

TRABAJO FINAL DE MÁSTER

Título: Análisis de la relación lineal y no lineal del S&P 500 y los precios de *commodities*

Autoría: Anas Serour El Aouad

Tutoría: Helena Chuliá

Curso académico: 2020-2021



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

Análisis de la relación lineal y no lineal del S&P 500 con los precios de *commodities*

Autoría: Anas Serour El Aouad

Tutoría: Helena Chuliá

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.

Análisis de la relación lineal y no lineal del S&P 500 con los precios de *commodities*

Anas Serour El Aouad

11 de enero de 2021

Resumen

El trabajo final de master se centra en el análisis de la relación lineal y no lineal entre los precios de *commodities*, los cuales han ido ganando fuerza e importancia en el mercado financiero internacional en las últimas décadas, y el índice bursátil S&P 500 de los Estados Unidos, siendo los *commodities* estratégicos escogidos en el análisis, el oro, el cobre, el petróleo crudo, el trigo y el algodón. Para ello, recurriremos desde un enfoque lineal al modelo DCC-GARCH. Mediante este modelo obtendremos las correlaciones condicionales y realizaremos un análisis comparativo de las mismas centrándonos especialmente en la crisis financiera del 2008 y la crisis del COVID-19. Por otro lado, utilizaremos el modelo de regresión cuantílica para medir la relación no lineal entre el S&P 500 y los precios de los *commodities*.

Palabras clave: *Commodities*, S&P 500, DCC-GARCH, Correlación condicional, Regresión cuantílica

Abstract

The final master thesis focuses on the analysis of the linear and non-linear relationship between commodities prices, which have attracted considerable interest in the international financial market in recent decades and the S&P 500 stock index of the United States, being the strategic commodities chosen in the analysis, gold, copper, crude oil, wheat and cotton. For that purpose, we will use the DCC-GARCH model as a linear approach. By using this model, we will obtain the conditional correlations and we will carry out a comparison of them, focusing on the financial crisis of 2008 and the crisis of the COVID-19. On the other hand, we will use the quantile regression to measure the non-linear relationship between the S&P 500 the *commodity* prices.

Keywords: *Commodities*, S&P 500, DCC-GARCH, Conditional correlation, Quantile regression.

ÍNDICE DE CONTENIDOS

1.- INTRODUCCIÓN.....	7
2.- DATOS	9
2.1.- Análisis histórico de las series.....	9
2.2.- Análisis de estacionariedad de las series	13
2.3.- Análisis de los estadísticos descriptivos.....	16
2.4.- Correlaciones incondicionales.....	16
3.- METODOLOGÍA	17
3.1.- Modelo para la media condicional	17
3.2.- Modelo para la varianza condicional.....	18
3.3.- Modelo para la correlación condicional	19
3.4.- Modelo de Regresión cuantílica	20
4.- RESULTADOS.....	21
4.1.- Modelos para la media, varianza y correlación condicional	21
4.2.- Análisis comparativo de la volatilidad individual.....	24
4.3.- Análisis comparativo de las correlaciones condicionales.....	25
4.4.- Análisis comparativo de las correlaciones obtenidas en la crisis financiera de 2008 y el COVID-19.....	27
4.5.- Relación no lineal	28
5.- CONCLUSIONES.....	30
6.- REFERENCIAS	32
ANEXOS	34
Anexo 1.- Gráficos ACF y PACF de las series.....	34
Anexo 2.- Script del código R	35

1.- INTRODUCCIÓN

En las últimas décadas el sector de los *commodities* ha sido uno de los más importantes en los mercados financieros internacionales en términos de contribución al comercio mundial, ingresos, especulación y empleo dadas sus características, siendo la más relevante la ausencia de valor agregado en los mismos.

Entendemos por *commodities* los recursos naturales sin elaborar o cuasi elaborados utilizados en producción y en procesos de manufacturación. Existen diversos tipos de *commodities* dividiéndose principalmente en *Hard Commodities* o “*Commodities* duros” y *Soft Commodities* o “*Commodities* Blandos”. Los primeros hacen referencia a aquellos recursos naturales que deben extraerse como el oro, petróleo, cobre etc. Mientras que los *Soft Commodities* son recursos principalmente agrícolas como el trigo, el maíz, azúcar etc.

Según Farooki y Kaplinsky (2012) los *commodities* se pueden clasificar de la siguiente forma:

Tabla 1. Clasificación de los *commodities*

Sector primario	Categorías	Uso principal	<i>Commodities</i>
<i>Soft Commodities</i>	Cultivos industriales	Input para manufacturación	Madera
	Pesca	Consumo final (con procesamiento limitado)	Langostino, bacalao
	Cereales		Arroz, trigo, maíz
	Bebidas		Té, café, cacao
	Ganado		Bovino, ovino
<i>Hard Commodities</i>	Metales preciosos	Input para manufacturación	Oro, plata, platino
	Metales industriales	Infraestructuras y construcción	Hierro, acero
		Input para manufacturación	Cobre, zinc, plomo, aluminio
Energía	Derivados del petróleo	Combustible o uso industrial	Petróleo crudo, gasolina, aceite de calefacción
	Otros	Consumo final	Gas natural, carbón

Fuente: Elaboración propia a partir de Farooki, M. Z. and R. Kaplinsky (2011). *The Impact of China on Global Commodities: The Disruption of the World's Resource Sector*. Routledge London. (Reino Unido)

Históricamente los *commodities* han sido clave en el desarrollo económico de varios países, destacando potencias como Estados Unidos y China, las cuales han requerido de una inversión importante en *commodities* como el acero, cobre y el petróleo para construir sus infraestructuras, el algodón y los metales para producir productos manufacturados y *commodities* relacionados con los alimentos, como el trigo, para alimentar a sus respectivas poblaciones.

Estas tendencias han producido una demanda significativa y una mayor volatilidad de los precios de los *commodities*, lo cual ha dado lugar a un interés creciente por parte de los inversores, que tradicionalmente solo invertían en mercados de acciones y bonos, con el objetivo de aprovechar dichos activos para obtener beneficios (Henderson et al., 2015) y formar las carteras de inversión incluyendo estos tipos de activos (Vivian y Wohar, 2012).

Paralelamente, la progresiva liberalización de los mercados financieros y la apertura de economías en las últimas décadas condujo a un interés en el análisis del incremento de la volatilidad, fruto de las crisis, guerras, políticas económicas adoptadas, condiciones meteorológicas y otros eventos importantes y a realizar por ende una investigación significativa sobre el posible nexo entre los mercados de valores y los *commodities* (Caporin et al. 2016).

Diferentes estudios en la literatura financiera muestran que los *commodities* han sido tradicionalmente un activo interesante para la diversificación de nuestras carteras ya que han mostrado correlaciones pequeñas con los *mercados de acciones* en periodos turbulentos (Chong y Miffre, 2010). Por otro lado, algunos autores han analizado la correlación entre el crudo y los mercados de valores entre ellos el S&P 500 (Jones y Kaul, 1996; Faff y Brailsford, 1999; Sadorsky, 1999) y entre el oro y los mercados de valores (Jaffe, 1989; Johnson y Soenen, 1997; Davidson et al. 2003).

Filis et al. (2011) analizaron la interacción entre los precios del petróleo y los mercados de valores diferenciando entre países importadores y exportadores de petróleo. Su estudio muestra que existe una interacción entre el petróleo y los precios de las acciones para las economías importadoras y exportadoras de petróleo.

Tang et al. (2012) y Büyükşahin y Robe (2010) muestran que la financiarización¹ de los *commodities* tiene relaciones complejas entre diferentes *commodities* y en las interacciones entre *commodities* y activos financieros llegando a mostrar que la actividad especulativa de los fondos de cobertura que se negocian activamente en los mercados de futuros de acciones y *commodities* tiene poder explicativo sobre la correlación entre acciones y *commodities*. Sin embargo, muestran que el poder predictivo de la actividad especulativa es más débil en períodos de estrés en el mercado financiero. (Büyükşahin y Robe 2010). Finalmente, Creti et al. 2013 muestran que la correlación entre los dos mercados es muy volátil, principalmente a partir de la crisis financiera de 2008.

A diferencia de otros estudios que han aparecido en la literatura, el objetivo de éste trabajo se centra en el análisis y estudio desde un enfoque lineal y no lineal de la relación existente entre el precio de distintos tipos de *commodities* con el S&P 500 y se estudia y compara cual es el comportamiento de los mismos en 2 de las crisis más importantes de las últimas dos décadas, siendo éstas la crisis financiera de 2008 y el COVID-19.

Por lo tanto, en nuestro estudio en lo que al enfoque lineal se refiere, partiremos de un análisis histórico de nuestras series de precios de *commodities* y del S&P 500 así como un análisis de estacionariedad y descriptivo de los rendimientos de los *commodities* y del S&P 500. Una vez realizados dichos análisis, obtendremos a su vez las correlaciones incondicionales entre *commodities* y el S&P 500. Posteriormente, estimaremos un modelo para la media condicional y un modelo para la varianza condicional de cada una de las series objeto de nuestro análisis, lo cual nos será de gran utilidad para realizar un análisis

¹ Proceso que en la literatura financiera hace referencia al aumento del comportamiento de los *commodities* como activo financiero y a la creciente participación de los inversores financieros en los mercados de futuros de *commodities*.

exhaustivo de la volatilidad, así como un análisis comparativo de la volatilidad individual de cada uno de los precios de *commodities* y el S&P.

Finalmente, mediante el modelo de correlación condicional dinámico DCC-GARCH propuesto por Engle (2002) observaremos la correlación cambiante a lo largo del tiempo entre el precio de los *commodities* y el índice S&P 500 y realizaremos un análisis comparativo entre las correlaciones condicionales obtenidas, así como una comparativa entre la crisis financiera de 2008 y COVID-19 de 2020.

Para el enfoque no lineal, estimaremos la relación no lineal entre los diferentes *commodities* y el índice S&P 500 en los diferentes cuantiles con el modelo de regresión cuantílica propuesto por Koenker y Basset (1978).

El resto del trabajo se estructura de la siguiente forma. La sección 2 muestra los datos que se utilizan en el análisis. La sección 3 presenta la metodología utilizada. En la sección 4 se muestran los resultados y, finalmente, la sección 5 las conclusiones.

2.- DATOS

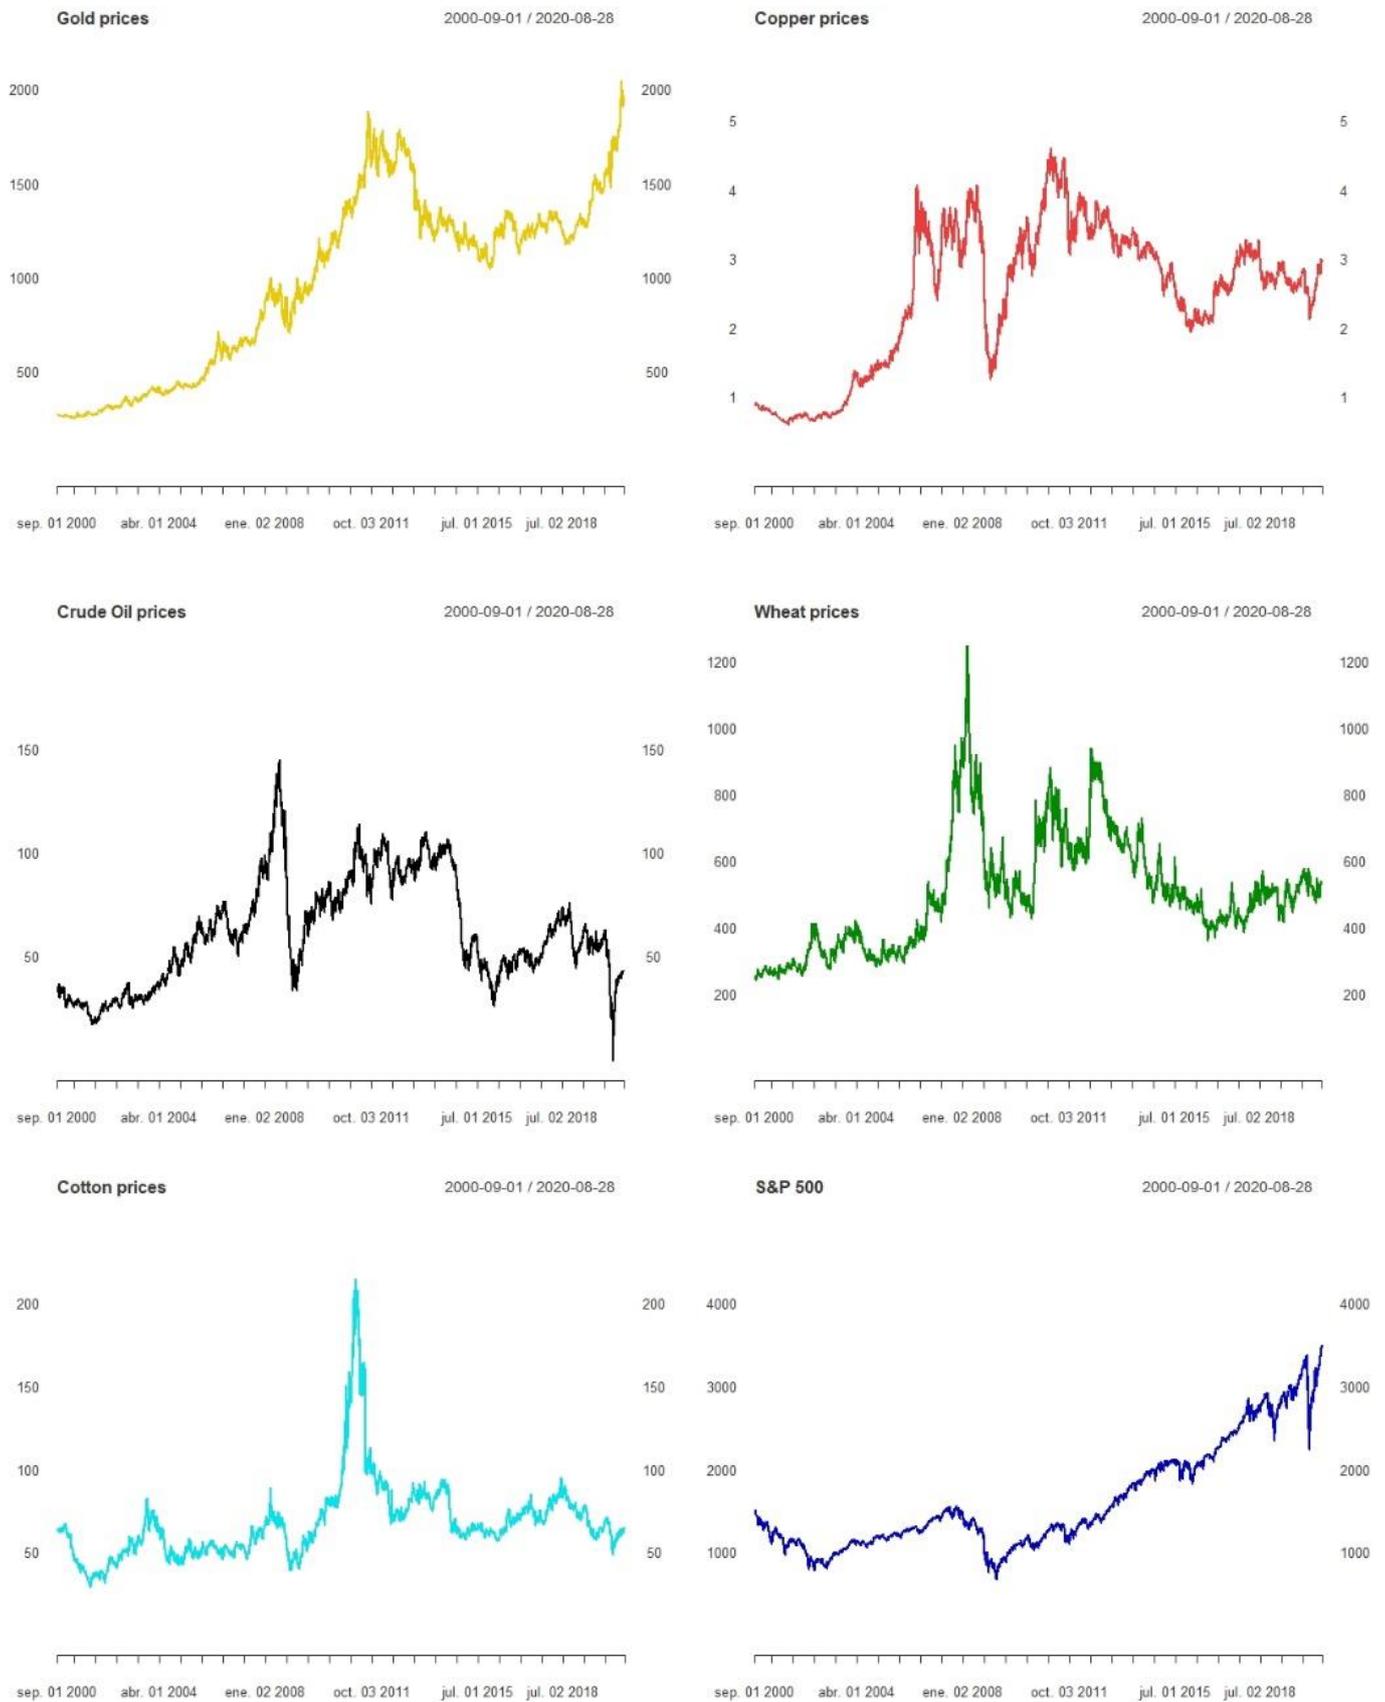
La base de datos en nuestro estudio se compone de las series de precios de diferentes tipos de *commodities* estratégicos, siendo éstos el oro (metal precioso), el cobre (metal industrial), el petróleo crudo (energía), el trigo (agricultura, granos) y el algodón (*soft commodity*) más el índice S&P 500 como el índice representativo bursátil más importante de los Estados Unidos. Los datos se han obtenido de *Yahoo Finance* mediante el paquete Quantmod de R-Studio.

