol.df<-ur.df(rendeurdol, type = c("trend"), lags=20, selectlags = c("BIC"))

summary(rendeurdol.df)      #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA
```

```
#####

### eur_cny ###

#####

rendeurcny=diff(log(eurcny))

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)

plot(rendeurcny) #es estacionaria en media pero existen algunos picos

rendeurcny<-rendeurcny[-1] #eliminamos la primera observacion que ahora es NA porque si
no, el contraste da un error

rendeurcny.df<-ur.df(rendeurcny, type = c("trend"), lags=20, selectlags = c("BIC"))

summary(rendeurcny.df)      #RECHAZO HIPOTESIS NULA-> ES ESTACIONARIA
```

```
#####

### eur_gbp ###

#####

rendeurgbp=diff(log(eurgbp))

par(mfrow=c(1,1),font=2,font.lab=4,font.axis=2,las=1)
```

```
plot(rendeurgbp) #es estacionaria en media pero existen algunos picos
```

```
rendeurgbp<-rendeurgbp[-1] #eliminamos la primera observacion que ahora es NA porque si  
no, el contraste da un error
```

```
#####
```

```
#modelo DCC multivariante#
```

```
#####
```

```
dim(rendbtc)
```

```
dim(rendgspc)
```

```
dim(rendgspc)
```

```
dim(rendn225)
```

```
dim(renddji)
```

```
dim(rendstoxx)
```

```
dim(rendeurdol)
```

```
dim(rendeurncy)
```

```
dim(rendeurgbp)
```

```
#####
```

```
##### BTC-GLD #####
```

```
#####
```

```
rX1=cbind(rendbtc, rendgld)
```

```
spec1 <- ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),  
mean.model=list(armaOrder=c(0,0)), distribution.model = "std")
```

```
spec2 <- ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),  
mean.model=list(armaOrder=c(0,0)), distribution.model = "std")
```

```
dcc.garch11.spec1 <- dccspec(uspec = multispec(c(spec1, spec2)), dccOrder = c(1,1),  
distribution = "mvnorm")
```

```
dcc.fit1 <- dccfit(dcc.garch11.spec1, data = rX1)
```

```
dcc.fit1
```

```
plot(dcc.fit1, main="Correlation BTC-GLD")
```

```
#superficie de impacto a las noticias
```

```
nisurface(dcc.fit1, type="cor")
```

```
#####
```

```
##### BTC-GSPC #####
```

```
#####
```

```
rX2 <- cbind(rendbtc, rendgspc)
```

```
dcc.fit2 <- dccfit(dcc.garch11.spec1, data = rX2)
```

```
dcc.fit2
```

```
plot(dcc.fit2, main="Correlation BTC-GSPC")
```

```
#superficie de impacto a las noticias
```

```
nisurface(dcc.fit2, type="cor")
```

```
#####
```

```
##### BTC-DJI #####
```

```
#####
```

```

rX3 <- cbind(rendbtc, renddji)

dcc.fit3 <- dccfit(dcc.garch11.spec1, data = rX3)

dcc.fit3

plot(dcc.fit3, main="Correlation BTC-DJI")

#superficie de impacto a las noticias

nisurface(dcc.fit3, type="cor")

#####
##### BTC-N225 #####
#####

rX4=cbind(rendbtc, rendn225)

dcc.fit4 <- dccfit(dcc.garch11.spec1, data = rX4)

dcc.fit4

plot(dcc.fit4, main="Correlation BTC-N225")

#superficie de impacto a las noticias

nisurface(dcc.fit4, type="cor")