La frecuencia de nuestros datos es diaria y el horizonte temporal que consideramos abarca el periodo comprendido entre septiembre del año 2000 y finales de agosto del año 2020, el cual nos permitirá analizar la relación de nuestros *commodities* con el S&P 500 tanto en tiempos estables como en las dos crisis más importantes de las últimas décadas, la crisis financiera de 2008 y el COVID-19.

2.1.- Análisis histórico de las series

En esta sección se analizará las series de los precios de los *commodities* escogidos desde una perspectiva histórica para entender como primera instancia cuál es el comportamiento de los mismos a lo largo de los últimos 20 años de nuestro periodo muestral considerando los momentos temporales e históricos más importantes y destacados que han afectado a su fluctuación.

Figura 1. Evolución del precio de los *commodities* escogidos y el índice S&P 500



Fuente: Elaboración propia a partir de datos de Yahoo Finance

Como se muestra en la figura 1, observamos como característica común que no son series estacionarias con una tendencia estocástica para todos los precios de *commodities* y el índice S&P 500. A continuación, se analizan históricamente y de forma individual las series de los precios de *commodities* y el índice S&P 500 basándonos en la figura 1.

Evolución del precio del oro

Por lo que a la serie de precios del oro se refiere (véase figura 1 *Gold*), observamos que muestra una tendencia creciente a partir de 2003 coincidiendo con la invasión estadounidense de Irak hasta el 2008 coincidiendo con la crisis financiera, donde cayó ligeramente el precio hasta situarse en los 716,80 dólares. A partir de entonces, el precio del oro continuó creciendo hasta alcanzar uno de los máximos históricos del mismo de 1.895 dólares en 2011. Posteriormente, observamos que el precio del oro cayó en un mercado bajista de varios años cotizando aproximadamente a 1.270 dólares de media hasta mediados de 2019, donde volvió a iniciar una tendencia creciente impulsado por la epidemia del COVID-19 y alcanzó el máximo histórico de 1.984 dólares a mediados de 2020.

Evolución del precio del cobre

En el caso de la serie de precios del cobre (véase figura 1 *Copper*), ésta ha sido bastante volátil en los últimos años. Observamos que a partir de 2002 el precio del cobre pasó de aproximadamente unos 0,66 dólares a situarse alrededor de los 4 dólares en 2008, período en que China superó a Estados Unidos como mayor consumidor de cobre. En ese mismo año, tras la crisis financiera del 2008, el precio cayó bruscamente hasta situarse en 1,29 dólares aproximadamente y más tarde alcanzaría su máximo histórico en 4,5 dólares a principios de 2011, lo cual viene explicado en parte por el crecimiento de la demanda en las economías emergentes a niveles pre-crisis financiera. A partir de entonces, el precio del cobre a continuado siendo muy volátil fluctuando entre 2 y 3,5 dólares hasta mediados de 2020.

Evolución del precio del petróleo crudo

Tal y como observamos en la figura 1 *Crude Oil*, los precios comenzaron a subir ya a principios del año 2000 y tres años más tarde, en el 2003, tras la invasión estadounidense de Irak se creó una incertidumbre sobre el suministro futuro de petróleo y al mismo tiempo la demanda asiática (impulsada por China) aumentó enormemente, lo que contribuyó a un aumento del precio del petróleo crudo de 25 dólares en 2003 a un máximo de 140 dólares el barril en julio de 2008. A partir de allí y como resultado de la crisis financiera a nivel mundial, los precios cayeron hasta situarse en menos de 50 dólares ese mismo año. En 2011 en pleno auge de la Primavera Árabe, el precio subió nuevamente hasta alcanzar los 126 dólares. Más tarde, en 2014, los avances tecnológicos llevados a

cabo en la materia permitieron el aumento de la producción de petróleo de esquisto² en Estados Unidos, lo que hizo reducir la influencia de la OPEP y que por lo tanto el precio del petróleo crudo pasara de 115 dólares a 28 en 2016. Desde entonces el precio del petróleo crudo a seguido siendo bastante volátil y, tras la declaración de la epidemia COVID-19 en marzo de 2020, el precio volvió a caer hasta situarse alrededor de 20 dólares.

Evolución del precio del trigo

En el caso de la serie de precios del trigo (véase figura 1 *Wheat*), nuevamente observamos mucha volatilidad a lo largo de nuestro periodo muestral. A mediados de 2000, el precio del trigo cotizaba aproximadamente a 250 dólares y dicho precio fue creciendo levemente hasta alcanzar sus máximos de 939 dólares en 2007 y de 1073 dólares en 2008. Tal y como nos indican Abbott et al. (2009) y Hurt y Tyner (2008), la mayoría de los análisis están de acuerdo en una lista común de posibles factores contribuyentes, aunque no necesariamente en su importancia. Incluyen:

- Por el lado de la oferta: malas cosechas, especialmente de trigo, menores existencias de cereales y aumento del precio del petróleo.
- Por el lado de la demanda: inflación generalizada resultante del rápido crecimiento de la economía mundial.
- Políticas: prohibiciones y restricciones a la exportación, reposición de existencias en mercados estrechos y aranceles de importación reducidos.
- Financiero: depreciación del dólar estadounidense.

A partir de la crisis financiera de 2008, el precio del trigo vuelve a caer hasta situarse por debajo de 600 dólares. En los próximos años observamos que el precio fluctúa entre los 550 y 900 dólares aproximadamente entre los años 2008 y 2014. Del 2016 a mediados de 2020 se observa un precio más estable alrededor de los 500 dólares.

Evolución del precio del algodón

El precio del algodón (véase figura 1 *Cotton*) se ven afectados por la evolución de los precios de otras materias primas industriales, los precios de posibles sustitutos (lana y fibras sintéticas), la evolución del sector textil, el valor del dólar y la teoría de la oferta y la demanda asociadas al algodón. Como resultado, los precios han sido extremadamente volátiles en los últimos años.

Observamos que durante los años de fuerte crecimiento mundial de 2003-2008, el precio del algodón aumentó por la fuerte demanda del sector de exportación de textiles de China cotizando en ese entonces a 70 dólares aproximadamente a mediados de 2008. Al igual que los precios de todas las materias primas industriales, el precio del algodón cayó en 2009, debido a una demanda más débil³, en parte fruto de la crisis financiera, pasando a

² O *shale oil* es un petróleo no convencional que se extrae de la roca de esquisto, una roca metamórfica del grupo de los silicatos que es menos permeable y cuyo petróleo que se encuentra bajo la misma no se puede extraer con los métodos tradicionales tenido que recurrir diversas técnicas destacando entre ellas la de fractura hidráulica.

³ Véase *Cotton Price Trends in 2017/18*, by Lihan Wei, ICAC Washington (EEUU)

un precio de 45 dólares aproximadamente. Ese mismo año y el siguiente, una mala cosecha provocó un déficit en el mercado y se produjo un aumento muy destacable del precio del algodón hasta situarse en 200 dólares a principios de 2011 tal y como observamos en la figura 1 *Cotton* (ICAC, 2018).

Sin embargo, el crecimiento de la demanda fue débil (en parte debido al aumento de los precios), y en la segunda mitad de 2011 los precios comenzaron a caer y continuaron cayendo durante 2012 volviendo a niveles de precios del 2003-2008 en el periodo de 2012 a mediados de 2020.

Evolución del S&P 500

Por lo que a la evolución del S&P 500 se refiere, observamos en la figura 1 *S&P 500* una tendencia creciente, aunque con fluctuaciones relativamente importantes. Dicha tendencia creciente se ha visto afectada en tres momentos clave y que causaron pérdidas significativas.

El primer momento que observamos hace referencia al periodo comprendido entre septiembre del 2000 y 2001, donde el índice pasó de una cotización de 1.400 puntos a mediados del 2000 a situarse por debajo de los 1.000 puntos, fruto de la Burbuja puntocom, periodo en el cual hubo burbuja especulativa entorno a las empresas de internet que culminó con la caída de las acciones de múltiples empresas tecnológicas.

El segundo momento se remonta a la crisis financiera de 2008, donde nuevamente tras alcanzar los 1.576 puntos a finales de 2007 se invierte dicho crecimiento pasando a cotizar alrededor de los 676,53 puntos a principios de 2009.

Y finalmente el último momento lo observamos tras un crecimiento muy notable llegando a alcanzar máximos históricos alrededor de los 3.400 puntos en febrero de 2020, debido principalmente a la recuperación económica y a la época de crecimiento económico en la cual se encontraba Estados Unidos. En marzo de 2020 vuelve a caer por debajo de los 2.500 puntos tras la declaración de la epidemia del COVID-19. En los próximos meses se recupera rápidamente y vuelve a alcanzar niveles superiores a los previos al COVID-19.

2.2.- Análisis de estacionariedad de las series

En este apartado se empleará la metodología específica para analizar la estacionariedad de nuestras series de *commodities* y S&P 500, con el objetivo de posteriormente estimar un modelo para la media y varianza condicional.

Para ello recurriremos en primer lugar a los contrastes informales ACF y PACF o Función de Autocorrelación y Función de Autocorrelación Parcial propuestas por Dickey y Fuller en (1979) y a los estadísticos de Box-Pierce y Ljung-Box (1978).

Mediante los primeros⁴ concluimos que las series de precios no son estacionarias ya que los coeficientes son significativos en todos los casos lo que indica que los choques tendrán un efecto permanente y será necesario diferenciar nuestras series para trabajar con ellas.

Por otro lado, también recurrimos a herramientas formales destacando a continuación, los resultados de los contrastes de raíces unitarias, (DF) Dickey-Fuller (1979), (PP) Phillips-Perron (1988) y (KPSS) Kwiatkowski-Phillips-Schmidt-Shin (1992).

En la tabla 2 se muestran los valores de los estadísticos de contraste, los valores críticos con los que se comparan y los resultados que llegamos con los contrastes de raíces unitarias previamente especificados, concluyendo de nuevo que todas nuestras series no son estacionarias.

Tabla 2. Resultados de los contrastes de raíces unitarias DF, PP y KPSS para nuestras series de precios de *commodities* y el S&P 500

<i>Commodity</i> /índice	Test	DF	PP	KPSS
	<i>Hipótesis nula</i>	<i>No estacionariedad</i>	<i>No estacionariedad</i>	<i>Estacionariedad</i>
Oro	Valor t-estadístico	-0,3628	-0,2964	36,5992
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	NRH0	NRH0	RH0
Cobre	Valor t-estadístico	-1,8319	-1,8718	19,5427
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	NRH0	NRH0	RH0
Petróleo Crudo	Valor t-estadístico	-1,9976	-2,0655	10,4729
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	NRH0	NRH0	RH0
Trigo	Valor t-estadístico	-2,5922	-0,2169	12,0282
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	NRH0	RH0
Algodón	Valor t-estadístico	-2,5303	-2,4316	9,3857
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	NRH0	NRH0	RH0
S&P 500	Valor t-estadístico	0,9724	1,1032	35,5779
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	NRH0	NRH0	RH0

Fuente: Elaboración propia, siendo "RH0" el rechazo de la hipótesis nula y "NRH0" el no rechazo de la hipótesis nula. Contraste incluyendo constante "drift", lags igual a 20 y lags seleccionados mediante BIC en DF y "short" en PP y KPSS. Valores críticos al 5% de nivel de significación.

⁴ Véase Anexo 1. Gráficos ACF y PACF de las series de precios de *commodities* y S&P 500

Una vez concluida la no estacionariedad de las series, procedemos a transformar nuestras series en rendimientos mediante una diferenciación y la aplicación de logaritmos para corregir la heteroscedasticidad.

Los resultados obtenidos los podemos observar en la tabla 3 donde en este caso confirmamos la estacionariedad de nuestras series y, por tanto, solamente ha sido necesaria una diferenciación en cada una de las series de *commodities* y la serie del S&P 500.

Tabla 3. Resultados de los contrastes de raíces unitarias DF, PP y KPSS para los rendimientos estacionarios de nuestras series de *commodities* y el S&P 500

<i>Commodity/índice</i>	Test	DF	PP	KPSS
	<i>Hipótesis nula</i>	<i>No estacionariedad</i>	<i>No estacionariedad</i>	<i>Estacionariedad</i>
Oro	Valor t-estadístico	-50,2649	-71,5543	0,1623
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0
Cobre	Valor t-estadístico	-51,9633	-76,4635	0,1944
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0
Petróleo Crudo	Valor t-estadístico	-51,6615	-72,0551	0,055
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0
Trigo	Valor t-estadístico	-50,7686	-72,1333	0,0822
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0
Algodón	Valor t-estadístico	-49,1764	-66,7373	0,0466
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0
S&P 500	Valor t-estadístico	-53,8062	-80,1435	0,3350
	Valores críticos	-2,5700	-2,5673	0,3470
	Resultado	RH0	RH0	NRH0

Fuente: Elaboración propia, siendo "RH0" el rechazo de la hipótesis nula y "NRH0" el no rechazo de la hipótesis nula. Contraste incluyendo constante "drift", lags igual a 20 y lags seleccionados mediante BIC en DF y "short" en PP y KPSS. Valores críticos al 5% de nivel de significación.

2.3.- Análisis de los estadísticos descriptivos

La tabla 4 muestra los estadísticos descriptivos de las series de rendimientos. Observamos como efectivamente todos los rendimientos presentan una media prácticamente nula, aunque detectamos una mayor media en los rendimientos del oro de entre los *commodities* escogidos seguido de los rendimientos del cobre. Por otro lado, si observamos la mediana y la comparamos con la media vemos que hay una mayor dispersión respecto de la misma en el caso del S&P 500 y el petróleo principalmente. Sin embargo, se observa una menor dispersión respecto a la media en el caso del oro y del trigo.

Mediante el coeficiente de variación confirmamos que hay una mayor dispersión relativa en el caso del algodón, seguido del petróleo y el trigo. El oro presenta el menor coeficiente de variación de nuestro conjunto de rendimientos.

Por lo que a la asimetría se refiere, vemos que casi todas las series de rendimientos presentan asimetría negativa y por lo tanto una asimetría a la izquierda a excepción de los rendimientos del trigo y del petróleo crudo que presentan una asimetría positiva a la derecha. Finalmente, si analizamos la curtosis, observamos una curtosis muy elevada en los rendimientos del petróleo crudo seguido del S&P 500 lo que nos indica que hay un mayor nivel de riesgo en éstos, dejando valores extremos que conllevan a unas colas mucho más pesadas.

Tabla 4. Estadísticos básicos de los rendimientos de los *commodities* y el S&P 500

	Oro	Cobre	Petróleo Crudo	Trigo	Algodón	S&P 500
Mínimo	-0,098206	-0,116933	-0,282206	-0,099728	-0,155547	-0,127652
Máximo	0,086432	0,117693	0,319634	0,087943	0,136218	0,109572
Media	0,00039	0,000242	0,00017	0,000152	0,000003	0,000166
Mediana	0,000377	0,000000	0,000582	0,000000	0,000000	0,0006
C.V	28,5230769	70,8760331	154,964706	130,723684	6225,0000	75,373494
Desviación típica	0,011124	0,017152	0,026344	0,01987	0,018675	0,012512
Asimetría	-0,252806	-0,166417	0,109996	0,206765	-0,008786	-0,394171
Curtosis	5,601417	4,530568	18,751	1,854131	4,176717	11,518287

Fuente: Elaboración propia

2.4.- Correlaciones incondicionales

En éste apartado obtenemos las correlaciones incondicionales mediante el coeficiente de correlación de Pearson. En la tabla 5 observamos que la correlación incondicional es positiva, aunque muy pequeña para todos los *commodities* con el S&P 500 a excepción del oro, el cual presenta una correlación negativa.

La mayor correlación la encontramos entre el cobre y el S&P 500 con 0,27 puntos seguido del crudo. Finalmente vemos que las menores correlaciones positivas con el S&P 500 las encontramos en los *commodities* de agricultura, el trigo y el algodón.

Tabla 5. Correlaciones incondicionales entre los rendimientos de commodities y el S&P 500

<i>Commodity</i>	S&P 500
Oro	-0,0216
Cobre	0,2768
Petróleo Crudo	0,2259
Trigo	0,1058
Algodón	0,1671

Fuente: Elaboración propia

3.- METODOLOGÍA

En el siguiente apartado se muestra cuál será la metodología a utilizar para estimar la correlación condicional y por lo tanto la relación cambiante a lo largo del tiempo entre el precio de los *commodities* escogidos con el S&P 500.

Para la estimación de dicha correlación condicional, se utilizará uno de los modelos multivariantes más destacados en la literatura econométrica, siendo éste el modelo *Dynamic Conditional Correlation* (DCC) propuesto por Engle en 2002. Para la construcción de dicho modelo será necesario estimar un modelo para la media condicional y un modelo para la varianza condicional de todas nuestras series de precios de *commodities* y el índice S&P 500 siguiendo la metodología de Box-Jenkins (1976).

La metodología Box-Jenkins sigue estrictamente el siguiente procedimiento:

- 1- Identificación del modelo (por medio de FAS y FAP) y contraste Ljung-Box.
- 2- Estimación del modelo.
- 3- Diagnóstico del modelo a partir de significación de los coeficientes estimados y el análisis de los residuos.

Para la selección del modelo que más se ajuste a nuestra serie se utilizarán dos criterios de selección, el criterio de información de Akaike (AIC) y el criterio de información Bayesiano (BIC)

3.1.- Modelo para la media condicional

El modelo utilizado para estimar la media condicional será un modelo ARMA (p, q) como modelo general de series temporales autorregresivo (AR) con media móvil (MA) de p términos autorregresivos y q términos de media móvil, pudiendo ser alguno de éstos o ambos igual a cero y ceñirnos a un modelo AR, un modelo MA simplemente o que se dé un proceso de Ruido Blanco.

Un modelo ARMA (p, q) se puede expresar de la siguiente forma:

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

donde y_t se refiere a la serie de rendimientos y ϵ_t es un proceso ruido blanco de media cero y varianza σ_t .

La expresión de un modelo AR (p) es:

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t$$

La expresión de un modelo MA (q) es:

$$y_t = \mu + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t$$

3.2.- Modelo para la varianza condicional

El modelo utilizado para estimar la varianza condicional será el modelo GARCH (p,q) o *Generalized Autorregresive Conditional Heterocedasticity* propuesto por Engle en 1982. El modelo GARCH (p,q) sigue la siguiente expresión:

$$\sigma_{it}^2 = \omega_i + \sum_{q=1}^{qi} \alpha_{iq} \epsilon_{i,t-q}^2 + \sum_{p=1}^{pi} \beta_{ip} \sigma_{i,t-p}^2$$

Donde:

- Los parámetros $\omega > 0$ y $\alpha_i, \beta_i \geq 0$ e $i=1\dots q$, y $j=1\dots p$. Además, para el cumplimiento de la condición de estacionariedad la suma de los parámetros α_i más β_i debe ser menor a la unidad.

Adicionalmente, se han utilizado modelos asimétricos que han aparecido en la literatura econométrica para estimar la varianza condicional teniendo en cuenta la respuesta asimétrica de la volatilidad ante noticias negativas y positivas. Empíricamente se ha demostrado que la volatilidad aumenta más cuando las noticias que llegan al mercado son negativas que cuando son positivas. Uno de los principales modelos propuestos es el modelo EGARCH propuesto por Nelson (1990)

El modelo EGARCH (p,q) sigue la siguiente expresión en términos del logaritmo de la varianza:

$$\ln(\sigma_t^2) = \alpha_0 + \beta \ln(\sigma_{t-1}^2) + \gamma \frac{r_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \theta \left[\frac{|r_{t-1}|}{\sqrt{\sigma_{t-1}^2}} - \frac{2}{\pi} \right]$$

Dónde el nivel de la varianza a largo plazo viene dado por:

$$\ln \sigma^2 = \frac{\alpha_0}{1 - \beta}$$

En este modelo no se deben imponer condiciones de positividad dado que se formula sobre el logaritmo de la varianza. La principal contribución de este modelo es que toma en cuenta el hecho de que los choques negativos tienen un mayor impacto en la volatilidad que los positivos.

3.3.- Modelo para la correlación condicional

El modelo utilizado para estimar la correlación condicional será el modelo *Dynamic Conditional Correlation* (DDC-GARCH) introducido por Engle en 2002. En este modelo la matriz de varianzas y covarianzas, H_t , se descompone en desviaciones estándar, D_t , y en una matriz de correlación condicional, R_t , que sigue la siguiente expresión:

$$H_t = D_t R_t D_t$$

donde los elementos de la matriz diagonal, D_t , son desviaciones estándar que se estiman a través de modelos GARCH univariantes.

$$D_t = \text{diag}(\sigma_{1t}, \dots, \sigma_{nt})$$

donde:

$$\sigma_{it}^2 = \omega_i + \sum_{q=1}^{Qi} \alpha_{iq} \varepsilon_{i,t-q}^2 + \sum_{p=1}^{Pi} \beta_{ip} \sigma_{i,t-p}^2$$

Por ende, la matriz de correlaciones se define como:

$$R_t = \begin{bmatrix} 1 & p_{12,t} & p_{13,t} & \dots & p_{1n,t} \\ p_{12,t} & 1 & p_{23,t} & \dots & p_{2n,t} \\ p_{13,t} & p_{23,t} & 1 & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & p_{n-1,n,t} \\ p_{1n,t} & p_{2n,t} & \dots & p_{n-1,n,t} & 1 \end{bmatrix}$$

Cumpléndose nuevamente las mismas condiciones que para los procesos GARCH univariante que garantizan que esta matriz es positiva definida.

Por lo tanto, se puede descomponer a su vez mediante la siguiente expresión:

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

$$Q_t = (1 - a - b)\bar{Q} + \alpha \eta_{t-1} \eta_{t-1}^T + \beta Q_{t-1}$$

donde Q_t es la matriz de varianzas de η_t y η_t son los residuos estandarizados que provienen de los modelos GARCH univariantes. Finalmente, los parámetros α y β tienen que satisfacer que $\alpha + \beta < 1$.

$$R_t = \frac{Q_t}{\sqrt{\text{diag}(Q_t) \cdot \text{diag}(Q_t)}}$$

$$\rho_{ij,t} = \frac{q_{ji,t}}{\sqrt{q_{ii,t} q_{jj,t}}} \text{ para } i, j = 1, 2, \dots, n \text{ y } i \neq j$$

Siendo $\rho_{ij,t}$ la correlación y la covarianza de j e i :

$$\rho_{ij,t} = \frac{(1 - \alpha - \beta)\bar{q}_{ij} + \alpha\hat{\eta}_{i,t-1}\hat{\eta}_{j,t-1} + \beta q_{ij,t-1}}{\sqrt{((1 - \alpha - \beta)\bar{q}_{ii} + \alpha\hat{\eta}_{i,t-1}^2 + \beta q_{ii,t-1})(1 - \alpha - \beta)\bar{q}_{jj} + \alpha\hat{\eta}_{j,t-1}^2 + \beta q_{jj,t-1}}}$$

Dicho modelo contiene $(k + 1)(k+4)/2$ parámetros, siendo k el número de variables incluidas en el modelo.

3.4.- Modelo de Regresión cuantílica

El modelo utilizado para estimar la relación no lineal es el modelo de regresión cuantílica propuesto por Koenker y Basset (1978), un método de estimación basado en la minimización de desviaciones absolutas ponderadas con pesos asimétricos que no se ven afectadas por datos extremos y que busca dar solución a la estimación de un modelo de regresión lineal estándar, el cual puede conducir a estimaciones engañosas, ya que promediará los efectos positivos y negativos.

La expresión de la regresión cuantílica se puede expresar de la siguiente forma:

$$y_i = x_i' \beta_\tau + \varepsilon_i$$

Donde β_τ es un vector de parámetros desconocidos asociados al cuantil τ^{th} , y_i es la variable endógena o dependiente del modelo, x_i es el elemento i -ésimo de la matriz de variables exógenas o independientes y ε_i es el término de perturbación que recoge todos aquellos factores distintos de las variables x_i que influyen en y_i .

τ^{th} hace referencia al cuantil de la muestra con $0 < \tau < 1$ que deja una proporción τ de observaciones por debajo y una proporción de $(1 - \tau)$ por encima y se define como:

$$Q(\tau) = \inf y : F(y) \geq \tau$$

Donde \inf hace referencia al ínfimo o valor más pequeño de y .

Podemos reescribir el método de estimación de la regresión cuantílica de la siguiente forma:

$$\hat{\beta}_\tau = \arg \min_\beta \left(\sum_{i:y_i > \beta x_i} \tau |y_i - \beta x_i| + \sum_{i:y_i < \beta x_i} (1 - \tau) |y_i - \beta x_i| \right)$$

Donde $\hat{\beta}_\tau$ es el parámetro de la regresión cuantílica que estima el cambio en un cuantil específico τ de la variable dependiente y_i producido por una unidad de cambio en la variable independiente x_i .

Este método ofrece dos tipos de significación importantes para los coeficientes del cuantil τ , donde:

- Los coeficientes del cuantil τ pueden ser significativamente diferentes de cero.
- Los coeficientes del cuantil τ pueden ser significativamente diferentes del coeficiente estimado por *mínimos cuadrados ordinarios (MCO)*, mostrando diferentes efectos a lo largo de la distribución de la variable dependiente.

4.- RESULTADOS

En el siguiente apartado se detallan los resultados obtenidos tras la estimación de los modelos para la media condicional, la varianza condicional y la correlación condicional de nuestros *commodities* con el S&P 500 desde un enfoque lineal y los resultados obtenidos en la estimación del modelo de regresión cuantílica para la relación no lineal.

4.1.- Modelos para la media, varianza y correlación condicional

Para la estimación de un modelo para la media condicional hacemos uso de la metodología Box-Jenkins obteniendo los resultados que se detallan en la tabla 6.

Observamos que el oro y el trigo siguen un proceso ruido blanco y el resto de series se modelizan correctamente con un modelo ARMA con pocos parámetros.

Tabla 6. Resumen estimación modelo para la media condicional de los *commodities* y el S&P 500

<i>Commodity</i> /índice	Modelo	Coefficientes	Valor	Prob.
Oro	ARMA (0,0) <i>Ruido Blanco</i>	-	-	-
Cobre	AR (1)	Constante ϕ_1	0,0400 -0,0769	1,4107e-01 2,2949e-08
Petróleo Crudo	ARMA (1,1)	Constante ϕ_1 θ_1	0,4000 0,5013 -0,5263	0,3454 0,0036 0,0021

Trigo	ARMA (0,0) <i>Ruido Blanco</i>	-	-	-
Algodón	MA (1)	Constante	0,0000	4,9607e-01
		θ_1	0,0611	8,3947e-06
S&P 500	MA (1)	Constante	0,0004	1,4151e-01
		θ_1	-0,1198	5,4384e-18

Fuente: Elaboración propia.

Para la estimación de un modelo para la varianza condicional, hacemos uso de modelos simétricos y asimétricos siendo más apropiado en el caso de las series de *commodities* un modelo GARCH (1,1) con distribución T-Student y en el caso del S&P 500 un modelo E-GARCH (1,1) con distribución T-Student que tiene en cuenta el comportamiento asimétrico de la volatilidad, tal y como observamos en la tabla 7.

Si analizamos los coeficientes α y β (véase α_1 y β_1 en la tabla), coeficientes que nos miden el impacto de las noticias sobre dicha volatilidad como la persistencia de la misma, respectivamente, observamos en primer lugar que α es significativa en todos los casos, aunque muy pequeña en los *commodities* cogiendo valores inferiores a 0.1, habiendo, por lo tanto, muy poca sensibilidad al impacto de las noticias. En el caso del coeficiente β , éste es superior al 0,9 en el caso de los *commodities* indicando en todos los casos una volatilidad muy persistente.

Por otro lado, vemos que se cumplen las condiciones de positividad (ω , α_1 y β_1 mayor o igual a 0) y de estacionariedad (α_1 más β_1 inferior a 1).

Finalmente, para el S&P 500 observamos que todos los coeficientes son significativos y a su vez gamma (véase α_1) es negativo, valor que se espera del mismo. Si analizamos el efecto que tienen las noticias negativas frente al efecto de las noticias positivas, observamos que la volatilidad aumenta más con las noticias negativas que con las positivas. Nuevamente por lo que a la persistencia se refiere, vemos que la volatilidad del S&P 500 es muy persistente.

Tabla 7. Resumen estimación modelo para para la varianza condicional de los *commodities* y el S&P 500

<i>Commodity</i> /índice	Modelo	Coefficientes	Valor	Prob.
Oro	ARMA (0,0) – GARCH (1,1) Distribución T-Student	Mu	0,0005	0,0000
		ω	0,0000	0,2675
		α_1	0,0373	0,0000
		β_1	0,9590	0,0000
		Shape	4,5950	0,0000
Cobre	AR (1) – GARCH (1,1) Distribución T-Student	Mu	0,0001	0,3039
		ϕ_1	-0,0651	0,0000
		ω	0,0000	0,0428
		α_1	0,0373	0,0000

		β_1	0,9585	0,0000
		Shape	5,8269	0,0000
Petróleo Crudo	ARMA (1) – GARCH (1,1) Distribución T-Student	Mu	0,0006	0,0122
		ϕ_1	0,0359	0,9429
		θ_1	-0,0648	0,8969
		ω	0,0000	0,0031
		α_1	0,0764	0,0000
		β_1	0,9123	0,0000
		Shape	7,4367	0,0000
Trigo	ARMA (0,0) – GARCH (1,1) Distribución T-Student	Mu	-0,0002	0,2705
		ω	0,0000	0,0230
		α_1	0,0401	0,0000
		β_1	0,9524	0,0000
		Shape	7,9454	0,0000
Algodón	MA (1) – GARCH (1,1) Distribución T-Student	Mu	-0,0000	0,9760
		θ_1	0,0198	0,1541
		ω	0,0000	0,5473
		α_1	0,0422	0,0620
		β_1	0,9493	0,0000
		Shape	4,8987	0,0000
S&P 500	MA (1) – E-GARCH (1,1) Distribución T-Student	Mu	0,0005	0,0000
		θ_1	-0,0584	2,7e-05
		ω	-0,1868	0,0000
		α_1	-0,1554	0,0000
		β_1	0,9807	0,0000
		γ	0,1461	0,0000
		Shape	6,6361	0,0000

Fuente: Elaboración propia

Para la estimación de la correlación condicional, hacemos uso del modelo DCC-GARCH (1,1). La tabla 8 muestra los coeficientes α y β de nuestros modelos DCC estimados donde α mide el impacto de las noticias sobre la correlación, mientras que β mide la persistencia de la correlación.