#####

```

```
##### BTC-STOXX #####  
#####
```

```
rX5 <- cbind(rendbtc, rendstox)
```

```
dcc.fit5 <- dccfit(dcc.garch11.spec1, data = rX5)
```

```
dcc.fit5
```

```
plot(dcc.fit5, main="Correlation BTC-STOXX")
```

```
#superficie de impacto a las noticias
```

```
nisurface(dcc.fit5, type="cor")
```

```
#####  
##### BTC-EUR_DOL #####  
#####
```

```
rX6 <- cbind(rendbtc, rendeurdol)
```

```
dcc.fit6 <- dccfit(dcc.garch11.spec1, data = rX6)
```

```
dcc.fit6
```

```
plot(dcc.fit6, main="Correlation BTC-EUR_DOL")
```

```
#superficie de impacto a las noticias
```

```
nisurface(dcc.fit5, type="cor")

#####
##### BTC-EUR_CNY #####
#####
```

```
rX7 <- cbind(rendbtc, rendeurncy)

dcc.fit7 <- dccfit(dcc.garch11.spec1, data = rX7)
dcc.fit7
```

```
plot(dcc.fit7, main="Correlation BTC-EUR_DOL")
```

#superficie de impacto a las noticias

```
nisurface(dcc.fit7, type="cor")

#####
##### BTC-EUR_CBP #####
#####
```

```
rX8 <- cbind(rendbtc, rendeurgbp)

dcc.fit8 <- dccfit(dcc.garch11.spec1, data = rX8)
dcc.fit8
```

```
plot(dcc.fit8, main="Correlation BTC-EUR_DOL")
```

```
#superficie de impacto a las noticias
```

```
nisurface(dcc.fit5, type="cor")
```

```
#####
```

```
##### VIF #####
```

```
#####
```

```
rX123 <- cbind(rendbtc,rendgld,rendgspc,renddji,rendn225,
```

```
rendstoxx,rendeurdol,rendeurcny,rendeurgbp)
```

```
model123 <- lm(rendbtc ~rendgld+rendgspc+renddji+rendn225+
```

```
rendstoxx+rendeurdol+rendeurcny+rendeurgbp,data=rX123 )
```

```
summary(model123)
```

```
install.packages("car")
```

```
library(car)
```

```
vif_values <- vif(model123)
```

```
vif_values
```

```
barplot(vif_values, main = "VIF Values", horiz = TRUE, col = "steelblue",cex.names = .5)
```

```
blines(v = 10, lwd = 3, lty = 2)
```

9. Bibliografía

- Samer Ajour El Zein, Carlos Romera Jiménez, Reza Gheshmi (2020). *META-ANALYSIS ON BITCOIN*. España.
- Karl Oton Rudolf, , Samer Ajour El Zein, Nicola Jackman Lansdowne (2021). *Bitcoin as an Investment and Hedge Alternative. A DCCMGARCH Model Analysis*. Economics and Business Administration Department, EAE Business School, España.
- Guillem Cullerés (2014). *El bitcoin y su posible impacto en los mercados*. Observatorio de divulgación financiera, España.
- Ana María Buzzi, Mario Esteban Cittadini, Máximo Martín De Oliveira (2018). *Introducción a las criptomonedas*. San Luis (Argentina).
- Kelly Ann Coulter (2022). *The impact of news media on Bitcoin prices: modelling data driven discourses in the crypto-economy with natural language processing*. Coulter KA, Londres (Reino Unido).
- Shaen Corbeta, Charles Larkinb, Brian Luceyb, Andrew Meegana, Larisa Yarovayac. *The volatility generating effects of macroeconomic news on cryptocurrency returns*. Dublin.
- Andrew Urquhart (2017). *The Volatility of Bitcoin*. Berkshire (Reino Unido).
- Lukáš Pichl, Taisei Kaizoji (2017). *Volatility Analysis of Bitcoin Price Time Series*. Tokyo (Japón).
- Hans Byström, Dominika Krygier (2018). *What Drives Bitcoin Volatility?*. Lund, Suecia.
- Yutaka Kurihara, Akio Fukushima (2018). *How Does Price of Bitcoin Volatility Change?*. July Press, Nagoya (Japan).
- Jorge López Villa, Miriam Sosa Castro (2020). *Volatilidad condicional y correlación dinámica entre los mercados cambiarios y de valores en México (2009-2019). Una aproximación GARCH-DCC*. Ciudad de México (México)