Observamos que los valores de α son muy pequeños y significativos en todos los casos a excepción del trigo y el algodón lo que indica en líneas generales que el impacto de las noticias sobre la correlación es muy pequeño. En el caso del coeficiente β del modelo DDC observamos un valor muy elevado por encima de 0,95 puntos en todos los casos, lo que nos indica que hay mucha persistencia en la correlación.

Tabla 8. Coeficientes del modelo DDC-GARCH (1,1) para la correlación condicional entre *commodities* y S&P 500

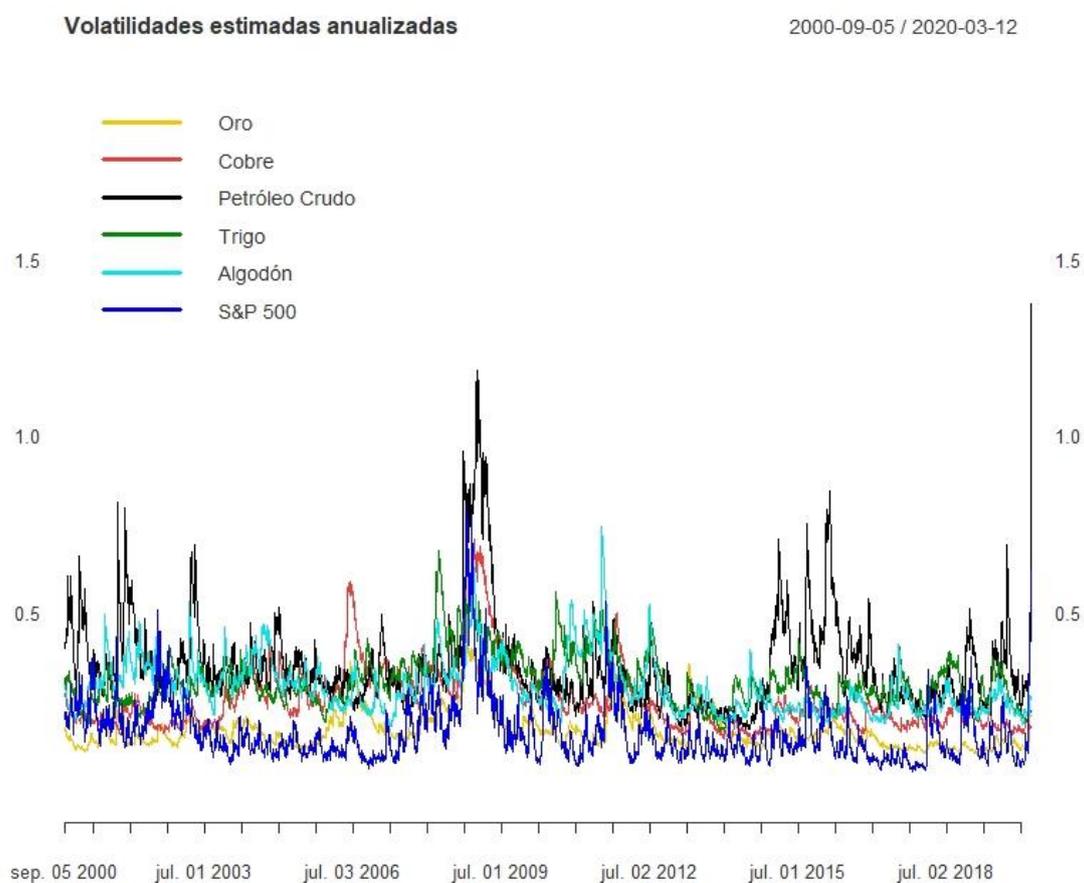
<i>Commodity</i>	Coefficiente DDC α	Prob.	Coefficiente DDC β	Prob.
Oro	0,0332	0,0000	0,9504	0,0000
Cobre	0,0124	0,0000	0,9841	0,0000
Petróleo Crudo	0,0287	0,0002	0,9644	0,0000
Trigo	0,0047	0.1014	0.9909	0,0000
Algodón	0,0081	0,2564	0,9861	0,0000

Fuente: Elaboración propia

4.2.- Análisis comparativo de la volatilidad individual

En el siguiente apartado realizaremos un análisis comparativo de la volatilidad estimada anualizada de nuestros *commodities* así como el S&P 500 para observar cuál es su patrón de comportamiento y su evolución a lo largo de nuestro periodo muestral.

Figura 2. Volatilidades estimadas anualizadas de los *commodities* y S&P 500



Fuente: Elaboración propia

Tal y como se observa en la figura 2, el petróleo es el *commodity* que presenta una mayor volatilidad a lo largo de nuestro periodo muestral con máximos en 2008, coincidiendo con la crisis financiera, así como en el periodo de 2014 a 2016, coincidiendo con la caída en picado de los precios debido a un aumento de la producción de petróleo de esquisto en Estados Unidos, y finalmente en 2020 tras la llegada del COVID-19.

Además, vemos lo que en la literatura econométrica se conoce como agrupamiento o clústeres de la volatilidad en los periodos del 2000 al 2003, coincidiendo con el atentado a las torres gemelas y la posterior invasión estadounidense en Irak, en el periodo de crisis financiera de 2008 y tras la declaración del COVID-19 en 2020, donde la volatilidad es muy alta alternada con volatilidades más pequeñas en periodos más estables para la mayoría de nuestros *commodities* y el S&P 500. En 2008, durante la crisis financiera, es donde observamos de forma clara que en todos los *commodities* objeto de estudio y el S&P 500 su volatilidad se ve incrementada.

Finalmente, observamos comportamientos de la volatilidad muy parecidos en 2 casos:

- En *commodities* que forman parte del grupo de agricultura, siendo estos el trigo (subgrupo *grains* o granos) y el algodón (subgrupo *soft* o blandos)
- El oro y el cobre donde además observamos una volatilidad menor en el primero en comparación con el resto de *commodities* analizados.

4.3.- Análisis comparativo de las correlaciones condicionales

En el siguiente apartado se comparan las correlaciones condicionales obtenidas de nuestros *commodities* con el S&P 500 para observar cuál es su patrón de comportamiento y su evolución.

En la figura 3 observamos la correlación condicional de los *commodities* con el S&P 500 a lo largo de nuestro periodo muestral.

Observamos en primera instancia dos comportamientos bien diferenciados entre nuestros *commodities*. Por un lado, *commodities* como el trigo y el algodón, los cuales presentan una evolución muy similar en lo que a volatilidad y correlación se refiere más el cobre, presentan correlaciones positivas con el S&P 500 a lo largo del periodo muestral. Aunque dicha correlación es positiva es muy pequeña situándose entre los 0,05 y los 0,4 puntos en algunos periodos. De entre éstos, el cobre en general es el *commodity* que tiene una correlación mayor hasta finales de 2013 donde se sitúa a niveles similares al trigo y el algodón. Por el contrario, el trigo es el *commodity* que presenta una correlación menor en términos positivos siendo además muy estable durante todo el periodo muestral junto con el algodón.

Por otro lado, *commodities* como el oro y petróleo crudo, presentan correlaciones negativas y positivas en algunos periodos, con una variabilidad mucho mayor durante todo el período muestral. En el caso del oro, observamos que los valores más bajos en la correlación con el S&P 500 coinciden con períodos turbulentos en los mercados financieros, tales como la Burbuja puntocom a finales del 2000, la crisis financiera de 2008, la crisis de la deuda soberana de 2012, tras el anuncio del Brexit en 2016 y, finalmente, tras el inicio de la pandemia producida por el COVID-19 en 2020. Algunas

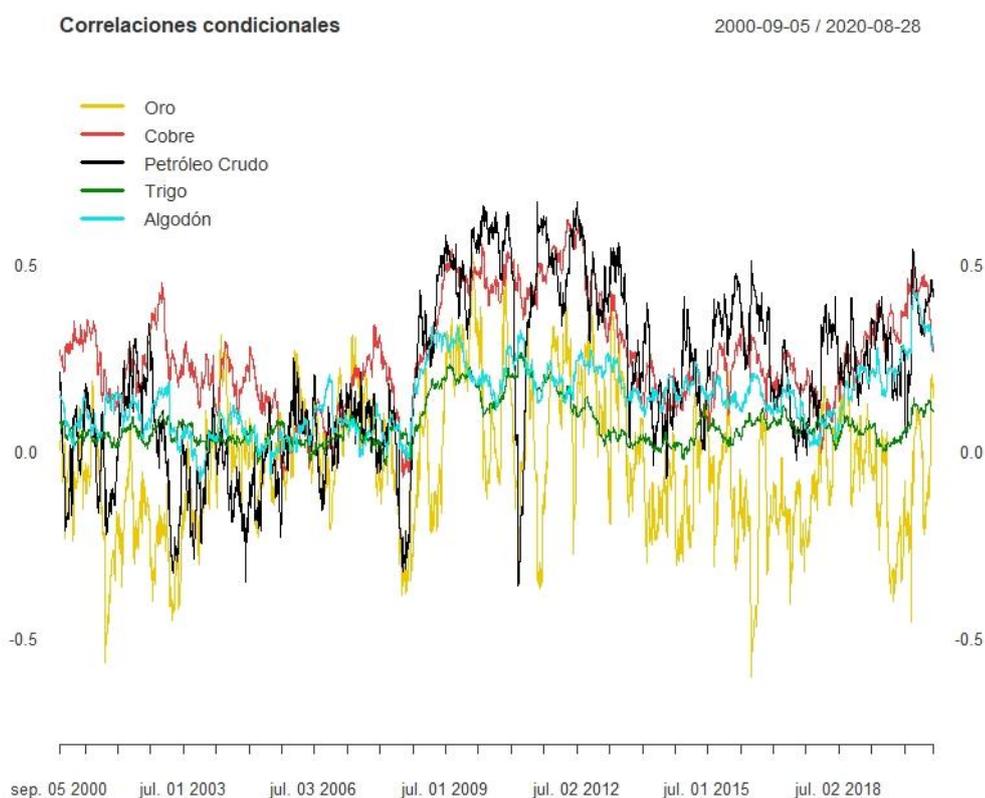
de las razones que explican este fenómeno son que el oro es fungible y fácil de almacenar y, por este motivo, juega un papel importante como reserva de valor o como buena cobertura, especialmente en tiempos de incertidumbre política, económica y financiera.

Por lo tanto, el oro puede ser visto como un activo refugio y observarse lo que se conoce en la literatura económica como “*flight to safety*”, donde los inversores en tiempos de incertidumbre en los mercados financieros venden sus acciones ante la percepción de un riesgo elevado en sus inversiones o para detener la pérdida de valor que pudiera darse en su cartera de acciones invirtiendo en su lugar en activos refugio como el oro en éste caso.

En resumen, el oro es un activo refugio seguro principalmente durante períodos comercializados por temores de recesión, preocupaciones sobre la tasa de inflación y fuerte incertidumbre en los mercados financieros. Además, como se ha demostrado en la literatura financiera, los beneficios obtenidos con carteras diversificadas con oro son mayores que las que no tienen en cuenta este activo (Jaffe, 1989; Chua et al. 1990; Johnson y Soenen, 1997; Davidson et al. 2003).

Por lo que a la correlación del crudo con el S&P 500 se refiere no está claramente definida (Pescatori y Mowry, 2008). Por un lado, observamos como en periodos de recesión económica la correlación es positiva ya que el precio del crudo y el S&P 500 disminuyen y esto se ve en los periodos de 2001 a 2002 y post crisis financiera en 2009. Por otro lado, en la crisis financiera del 2008, dicha correlación cae a niveles negativos de -0,3 puntos y alcanza otro mínimo de aproximadamente el mismo valor en febrero de 2011. Posteriormente es positiva, aunque con fluctuaciones importantes. En términos generales, podemos decir que a partir de finales de 2008 es el *commodity* que presenta una mayor correlación en comparación con el resto.

Figura 3. Correlación condicional a lo largo del periodo muestral



Fuente: Elaboración propia

Los *commodities* de alguna manera se comportan independientemente de los rendimientos globales de acciones y bonos lo que hace que ésta característica sea buscada por inversores adversos al riesgo que utilizarían los *commodities* para la diversificación del riesgo de sus carteras.

4.4.- Análisis comparativo de las correlaciones obtenidas en la crisis financiera de 2008 y el COVID-19

Éste sub-apartado se centra en el análisis comparativo de las correlaciones de los *commodities* con el S&P 500 en la crisis financiera del 2008 y en la del COVID-19.

En la figura 4, observamos las correlaciones obtenidas en las dos crisis y podemos ver en líneas generales comportamientos parecidos, aunque con un efecto más notable en las correlaciones durante la crisis financiera del 2008.

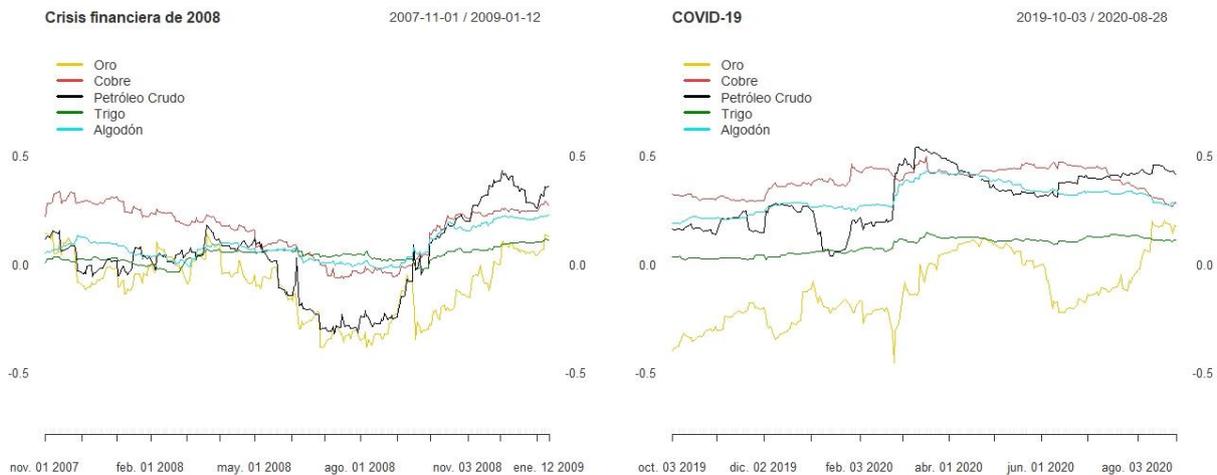
En primer lugar, *commodities* como el trigo y el algodón presentan una correlación muy parecida en las dos crisis, siendo bastante estable en ambos casos, aunque con niveles distintos en el caso de algodón, el cual, durante la crisis financiera de 2008 presentaba una correlación casi nula muy próxima cero y en periodos de COVID-19 de 0.3 aproximadamente.

En segundo lugar, el cobre presenta diferencias sustanciales en las dos crisis. Vemos como característica común que el cobre presentaba mayores niveles de correlación en periodos pre-crisis, sin embargo, tras la crisis financiera de 2008 éste pasa a ser el *commodity* con menor correlación positiva situándose a niveles parecidos a los del trigo y el algodón, cosa que no ocurre tras la epidemia del COVID-19 donde generalmente se mantiene con la mayor correlación.

En el caso del oro, en ambas crisis el nivel de correlación cae a niveles negativos, aunque en el caso del COVID-19 es el único *commodity* que presenta una correlación negativa con el S&P 500. Además, vemos que tras el punto más crítico de ambas crisis el oro presenta una tendencia creciente en lo que ha correlación se refiere.

Finalmente, vemos que la correlación del crudo es muy diferente en ambas crisis. En la crisis financiera vemos que éste tiene una correlación muy parecida a la del oro cayendo por lo tanto a niveles negativos, sin embargo, en el COVID-19 la correlación es siempre positiva. Al igual que el oro, la correlación del crudo aumenta tras el momento crítico de ambas crisis y se sitúa a niveles muy parecido a los del cobre y el algodón, llegando a presentar una mayor correlación en momentos posteriores. Sin embargo, a diferencia del oro, el petróleo no actúa como un activo refugio en ésta última crisis.

Figura 4. Correlación condicional durante la crisis financiera de 2008 y el COVID-19



Fuente: Elaboración propia

4.5.- Relación no lineal

En el apartado anterior, hemos analizado la relación lineal entre los *commodities* y el S&P 500 a través de la estimación de la correlación condicional. En este apartado, estamos interesados en analizar la relación no lineal entre los *commodities* y el S&P 500. Es posible que la relación entre las variables no sea homogénea a lo largo de la distribución y, por tanto, que el efecto de la variable predictor sobre la variable dependiente difiera entre los diferentes cuantiles de la variable respuesta. Para ello recurriremos al modelo de regresión cuantílica propuesto por Koenker y Basset (1978), el cual nos permitirá modelizar la relación entre los *commodities* y el índice S&P 500 en los diferentes cuantiles.

En la tabla 9 observamos los resultados de la estimación de los coeficientes β de la regresión cuantílica, los cuales nos indican el efecto de la variable independiente en el cuantil específico de la variable dependiente, siendo la variable endógena o dependiente los precios de los *commodities* en cuestión y la variable exógena o independiente el índice S&P 500. La tabla 9 también muestra el coeficiente β de la estimación por *mínimos cuadrados ordinarios (MCO)*.

Los resultados de las estimaciones por MCO indican que el S&P 500 presenta un efecto positivo sobre la media de los precios de los distintos *commodities*, siendo además dicho coeficiente significativamente diferente de cero para todos los *commodities*, *excepto el oro*. En el caso del oro, el efecto es negativo, pero no significativo

Sin embargo, los resultados de la regresión cuantílica muestran un efecto significativo y negativo del S&P500 sobre el oro en los cuantiles comprendidos entre 0,40 y 0,90, siendo en general el efecto mayor en los cuantiles más altos. Éstos coeficientes son significativamente diferentes del coeficiente estimado por MCO entre los cuantiles 0,50 y 0,80, tal y como observamos en la figura 5. Por otro lado, observamos que el S&P 500 tiene un mayor efecto (positivo) en el petróleo seguido del cobre, aunque éste último

presenta un efecto mayor en los cuantiles mayores (véase cuantil 0,90 y 0,95). Además, si comparamos el coeficiente estimado por MCO con el coeficiente estimado para los diferentes cuantiles, observamos que, en el caso del cobre, existen diferencias significativas en los cuantiles intermedios cercanos a la mediana y, en el caso del petróleo, únicamente en los cuantiles mayores (véase figura 5).

El efecto menor del S&P 500 lo observamos en el trigo, siendo este bastante similar para los distintos cuantiles aunque algo inferior en la mediana y en los cuantiles superiores. Por lo que a las diferencias significativas en relación al MCO, éstas son inexistentes.

Finalmente, vemos que para el caso del algodón adicionalmente presenta diferencias significativas diferentes a MCO en el cuantil de la mediana tal y como observamos en la figura 5.

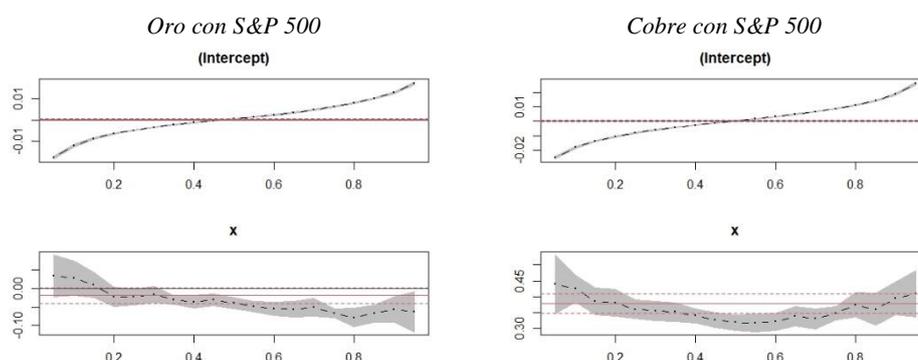
Hemos visto por lo tanto que el caso más significativo de diferencias sería en el caso del oro dado que la estimación por MCO nos indica que no hay efecto, pero por regresión cuantílica obtenemos que en determinados cuantiles sí que los hay (véase 0,5 a 0,8) y por ende es éste caso es más interesante aplicar técnicas no lineales para analizar su relación con el S&P. Asimismo remarcamos que el efecto del S&P es positivo en todos los *commodities* menos oro lo cual nos reafirma la posible actuación del mismo como activo refugio tal y como vimos en el análisis de la relación lineal.

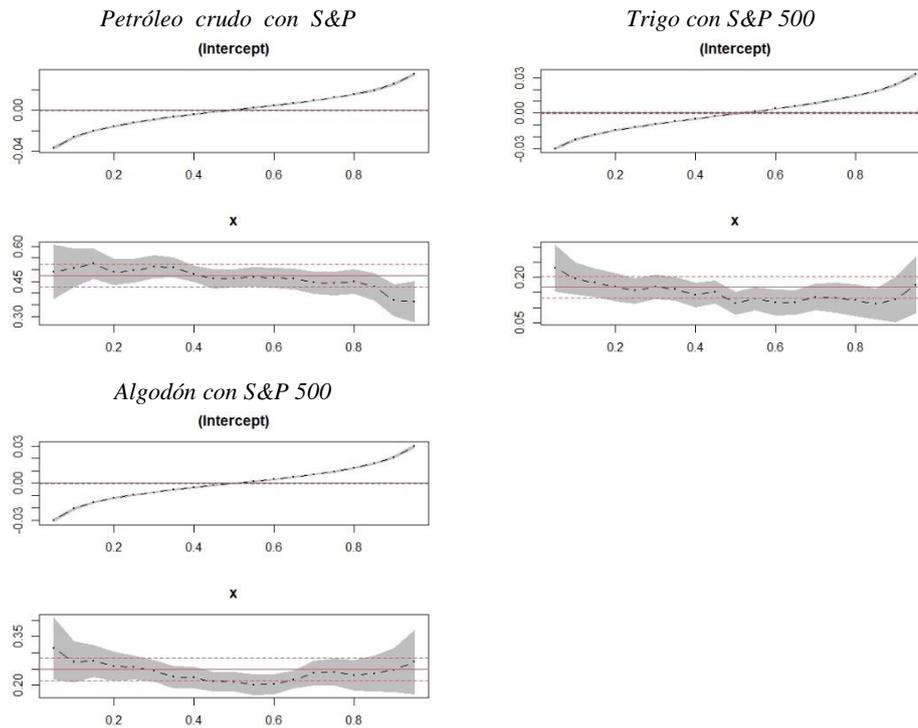
Tabla 9. Resultados de la estimación de los coeficientes β de la regresión cuantílica de los *commodities* con el S&P 500

	MCO	0,05	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	0,95
Oro	-0,0192	0,0345	0,0281	-0,0230	-0,0169	-0,0358	-0,0395	-0,0546	-0,0505	-0,0783	-0,0573	-0,0631
Cobre	0,3795	0,4392	0,4252	0,3805	0,3556	0,3402	0,3186	0,3219	0,3309	0,37407	0,3949	0,4085
Petróleo Crudo	0,4760	0,4914	0,5077	0,4903	0,5125	0,4821	0,4630	0,4650	0,4454	0,4497	0,3697	0,3638
Trigo	0,1681	0,2322	0,1953	0,1678	0,1683	0,1416	0,1141	0,1164	0,1348	0,1243	0,1265	0,1746
Algodón	0,2495	0,3146	0,2723	0,2590	0,2448	0,2236	0,2109	0,2026	0,2383	0,2307	0,2477	0,2719

Fuente: Elaboración propia. Nota: (*) significación al 5%.

Figura 5. Coeficientes β de la regresión cuantílica de los *commodities* con el S&P 500 para los diferentes cuantiles comparada con la estimación por MCO





Fuente: Elaboración propia, siendo la “línea roja” el coeficiente estimado por MCO, las “líneas discontinuas rojas” el intervalo de confianza del coeficiente estimado por MCO, los puntos negros los coeficientes de la regresión cuantílica correspondientes al cuantil indicado en el eje de abscisas y la zona sombreada el intervalo de confianza de los mismos.

5.- CONCLUSIONES

En éste trabajo se ha analizado y estudiado la relación lineal y no lineal de cinco *commodities* estratégicos, el oro, el petróleo crudo, el cobre, el trigo y el algodón con el S&P 500 como índice representativo bursátil más importante de EEUU a lo largo de las dos últimas décadas.

Hemos partido de un análisis histórico previo de todas nuestras series de precios de *commodities* y del índice S&P 500 así como un análisis de estacionariedad y descriptivo de los rendimientos de los mismos para poner en contexto nuestro análisis y una mayor comprensión de los resultados posteriores. Una vez realizados dichos análisis, hemos obtenido las correlaciones incondicionales entre *commodities* y el S&P, la cual es positiva en todos los casos a excepción del oro donde esta es negativa.

Posteriormente, hemos estimado un modelo para la media condicional y un modelo para la varianza condicional de cada una de las series objeto de nuestro análisis, lo cual nos ha sido de gran utilidad para realizar un análisis exhaustivo de la volatilidad, así como un análisis comparativo de la volatilidad individual de cada uno de los precios de *commodities* y el S&P. En éste análisis comparativo hemos observado que la volatilidad de los *commodities* y el S&P 500 se ve incrementada de forma clara en 2008 con la crisis financiera y el petróleo ha sido el *commodity* más volátil a lo largo del periodo muestral.

Mediante el modelo de correlación condicional dinámico DCC-GARCH propuesto por Engle (2002) hemos analizado la relación lineal, donde hemos obtenido la correlación cambiante a lo largo del tiempo entre el precio de los *commodities* y el índice S&P 500 lo que nos ha permitido realizar una comparativa entre correlaciones condicionales obtenidas así como entre las crisis financiera de 2008 y la del COVID-19, siendo estas negativa en el caso del oro, moderadas en el caso del petróleo y el cobre y pequeñas en el caso del trigo y el algodón. En la comparativa entre crisis financiera y crisis COVID-19 hemos observado que las correlaciones son parecidas, aunque no para el petróleo crudo, ya que éste no actúa como un activo refugio en la crisis COVID-19 a diferencia de la crisis financiera de 2008.

También se analizado la relación no lineal entre los *commodities* y el S&P 500 ya que posible que la relación entre las variables no sea homogénea a lo largo de la distribución, recurriendo al modelo de regresión cuantílica propuesto por Koenker y Basset (1978) para los diferentes cuantiles, comparándolo a su vez con las estimaciones por mínimos cuadrados ordinarios (MCO). En éste análisis hemos visto que en la mayoría los *commodities*, el índice S&P 500 tiene un efecto positivo y significativo tanto en MCO como en los distintos cuantiles, siendo nuevamente mayor el efecto en el petróleo y el menor en el trigo. Sin embargo, hemos visto que el caso más significativo de diferencias es el del oro el cual nos indica que no hay efecto al realizar la estimación por MCO, pero si se ha obtenido efecto en cuantiles próximos a la mediana y superiores, siendo dicho efecto negativo a diferencia de los otros *commodities* analizados.

Podemos concluir que los *commodities* de alguna manera se comportan independientemente de los rendimientos globales de acciones dadas las pequeñas correlaciones y efectos del S&P 500 sobre los mismos, destacando especialmente el oro que puede ser visto como un activo refugio. Por ese motivo, los *commodities* son interesantes para inversores adversos al riesgo que busquen diversificación del riesgo de sus carteras especialmente en tiempos de crisis.

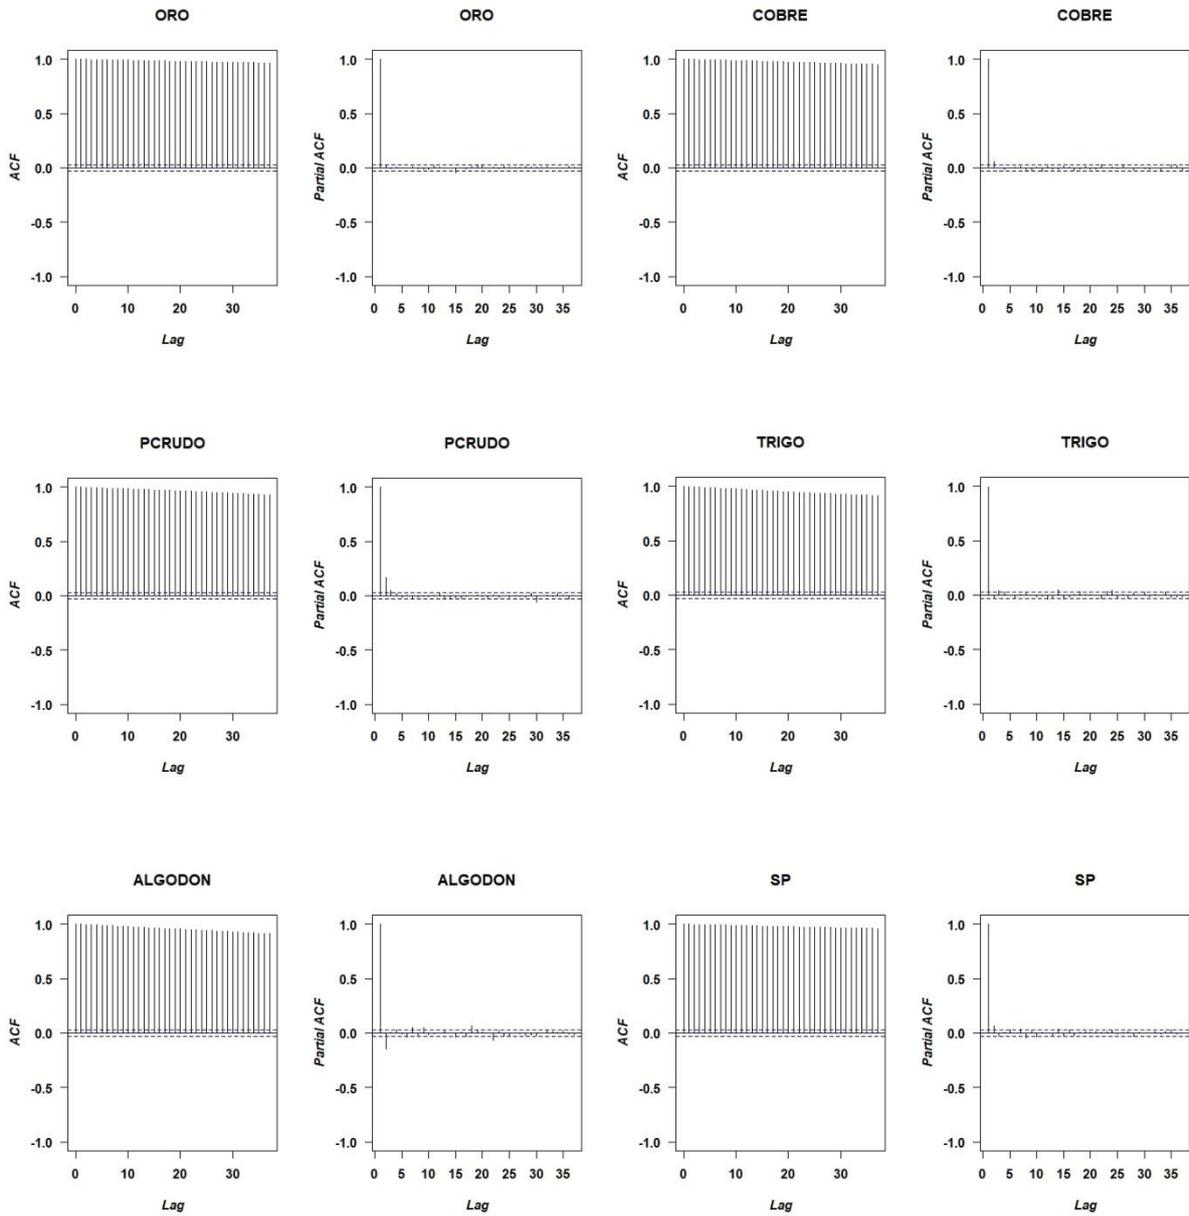
6.- REFERENCIAS

- Abbott, P. and Battisti, A. (2009). “*Recent Global Food Price Shocks: Causes, Consequences and Lessons for African Governments and Donors*”. Journal of African Economies. Volume: 20, 12-62.
- Abbott, P., Hurt, C. and Tyner, W. (2008). “*What’s driving food prices?*” Report for the Farm Foundation. Oak Brook, Illinois (EEUU)
- Bain, C. (2013). “*Guide to commodities. Producers, layers and prices markets, consumers and trends*”. London. The Economist Newspaper Ltd.
- Büyükaşahin, B., Haigh, M. and Robe, M. (2010). “*Commodities and Equities: Ever a Market of One?*” The Journal of Alternative Investments. Volume: 12, 76-95.
- Caporin, M., Chang, C.L. and McAleer, M. (2016). “*Are the S&P 500 Index and Crude Oil, Natural Gas and Ethanol Futures Related for Intra-Day Data?*” International Review of Economics and Finance. Volume: 59, 50-70.
- Chong, J. and Miffre, J. (2010). “*Conditional correlation and volatility in commodity futures and traditional asset markets.*” The Journal of Alternative Investments. Volume: 3, 64-75.
- Chua, J., Sick, G., and Woodward, R. (1990). “*Diversifying with gold stocks.*” Financial Analysts Journal, 46, 76-79.
- Creti, A., Joëts, M. and Mignon, V. (2013) “*On the links between stock and commodity markets volatility.*” Energy Economics, Volume: 37, 16-28.
- Davidson, S., Faff, R., and Hillier, D. (2003). “*Gold factor exposures in international asset pricing.*” Journal of International Financial Markets, Institutions and Money, 13, 271-289.
- Farooki, M. Z. and R. Kaplinsky. (2011). “*The Impact of China on Global Commodities: The Disruption of the World’s Resource Sector*”. (Cantwell, J. and Mowery, D. Eds.). London. Routledge.
- Filis, G., Degiannakis, S. and Floros, C. (2011). “*Dynamic correlation between stock market and oil prices: the case of oil-importing and oil-exporting countries.*” International Review of Financial Analysis. Volume: 20, 152-164.
- Henderson, B.J., Pearson, N.D. and Wang, L. (2015). “*New Evidence on the Financialization of Commodity Markets.*” The Review of Financial Studies. Volume: 28, 1285-1311.
- Jaffe, J. (1989). “*Gold and gold stocks as investments for institutional portfolios.*” Financial Analysts Journal. Volume: 45, 53-59.
- Johnson, R., and Soenen, L. (1997). “*Gold as an investment asset perspectives from different countries.*” Journal of Investing. Volume: 6, 94-99.
- Jones, C. M., and Kaul, G. (1996). “*Oil and the stock market.*” Journal of Finance, Volume: 51, 463-491

- Pescatori, A., and Mowry, B. (2008). “*Economic Activity: Do oil prices directly affect the stock market? Economic Trends Federal Reserve.*” Bank of Cleveland (EEUU). Available at <https://fraser.stlouisfed.org/title/economic-trends-federal-reserve-bank-cleveland-3952/economic-trends-september-2008-493059/economic-activity-505150>
- Sadorsky, P. (1999) “*Oil price shocks and stock market activity*”, Energy Economics, Volume: 21, 449-469.
- Tang, K., Xiong, W. (2012) “*Index Investment and the Financialization of Commodities.*” Financial Analysts Journal. Volume: 68, 54-74.
- Vivian, A. and Wohar, M.E. (2012). “*Commodity volatility breaks.*” Journal of International Financial Markets, Institutions and Money. Volume: 22, 395-422.
- Wei, L. (2018). “*Cotton Price Trends in 2017/18.*”. Article from: The International Cotton Advisory Committee (ICAC), Washington (EEUU). Available at <https://icac.org/Publications/PastIssues?Id=1144>

ANEXOS

Anexo 1.- Gráficos ACF y PACF de las series



Fuente: Elaboración propia.

Anexo 2.- Script del código R

```
#####  
#Instalación de packages y libraries#  
#####  
install.packages("tseries")  
  
library(tseries)  
  
install.packages("fBasics")  
  
library(fBasics)  
  
install.packages("car")  
  
library(car)  
  
install.packages("urca")  
  
library(urca)  
  
install.packages("forecast")  
  
library(forecast)  
  
install.packages("fGarch")  
  
library(fGarch)  
  
install.packages("rugarch")  
  
library(rugarch)  
  
install.packages("quantmod") #Este package es para importar los datos directamente de Yahoo finance  
  
library(quantmod)  
  
  
  
install.packages("ggplot2") #para la estacionariedad de los modelos de la media  
  
library(ggplot2)  
  
install.packages("xts") #para cambiar las frecuencias de las series  
  
library(xts)  
  
#####  
  
#Importamos stock markets de Yahoo Finance  
  
#####  
  
#S&P 500  
  
getSymbols("^GSPC",from="2000-09-01", to="2020-08-29")  
  
SP<-na.locf(GSPC, fromLast = TRUE)  
  
dim(SP)  
  
SP=SP[,6]  
  
head(SP)  
  
tail(SP)
```

```
rendsp=diff(log(SP))
plot(rendsp)
rendsp<-rendsp[-1] #eliminamos la primera observación que ahora es NA porque si no, el contraste da un error
```

```
#Plots indices
```

```
indices<-cbind(SP);indices
```

```
head(indices)
```

```
plot(indices[,1],col="blue3",ylim=c(0,5000),lwd=2,grid.col = NA,main="S&P 500")
```

```
#Importamos precios de commodities
```

```
#Oro
```

```
ORO<-read.table("Anual.csv",sep=";",header=TRUE)
```

```
head(ORO)
```

```
tail(ORO)
```

```
ORO<-ORO[3];ORO
```

```
#cobre
```

```
COBRE<-read.table("Anual.csv",sep=";",header=TRUE)
```

```
head(COBRE)
```

```
tail(COBRE)
```

```
COBRE<-COBRE[4];COBRE
```

```
dim(COBRE)
```

```
#Petroleo Crudo
```

```
PCRUDO<-read.table("Anual.csv",sep=";",header=TRUE)
```

```
head(PCRUDO)
```

```
tail(PCRUDO)
```

```
PCRUDO<-PCRUDO[5];PCRUDO
```

```
dim(PCRUDO)
```

```
#Trigo
```

```
TRIGO<-read.table("Anual.csv",sep=";",header=TRUE)
```

```

head(TRIGO)
tail(TRIGO)
TRIGO<-TRIGO[6];TRIGO
dim(TRIGO)

#Algodon
ALGODON<-read.table("Anual.csv",sep=";",header=TRUE)
head(ALGODON)
tail(ALGODON)
ALGODON<-ALGODON[7];ALGODON
dim(ALGODON)

#Grafico precio commodities
oro<-ORO[c(0:5029),]
cobre<-COBRE[c(0:5029),]
pcrudo<-PCRUDO[c(0:5029),]
trigo<-TRIGO[c(0:5029),]
algodon<-ALGODON[c(0:5029),]

commodities<-cbind(SP,oro,cobre,pcrudo,trigo,algodon);commodities
head(commodities)
tail(commodities)

#####3##### PLOTS INDIVIDUALES #####
plot(commodities[,2],col="gold2",ylim=c(0,2200),lwd=2,grid.col = NA,main="Gold prices")
plot(commodities[,3],col="brown2",ylim=c(0,6),lwd=2,grid.col = NA,main="Copper prices")
plot(commodities[,4],col="black",ylim=c(0,200),lwd=2,grid.col = NA,main="Crude Oil prices")
plot(commodities[,5],col="green4",ylim=c(0,1250),lwd=2,grid.col = NA,main="Wheat prices")
plot(commodities[,6],col="turquoise2",ylim=c(0,250),lwd=2,grid.col = NA,main="Cotton prices")

#Rendimientos de los commodities
rendoro=diff(log(commodities[,2]))
plot(rendoro)
rendoro<-rendoro[-1]
head(rendoro)

```

```
rendcobre=diff(log(commodities[,3]))
plot(rendcobre)
rendcobre<-rendcobre[-1]
head(rendcobre)
```

```
rendpcrudo=diff(log(commodities[,4]))
plot(rendpcrudo)
rendpcrudo<-rendpcrudo[-1]
head(rendpcrudo)
```

```
rendtrigo=diff(log(commodities[,5]))
plot(rendtrigo)
rendtrigo<-rendtrigo[-1]
head(rendtrigo)
```

```
rendalgodon=diff(log(commodities[,6]))
plot(rendalgodon)
rendalgodon<-rendalgodon[-1]
head(rendalgodon)
```

```
##### MODELO PARA LA MEDIA CONDICIONAL #####
```

```
#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test – ORO
```

```
win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
#c(2,1) means two rows and one column.
acf(ORO,ylim=c(-1,1),main="ORO")
pacf(ORO,ylim=c(-1,1),main="ORO")
```

```
dev.off()
```

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

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

```

Box.test(ORO, lag = 10, type = c("Ljung-Box"))
Box.test(ORO, lag = 15, type = c("Ljung-Box"))
Box.test(ORO, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)

#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - ORO

#Dickey-Fuller

#series de precios

ORO.df<-ur.df(commodities[,2], type = c("drift"),lags=20, selectlags = c("BIC")) #NRHo
summary(ORO.df)
plot(ORO.df)

ORO.df<-ur.df(commodities[,2], type = c("drift"),lags=20, selectlags = c("AIC")) #NRHo
summary(ORO.df)
plot(ORO.df)

ORO.df<-ur.df(commodities[,2], type = c("drift"), lags = 2) #NRHo
summary(ORO.df)
plot(ORO.df)

ORO.df<-ur.df(commodities[,2], type = c("trend"), lags = 2)
summary(ORO.df)
plot(ORO.df)

#series de rendimientos
rendoro.df<-ur.df(rendoro, type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
summary(rendoro.df)
plot(rendoro.df)

#Phillips Perron -ORO
#series de precios
ORO.pp<-ur.pp(commodities[,2], type = c("Z-tau"), model = c("constant"), lags = c("short")) #NRho

```

```
summary(ORO.pp)
```

```
ORO.pp<-ur.pp(commodities[,2], type = c("Z-tau"), model = c("constant"), lags = c("long")) #NRho
```

```
summary(ORO.pp)
```

```
#series de rendimientos
```

```
rendoro.pp<-ur.pp(diff(log(commodities[,2])), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es estacionaria
```

```
summary(rendoro.pp)
```

```
rendoro.pp<-ur.pp(diff(log(commodities[,2])), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es estacionaria
```

```
summary(rendoro.pp)
```

```
#KPSS
```

```
ORO.kpss<-ur.kpss(commodities[,2], type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
```

```
summary(ORO.kpss)
```

```
rendoro.kpss<-ur.kpss(diff(log(commodities[,2])), type = c("mu"), lags = c("short")) #NRho, serie estacionaria
```

```
summary(rendoro.kpss)
```

```
#####
```

```
#FASE 1: IDENTIFICACIÓN DEL MODELO###
```

```
#fac, facp y Ljung-Box test
```

```
win.graph(width=8,height=5)
```

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

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

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

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

```

Box.test(rendoro, lag = 2, type = c("Ljung-Box"))
Box.test(rendoro, lag = 3, type = c("Ljung-Box"))
Box.test(rendoro, lag = 4, type = c("Ljung-Box"))
Box.test(rendoro, lag = 5, type = c("Ljung-Box"))
Box.test(rendoro, lag = 10, type = c("Ljung-Box"))
Box.test(rendoro, lag = 15, type = c("Ljung-Box"))
Box.test(rendoro, lag = 20, type = c("Ljung-Box"))

```

#FASE 2: ESTIMACIÓN DEL MODELO

```

#arma(1,1)
model3 = arima(rendoro, order = c(1,0,1),include.mean = TRUE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendoro)))
bic

```

```

#ar(2)
model4 = arima(rendoro, order = c(2,0,0),include.mean = TRUE)
model4
pnorm(c(abs(model4$coef)/sqrt(diag(model4$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model4,k = log(length(rendoro)))
bic

```

```

#arma(0,0)
model3 = arima(rendoro, order = c(0,0,0),include.mean = TRUE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendoro)))
bic

```

#ELEJIMOS EN FUNCIÓN DE LOS CRITERIOS DE INFORMACIÓN (SOLO NOS DA EL AIC)

#auto.arima, utiliza el criterio aicc (corregido para muestras pequeñas)

```

model6 = auto.arima(rendoro, ic="aic")#si ponemos el criterio de información, no nos devuelve los p-valores
model6
pnorm(c(abs(model6$coef)/sqrt(diag(model6$var.coef))), mean=0, sd=1, lower.tail=FALSE)

#####
# FASE3: DIAGNOSIS
#####

#Estacionariedad del modelo

#todas las raíces del polinomio característico deben caer fuera del círculo unitario
plot(model3) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model

# Análisis de los residuos
tsdiag(model3) #dibuja los residuos estandarizados, la ACF de los residuos y los pvalues del Ljung-Box test

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(model3$residuals,ylim=c(-1,1),main="Residuos arma(0,0)")
pacf(model3$residuals,ylim=c(-1,1),main="Residuos arma(0,0)")

qqnorm(model3$residuals)
qqline(model3$residuals, datax = FALSE)

plot(model3$residuals)
title (main="Gráfico de los residuos")
normalTest(model3$residuals,method="jb") #o jarque.bera.test(model$residuals)

##### MODELO CONDICIONAL PARA LA VARIANZA #####
##### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH ORO #####

# ACF y PACF de los residuos al cuadrado
residuos=model3$residuals
residuos2=residuos^2

```

```
win.graph(width=8,height=5)
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")
```

```
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')
```

```
# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS
```

```
# MA (1)-GARCH(1,1) con distribución 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=rendoro)
m1
```

```
#obtención de los residuos
```

```
plot(m1)
```

```
# MA (1)-GARCH(1,1) con distribución 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=rendoro)
m2
```

```
# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
```

```
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(0,1), archm=TRUE, archpow=1), distribution.model = "std")
m3=ugarchfit(spec=spec1,data=rendoro)
m3
```

```
v = sigma(m2)#para obtener la volatilidad estimada,
v_anualizadaoro=(250)^0.5*v
plot(v_anualizadaoro)
```

```
##### MODELO PARA LA MEDIA CONDICIONAL #####
```

```
#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test - COBRE
```

```
win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
#c(2,1) means two rows and one column.
acf(COBRE,ylim=c(-1,1),main="COBRE")
pacf(COBRE,ylim=c(-1,1),main="COBRE")
```

```
dev.off()
```

```
Box.test(COBRE, lag = 1, type = c("Ljung-Box"))
Box.test(COBRE, lag = 5, type = c("Ljung-Box"))
Box.test(COBRE, lag = 10, type = c("Ljung-Box"))
Box.test(COBRE, lag = 15, type = c("Ljung-Box"))
Box.test(COBRE, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)
```

```
#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - COBRE
```

```
#Dickey-Fuller
```

```
#series de precios
```

```
COBRE.df<-ur.df(commodities[,3], type = c("drift"),lags=20, selectlags = c("BIC")) #NRHo
summary(COBRE.df)
plot(COBRE.df)
```

```
COBRE.df<-ur.df(commodities[,3], type = c("drift"),lags=20, selectlags = c("AIC")) #NRHo
summary(COBRE.df)
```

```
plot(COBRE.df)
```

```
COBRE.df<-ur.df(commodities[,3], type = c("drift"), lags = 2) #NRHo
```

```
summary(COBRE.df)
```

```
plot(COBRE.df)
```

```
COBRE.df<-ur.df(commodities[,3], type = c("trend"), lags = 2) #NRHo
```

```
summary(COBRE.df)
```

```
plot(COBRE.df)
```

```
#series de rendimientos
```

```
rendcobre.df<-ur.df(rendcobre, type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
```

```
summary(rendcobre.df)
```

```
plot(rendcobre.df)
```

```
#Phillips Perron -COBRE
```

```
#series de precios
```

```
COBRE.pp<-ur.pp(commodities[,3], type = c("Z-tau"), model = c("constant"), lags = c("short")) #Rho
```

```
summary(COBRE.pp)
```

```
COBRE.pp<-ur.pp(commodities[,3], type = c("Z-tau"), model = c("constant"), lags = c("long")) #Rho
```

```
summary(COBRE.pp)
```

```
#series de rendimientos
```

```
rendcobre.pp<-ur.pp(diff(log(commodities[,3])), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es estacionaria
```

```
summary(rendcobre.pp)
```

```
rendcobre.pp<-ur.pp(diff(log(commodities[,3])), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es estacionaria
```

```
summary(rendcobre.pp)
```

```
#KPSS
```

```
COBRE.kpss<-ur.kpss(commodities[,3], type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
```

```
summary(COBRE.kpss)
```

```
rendcobre.kpss<-ur.kpss(diff(log(commodities[,3])), type = c("mu"), lags = c("short")) #NRrho, serie estacionaria
```

```
summary(rendcobre.kpss)
```

```
#####
```

```
#FASE 1: IDENTIFICACIÓN DEL MODELO###
```

```
#fac, facp y Ljung-Box test
```

```
win.graph(width=8,height=5)
```

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

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

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

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

```
Box.test(rendcobre, lag = 2, type = c("Ljung-Box"))
```

```
Box.test(rendcobre, lag = 3, type = c("Ljung-Box"))
```

```
Box.test(rendcobre, lag = 4, type = c("Ljung-Box"))
```

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

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

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

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

```
#FASE 2: ESTIMACIÓN DEL MODELO
```

```
#ar(1)
```

```
model = arima(rendcobre, order = c(1,0,0),include.mean = TRUE)
```

```
model
```

```
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
model$aic
```

```
model$bic
```

```
bic=AIC(model,k = log(length(rendcobre))) #no podemos recuperar directamente model$bic, pero model$aic sí
```

bic

```
model = arima(rendcobre, order = c(1,0,0),include.mean = FALSE)
```

model

```
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

model\$aic

model\$bic

```
bic=AIC(model,k = log(length(rendcobre))) #no podemos recuperar directamente model$bic, pero model$aic sí
```

bic

```
#arma(1,1)
```

```
model3 = arima(rendcobre, order = c(1,0,1),include.mean = TRUE)
```

model3

```
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model3,k = log(length(rendcobre))) #no podemos recupera directamente mode$bic, pero model$aic sí
```

bic

```
model3 = arima(rendcobre, order = c(1,0,1),include.mean = FALSE)
```

model3

```
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model3,k = log(length(rendcobre))) #no podemos recupera directamente mode$bic, pero model$aic sí
```

bic

```
#ma(1)
```

```
model4 = arima(rendcobre, order = c(0,0,1),include.mean = TRUE)
```

model4

```
pnorm(c(abs(model4$coef)/sqrt(diag(model4$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model4,k = log(length(rendcobre))) #no podemos recupera directamente mode$bic, pero model$aic sí
```

bic

```
model4 = arima(rendcobre, order = c(0,0,1),include.mean = FALSE)
```

model4

```
pnorm(c(abs(model4$coef)/sqrt(diag(model4$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model4,k = log(length(rendcobre))) #no podemos recupera directamente mode$bic, pero model$aic sí
```

bic

```
#####
```

```
# FASE3: DIAGNOSIS #Nos quedamos con AR 1
```

```
#####
```

```
#Estacionariedad del modelo
```

```
#todas las raíces del polinomio característico deben caer fuera del círculo unitario
```

```
plot(model) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model
```

```
# Análisis de los residuos
```

```
tsdiag(model) #hay autocorrelación en 2 retardo
```

```
win.graph(width=8,height=5)
```

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

```
acf(model$residuals,ylim=c(-1,1),main="Residuos arma(1,0)")
```

```
pacf(model$residuals,ylim=c(-1,1),main="Residuos arma(1,0)")
```

```
##### MODELO PARA LA VARIANZA CONDICIONAL #####
```

```
##### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH COBRE #####
```

```
# ACF y PACF de los residuos al cuadrado
```

```
residuos=model$residuals
```

```
residuos2=residuos^2
```

```
win.graph(width=8,height=5)
```

```
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")
```

```
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')
```

```

Box.test(residuos2,lag=30,type='Ljung')
Box.test(residuos2,lag=40,type='Ljung')

# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS

# MA (1)-GARCH(1,1) con distribución Normal
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(1,0)), distribution.model = "norm")
m1=ugarchfit(spec=spec1,data=rendcobre)
m1

#obtención de los residuos
#plot(m1)

# MA (1)-GARCH(1,1) con distribución t-student
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(1,0)), distribution.model = "std")
m2=ugarchfit(spec=spec1,data=rendcobre)
m2

# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(1,1), archm=TRUE, archpow=1), distribution.model = "std")
m3=ugarchfit(spec=spec1,data=rendcobre)
m3

v = sigma(m2)#para obtener la volatilidad estimada,
v_anualizadacobre=(250)^0.5*v
plot(v_anualizadacobre)

##### MODELO PARA LA MEDIA CONDICIONAL #####

#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test - PCRUDO

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)

```

#c(2,1) means two rows and one column.

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

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

```
dev.off()
```

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

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

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

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

```
Box.test(PCRUDO, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)
```

#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - PCRUDO

```
#Dickey-Fuller
```

```
#series de precios
```

```
PCRUDO.df<-ur.df(commodities[,4], type = c("drift"),lags=20, selectlags = c("BIC")) #NRHo
```

```
summary(PCRUDO.df)
```

```
plot(PCRUDO.df)
```

```
PCRUDO.df<-ur.df(commodities[,4], type = c("drift"),lags=20, selectlags = c("AIC")) #RHo
```

```
summary(PCRUDO.df)
```

```
plot(PCRUDO.df)
```

```
PCRUDO.df<-ur.df(commodities[,4], type = c("drift"), lags = 2) #NRHo
```

```
summary(PCRUDO.df)
```

```
plot(PCRUDO.df)
```

```
PCRUDO.df<-ur.df(commodities[,4], type = c("trend"), lags = 2) #NRHo
```

```
summary(PCRUDO.df)
```

```
plot(PCRUDO.df)
```

```

#series de rendimientos
rendp crudo.df<-ur.df(na.omit(rendp crudo), type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
summary(rendp crudo.df)
plot(rendp crudo.df)

#Phillips Perron -PCRUDO
#series de precios
PCRUDO.pp<-ur.pp(commodities[,4], type = c("Z-tau"), model = c("constant"), lags = c("short")) #NRho
summary(PCRUDO.pp)

PCRUDO.pp<-ur.pp(commodities[,4], type = c("Z-tau"), model = c("constant"), lags = c("long")) #NRho
summary(PCRUDO.pp)

#series de rendimientos

rendp crudo.pp<-ur.pp(diff(log(commodities[,4])), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es
estacionaria
summary(rendp crudo.pp)

rendp crudo.pp<-ur.pp(diff(log(commodities[,4])), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es
estacionaria
summary(rendp crudo.pp)

#KPSS

PCRUDO.kpss<-ur.kpss(commodities[,4], type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
summary(PCRUDO.kpss)

rendp crudo.kpss<-ur.kpss(diff(log(commodities[,4])), type = c("mu"), lags = c("short")) #NRho, serie estacionaria
summary(rendp crudo.kpss)

#####
#FASE 1: IDENTIFICACIÓN DEL MODELO###

#fac, facp y Ljung-Box test

```

```

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(na.omit(rendpcrudo),ylim=c(-1,1),main="rendpcrudo")
pacf(na.omit(rendpcrudo),ylim=c(-1,1),main="rendpcrudo")

```

```

Box.test(rendpcrudo, lag = 1, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 2, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 3, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 4, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 5, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 10, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 15, type = c("Ljung-Box"))
Box.test(rendpcrudo, lag = 20, type = c("Ljung-Box"))

```

#FASE 2: ESTIMACIÓN DEL MODELO

```

#ar(1)
model = arima(na.omit(rendpcrudo), order = c(1,0,0),include.mean = TRUE)
model
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
model$aic
model$bic
bic=AIC(model,k = log(length(rendpcrudo)))
bic

```

```

model = arima(rendpcrudo, order = c(1,0,0),include.mean = FALSE)
model
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
model$aic
model$bic
bic=AIC(model,k = log(length(rendpcrudo)))
bic

```

```

#ma(1)
model2 = arima(na.omit(rendpcrudo), order = c(0,0,1),include.mean = TRUE)
model2
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model2,k = log(length(rendpcrudo)))
bic

model2 = arima(rendpcrudo, order = c(0,0,1),include.mean = FALSE) #Nos quedamos con éste
model2
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model2,k = log(length(rendpcrudo)))
bic

#arma(1,1)
model3 = arima(na.omit(rendpcrudo), order = c(1,0,1),include.mean = TRUE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendpcrudo)))
bic

model3 = arima(na.omit(rendpcrudo), order = c(1,0,1),include.mean = FALSE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendpcrudo)))
bic

#####
# FASE3: DIAGNOSIS
#####

#Estacionariedad del modelo
#todas las raíces del polinomio característico deben caer fuera del círculo unitario
plot(model3) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model

```

```

# Análisis de los residuos
tsdiag(model3) #dibuja los residuos estandarizados, la ACF de los residuos y los pvalues del Ljung-Box test

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(model3$residuals,ylim=c(-1,1),main="Residuos arma(1,1)")
pacf(model3$residuals,ylim=c(-1,1),main="Residuos arma(1,1)")

##### MODELO CONDICIONAL PARA LA VARIANZA #####
#### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH PETROLEO CRUDO ####

# ACF y PACF de los residuos al cuadrado
residuos=model3$residuals
residuos2=residuos^2

win.graph(width=8,height=5)
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")

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')

# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS

# MA (1)-GARCH(1,1) con distribución Normal
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(1,1)), distribution.model = "norm")
m1=ugarchfit(spec=spec1,data=na.omit(rendpcrudo))

m1

#obtención de los residuos

```

```
#plot(m1)
```

```
# MA (1)-GARCH(1,1) con distribución t-student
```

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

```
m2=ugarchfit(spec=spec1,data=na.omit(rendpcrudo))
```

```
m2
```

```
# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
```

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

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

```
m3
```

```
v = sigma(m2)#para obtener la volatilidad estimada,
```

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

```
plot(v_anualizadapcrudo)
```

```
##### MODELO PARA LA MEDIA CONDICIONAL #####
```

```
#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test - TRIGO
```

```
win.graph(width=8,height=5)
```

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

```
#c(2,1) means two rows and one column.
```

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

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

```
dev.off()
```

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

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

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

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

```
Box.test(TRIGO, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)
```

#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - TRIGO

#Dickey-Fuller

#series de precios

```
TRIGO.df<-ur.df(commodities[,5], type = c("drift"),lags=20, selectlags = c("BIC")) #NRHo
```

```
summary(TRIGO.df)
```

```
plot(TRIGO.df)
```

```
TRIGO.df<-ur.df(commodities[,5], type = c("drift"),lags=20, selectlags = c("AIC")) #NRHo
```

```
summary(TRIGO.df)
```

```
plot(TRIGO.df)
```

```
TRIGO.df<-ur.df(commodities[,5], type = c("drift"), lags = 2) #NRHo
```

```
summary(TRIGO.df)
```

```
plot(TRIGO.df)
```

```
TRIGO.df<-ur.df(commodities[,5], type = c("trend"), lags = 2) #NRHo
```

```
summary(TRIGO.df)
```

```
plot(TRIGO.df)
```

#series de rendimientos

```
rendtrigo.df<-ur.df(rendtrigo, type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
```

```
summary(rendtrigo.df)
```

```
plot(rendtrigo.df)
```

#Phillips Perron - TRIGO

#series de precios

```
TRIGO.pp<-ur.pp(commodities[,5], type = c("Z-tau"), model = c("constant"), lags = c("short")) #NRho
```

```
summary(ORO.pp)
```

```
TRIGO.pp<-ur.pp(commodities[,5], type = c("Z-tau"), model = c("constant"), lags = c("long")) #NRho
```

```
summary(TRIGO.pp)
```

```
#series de rendimientos
```

```
rendtrigo.pp<-ur.pp(diff(log(commodities[,5])), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es estacionaria
```

```
summary(rendtrigo.pp)
```

```
rendtrigo.pp<-ur.pp(diff(log(commodities[,5])), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es estacionaria
```

```
summary(rendtrigo.pp)
```

```
#KPSS
```

```
TRIGO.kpss<-ur.kpss(commodities[,5], type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
```

```
summary(TRIGO.kpss)
```

```
rendtrigo.kpss<-ur.kpss(diff(log(commodities[,5])), type = c("mu"), lags = c("short")) #NRho, serie estacionaria
```

```
summary(rendtrigo.kpss)
```

```
#####
```

```
#FASE 1: IDENTIFICACIÓN DEL MODELO###
```

```
#fac, facp y Ljung-Box test
```

```
win.graph(width=8,height=5)
```

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

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

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

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

```
Box.test(rendtrigo, lag = 2, type = c("Ljung-Box"))
```

```
Box.test(rendtrigo, lag = 3, type = c("Ljung-Box"))
```

```
Box.test(rendtrigo, lag = 4, type = c("Ljung-Box"))
```

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

```
Box.test(rendtrigo, lag = 10, type = c("Ljung-Box"))
Box.test(rendtrigo, lag = 15, type = c("Ljung-Box"))
Box.test(rendtrigo, lag = 20, type = c("Ljung-Box"))
```

```
#FASE 2: ESTIMACIÓN DEL MODELO
```

```
#ar(1)
```

```
model = arima(rendtrigo, order = c(1,0,0),include.mean = TRUE)
```

```
model
```

```
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
model$aic
```

```
model$bic
```

```
bic=AIC(model,k = log(length(rendtrigo)))
```

```
bic
```

```
model = arima(rendtrigo, order = c(1,0,0),include.mean = FALSE)
```

```
model
```

```
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
model$aic
```

```
model$bic
```

```
bic=AIC(model,k = log(length(rendtrigo)))
```

```
bic
```

```
#ma(1)
```

```
model2 = arima(rendtrigo, order = c(0,0,1),include.mean = TRUE)
```

```
model2
```

```
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model2,k = log(length(rendtrigo)))
```

```
bic
```

```
model2 = arima(rendtrigo, order = c(0,0,1),include.mean = FALSE) #Nos quedamos con éste
```

```
model2
```

```
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model2,k = log(length(rendtrigo)))
```

```
bic
```

```

#arma(1,1)
model3 = arima(rendtrigo, order = c(1,0,1),include.mean = TRUE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendtrigo)))
bic

#arma(0,0)
model3 = arima(rendtrigo, order = c(0,0,0),include.mean = TRUE)
model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendtrigo)))
bic

#####
# FASE3: DIAGNOSIS
#####

#Estacionariedad del modelo
#todas las raíces del polinomio característico deben caer fuera del círculo unitario
plot(model3) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model

# Análisis de los residuos
tsdiag(model3) #dibuja los residuos estandarizados, la ACF de los residuos y los pvalues del Ljung-Box test

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(model3$residuals,ylim=c(-1,1),main="Residuos arma(0,0)")
pacf(model3$residuals,ylim=c(-1,1),main="Residuos arma(0,0)")

##### MODELO PARA LA VARIANZA CONDICIONAL #####
##### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH TRIGO #####

```

```

# ACF y PACF de los residuos al cuadrado
residuos=model3$residuals
residuos2=residuos^2

win.graph(width=8,height=5)
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")

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')

# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS

# MA (1)-GARCH(1,1) con distribución 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=rendtrigo)
m1

#obtención de los residuos
#plot(m1)

# ARMA (0,0)-GARCH(1,1) con distribución 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=rendtrigo)
m2

# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
spec1=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1,1)),
mean.model=list(armaOrder=c(0,1), archm=TRUE, archpow=1), distribution.model = "std")
m3=ugarchfit(spec=spec1,data=rendtrigo)

```

m3

v = sigma(m2)#para obtener la volatilidad estimada,

v_anualizadatrigo=(250)^0.5*v

plot(v_anualizadatrigo)

MODELO PARA LA MEDIA CONDICIONAL

#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test - ALGODON

win.graph(width=8,height=5)

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

#c(2,1) means two rows and one column.

acf(ALGODON,ylim=c(-1,1),main="ALGODON")

pacf(ALGODON,ylim=c(-1,1),main="ALGODON")

dev.off()

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

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

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

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

Box.test(ALGODON, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)

#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - ALGODON

#Dickey-Fuller

#series de precios

ALGODON.df<-ur.df(commodities[,6], type = c("drift"),lags=20, selectlags = c("BIC")) #RHo

summary(ALGODON.df)

plot(ALGODON.df)

```
ALGODON.df<-ur.df(commodities[,6], type = c("drift"),lags=20, selectlags = c("AIC")) #RHo
summary(ALGODON.df)
plot(ALGODON.df)
```

```
ALGODON.df<-ur.df(commodities[,6], type = c("drift"), lags = 2) #RHo
summary(ALGODON.df)
plot(ALGODON.df)
```

```
#series de rendimientos
```

```
rendalgodon.df<-ur.df(rendalgodon, type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
summary(rendalgodon.df)
plot(rendalgodon.df)
```

```
#Phillips Perron -ALGODON
```

```
#series de precios
```

```
ALGODON.pp<-ur.pp(commodities[,6], type = c("Z-tau"), model = c("constant"), lags = c("short")) #Rho
summary(ALGODON.pp)
```

```
ALGODON.pp<-ur.pp(commodities[,6], type = c("Z-tau"), model = c("constant"), lags = c("long")) #Rho
summary(ALGODON.pp)
```

```
#series de rendimientos
```

```
rendalgodon.pp<-ur.pp(diff(log(commodities[,6])), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es
estacionaria
```

```
summary(rendalgodon.pp)
```

```
rendalgodon.pp<-ur.pp(diff(log(commodities[,6])), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es
estacionaria
```

```
summary(rendalgodon.pp)
```

```
#KPSS
```

```
ALGODON.kpss<-ur.kpss(commodities[,6], type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
summary(ALGODON.kpss)
```

```
rendalgodon.kpss<-ur.kpss(diff(log(commodities[,6])), type = c("mu"), lags = c("short")) #NRho, serie estacionaria
summary(rendalgodon.kpss)
```

```
#####
```

```
#FASE 1: IDENTIFICACIÓN DEL MODELO###
```

```
#fac, facp y Ljung-Box test
```

```
win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(rendalgodon,ylim=c(-1,1),main="rendalgodon")
pacf(rendalgodon,ylim=c(-1,1),main="rendalgodon")
```

```
Box.test(rendalgodon, lag = 1, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 2, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 3, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 4, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 5, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 10, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 15, type = c("Ljung-Box"))
Box.test(rendalgodon, lag = 20, type = c("Ljung-Box"))
```

```
#FASE 2: ESTIMACIÓN DEL MODELO
```

```
#ar(1)
model = arima(rendalgodon, order = c(1,0,0),include.mean = TRUE)
model
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
model$aic
model$bic
bic=AIC(model,k = log(length(rendalgodon)))
bic
```

```

model = arima(rendalgodon, order = c(1,0,0),include.mean = FALSE)

model
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
model$aic
model$bic
bic=AIC(model,k = log(length(rendalgodon)))

bic

#ma(1)

model2 = arima(rendalgodon, order = c(0,0,1),include.mean = TRUE)

model2
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model2,k = log(length(rendalgodon)))

bic

model2 = arima(rendalgodon, order = c(0,0,1),include.mean = FALSE)

model2
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model2,k = log(length(rendalgodon)))

bic

#arma(1,1)

model3 = arima(rendalgodon, order = c(1,0,1),include.mean = TRUE)

model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendalgodon)))

bic

model3 = arima(rendalgodon, order = c(1,0,1),include.mean = FALSE)

model3
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
bic=AIC(model3,k = log(length(rendalgodon)))

bic

```

```

#####

# FASE3: DIAGNOSIS

#####

#Estacionariedad del modelo

#todas las raíces del polinomio característico deben caer fuera del círculo unitario

plot(model2) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model

# Análisis de los residuos

tsdiag(model2) #dibuja los residuos estandarizados, la ACF de los residuos y los pvalues del Ljung-Box test

win.graph(width=8,height=5)

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

acf(model2$residuals,ylim=c(-1,1),main="Residuos arma(1,1)")

pacf(model2$residuals,ylim=c(-1,1),main="Residuos arma(1,1)")

##### MODELO PARA LA VARIANZA CONDICIONAL #####

##### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH ALGODÓN #####

# ACF y PACF de los residuos al cuadrado

residuos=model2$residuals

residuos2=residuos^2

win.graph(width=8,height=5)

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")

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')

Box.test(residuos2,lag=30,type='Ljung')

```

```
# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS
```

```
# ARMA (1,1)-GARCH(1,1) con distribución Normal
```

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

```
m1=ugarchfit(spec=spec1,data=rendalgodon)
```

```
m1
```

```
#obtención de los residuos
```

```
#plot(m1)
```

```
# ARMA (1,1)-GARCH(1,1) con distribución t-student
```

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

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

```
m2
```

```
# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
```

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

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

```
m3
```

```
v = sigma(m2)#para obtener la volatilidad estimada,
```

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

```
plot(v_anualizadalgodon)
```

```
##### MODELO PARA LA MEDIA CONDICIONAL #####
```

```
#Contrastes informales: gráfico de la serie, fac, facp y Ljung-Box test - SP
```

```
win.graph(width=8,height=5)
```

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

```
#c(2,1) means two rows and one column.
```

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

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

```
dev.off()
```

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

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

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

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

```
Box.test(SP, lag = 20, type = c("Ljung-Box")) #RHo (p-valores son menores a 0,05 hay autocorrelación)
```

```
#Comprobación estacionariedad de las series mediante contrastes formales (contrastos de raíces unitarias) - SP
```

```
#Dickey-Fuller
```

```
#series de precios
```

```
SP.df<-ur.df(SP, type = c("drift"),lags=20, selectlags = c("BIC")) #NRHo
```

```
summary(SP.df)
```

```
plot(SP.df)
```

```
SP.df<-ur.df(SP, type = c("drift"),lags=20, selectlags = c("AIC")) #NRHo
```

```
summary(SP.df)
```

```
plot(SP.df)
```

```
SP.df<-ur.df(SP, type = c("drift"), lags = 2) #NRHo
```

```
summary(SP.df)
```

```
plot(SP.df)
```

```
SP.df<-ur.df(SP, type = c("trend"), lags = 2) #NRHo
```

```
summary(SP.df)
```

```
plot(SP.df)
```

```
#series de rendimientos
```

```
rendsp.df<-ur.df(rendsp, type = c("none"),lags=20,selectlags= c("BIC")) #RHo, es estacionaria
```

```
summary(rendsp.df)
```

```

plot(rendsp.df)

#Phillips Perron - SP
#series de precios
SP.pp<-ur.pp(SP, type = c("Z-tau"), model = c("constant"), lags = c("short")) #NRho
summary(SP.pp)

SP.pp<-ur.pp(SP, type = c("Z-tau"), model = c("constant"), lags = c("long")) #NRho
summary(SP.pp)

#series de rendimientos

rendsp.pp<-ur.pp(diff(log(SP)), type = c("Z-tau"), model = c("constant"), lags = c("short")) #RHo, es estacionaria
summary(rendsp.pp)

rendsp.pp<-ur.pp(diff(log(SP)), type = c("Z-tau"), model = c("constant"), lags = c("long")) #RHo, es estacionaria
summary(rendsp.pp)

#KPSS

SP.kpss<-ur.kpss(SP, type = c("mu"), lags = c("short")) #Rho, serie no estacionaria
summary(SP.kpss)

rendsp.kpss<-ur.kpss(diff(log(SP)), type = c("mu"), lags = c("short")) #NRho, serie estacionaria
summary(rendsp.kpss)

#####
#FASE 1: IDENTIFICACIÓN DEL MODELO###

#fac, facp y Ljung-Box test

win.graph(width=8,height=5)
par(mfrow=c(1,2),font=2,font.lab=4,font.axis=2,las=1)
acf(rendsp,ylim=c(-1,1),main="rendsp")

```

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

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

```
Box.test(rendsp, lag = 2, type = c("Ljung-Box"))
```

```
Box.test(rendsp, lag = 3, type = c("Ljung-Box"))
```

```
Box.test(rendsp, lag = 4, type = c("Ljung-Box"))
```

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

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

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

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

```
#FASE 2: ESTIMACIÓN DEL MODELO
```

```
#ar(1)
```

```
model = arima(rendsp, order = c(1,0,0),include.mean = FALSE)
```

```
model
```

```
pnorm(c(abs(model$coef)/sqrt(diag(model$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
model$aic
```

```
model$bic
```

```
bic=AIC(model,k = log(length(rendsp)))
```

```
bic
```

```
#ma(1)
```

```
model2 = arima(rendsp, order = c(0,0,1),include.mean = TRUE)
```

```
model2
```

```
pnorm(c(abs(model2$coef)/sqrt(diag(model2$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model2,k = log(length(rendsp)))
```

```
bic
```

```
#arma(1,1)
```

```
model3 = arima(rendsp, order = c(1,0,1),include.mean = TRUE)
```

```
model3
```

```
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model3,k = log(length(rendsp)))
```

bic

```
model3 = arima(rendsp, order = c(1,0,1),include.mean = FALSE)
```

model3

```
pnorm(c(abs(model3$coef)/sqrt(diag(model3$var.coef))), mean=0, sd=1, lower.tail=FALSE)
```

```
bic=AIC(model3,k = log(length(rendsp)))
```

bic

```
#####
```

```
# FASE3: DIAGNOSIS
```

```
#####
```

```
#Estacionariedad del modelo
```

```
#todas las raíces del polinomio característico deben caer fuera del círculo unitario
```

```
plot(model2) #Produce a plot of the INVERSE AR and MA roots of an ARIMA model
```

```
# Análisis de los residuos
```

```
tsdiag(model2) #dibuja los residuos estandarizados, la ACF de los residuos y los pvalues del Ljung-Box test
```

```
win.graph(width=8,height=5)
```

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

```
acf(model2$residuals,ylim=c(-1,1),main="Residuos arma(0,1)")
```

```
pacf(model2$residuals,ylim=c(-1,1),main="Residuos arma(0,1)")
```

```
##### MODELO PARA LA VARIANZA CONDICIONAL #####
```

```
##### TESTS GARCH Y FASE1 DE IDENTIFICACIÓN DEL MODELO GARCH SP
```

```
#####
```

```
# ACF y PACF de los residuos al cuadrado
```

```
residuos=model2$residuals
```

```
residuos2=residuos^2
```

```
win.graph(width=8,height=5)
```

```
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")
```

```
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')
```

```
# FASE2 y 3: ESTIMACIÓN DEL MODELO GARCH Y DIAGNOSIS
```

```
# ARMA (0,1)-GARCH(1,1) con distribución Normal
```

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

```
m1=ugarchfit(spec=spec1,data=rendsp)
```

```
m1
```

```
#obtención de los residuos
```

```
#plot(m1)
```

```
# ARMA (0,1)-GARCH(1,1) con distribución t-student
```

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

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

```
m2
```

```
# GARCH-M CON ugarchspec. archpow=1 utiliza la desviación estándar. archpow=2 utiliza la varianza
```

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

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

```
m3
```

```
#Egarch
```

```
#OJO, el coeficiente de la asimetría es el alpha1, mirar documentación INTRODUCTORIA del paquete rugarch
```

```
#distribución normal
```

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

```

m4=ugarchfit(spec=spec1,data=rendsp)

m4

#distribución t-student

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

m5=ugarchfit(spec=spec1,data=rendsp)

m5

#GJR-GARCH model

# distribución normal

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

m6=ugarchfit(spec=spec1,data=rendsp)

m6

#distribución student,

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

m7=ugarchfit(spec=spec1,data=rendsp)

m7

v = sigma(m4)#para obtener la volatilidad estimada,
v_anualizadasp=(250)^0.5*v
plot(v_anualizadasp)

#####

#Estadísticos básicos de las series de rendimientos de los commodities y indices stock markets

#####

basicStats(rendoro);basicStats(rendcobre);basicStats(rendpcrudo);basicStats(rendtrigo);basicStats(rendalgodon);basi
cStats(rendsp)

cbind(basicStats(rendoro),basicStats(rendcobre),basicStats(rendpcrudo),basicStats(rendtrigo),basicStats(rendalgodon
),basicStats(rendsp))

```

```

##### VOLATILIDADES ESTIMADAS COMMODITIES #####

plot(v_anualizadaoro[0:4910],col="gold2",ylim=c(0,2),lwd=1,grid.col = NA,main="Volatilidades estimadas
anualizadas")

lines(v_anualizadacobre,col="brown2",lty=1,lwd=1)

lines(v_anualizadapcrudo,col="black",lty=1,lwd=1)

lines(v_anualizadatrigo,col="green4",lty=1,lwd=1)

lines(v_anualizadalgodon,col="turquoise2",lty=1,lwd=1)

lines(v_anualizadasp,col="blue2",lty=1,lwd=1)

addLegend(legend.loc = "topleft", legend.names = c("Oro","Cobre","Petróleo Crudo","Trigo","Algodón","S&P 500"),
col = c("gold2","brown2","black","green4","turquoise2","blue2"),ncol = 1, on = 0,lty=c(1, 1,1,1,1,1), lwd=c(3,
3,3,3,3,3))

#####
##### MODELO PARA LA CORRELACION CONDICIONAL DDC-GARCH #####

#Instalamos paquete
install.packages("rmgarch")
library(rmgarch)

##### SP – commodities #####

sporo<-data.frame(rendsp,rendoro)
spcobre<-data.frame(rendsp,rendcobre)
sppcrudo<-data.frame(rendsp,rendpcrudo)
sptrigo<-data.frame(rendsp,rendtrigo)
spalgodon<-data.frame(rendsp,rendalgodon)

# dcc specification - GARCH(1,1) SP - ORO

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

```

```

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

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

dcc.fit = dccfit(dcc.garch11.spec, data = sporo)

dcc.fit

plot(dcc.fit)

cor1 = rcor(dcc.fit)

dim(cor1) #This tells us that cor1 stores 2516 (2x2) correlation matrices, one for each day of data.

cor1[,dim(cor1)[2]] #Let's have a look at the correlation matrix for the last day

cor_eoro <- cor1[1,2,] # leaving the last dimension empty implies that we want all elements

cor_eoro <- as.xts(cor_eoro) # imposes the xts time series format - useful for plotting. If you transformed cor_BG to
be a xts series the plot function automatically picks up the date information.

plot(cor_eoro)

dim(cor_eoro)

# dcc specification - GARCH(1,1) SP - cobre

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

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

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

dcc.fit2 = dccfit(dcc.garch11.spec, data = spcobre)

dcc.fit2

cor2 = rcor(dcc.fit2)

dim(cor2) #This tells us that cor1 stores 2516 (2x2) correlation matrices, one for each day of data.

cor2[,dim(cor2)[2]] #Let's have a look at the correlation matrix for the last day

cor_ecobre <- cor2[1,2,] # leaving the last dimension empty implies that we want all elements

cor_ecobre <- as.xts(cor_ecobre) # imposes the xts time series format - useful for plotting. If you transformed
cor_BG to be a xts series the plot function automatically picks up the date information.

plot(cor_ecobre)

```

```

# dcc specification - GARCH(1,1) SP - PCRUDO

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

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

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

dcc.fit3 = dccfit(dcc.garch11.spec, data = na.omit(sppcrudo))

dcc.fit3

cor3 = rcor(dcc.fit3)

dim(cor3) #This tells us that cor1 stores 2516 (2x2) correlation matrices, one for each day of data.

cor3[,dim(cor3)[2]] #Let's have a look at the correlation matrix for the last day

cor_eprudo <- cor3[1,2,] # leaving the last dimension empty implies that we want all elements

cor_eprudo <- as.xts(cor_eprudo) # imposes the xts time series format - useful for plotting. If you transformed
cor_BG to be a xts series the plot function automatically picks up the date information.

plot(cor_eprudo)

# dcc specification - GARCH(1,1) SP - TRIGO

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

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

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

dcc.fit4 = dccfit(dcc.garch11.spec, data = (sptrigo))

dcc.fit4

cor4 = rcor(dcc.fit4)

dim(cor4) #This tells us that cor1 stores 2516 (2x2) correlation matrices, one for each day of data.

cor4[,dim(cor4)[2]] #Let's have a look at the correlation matrix for the last day

cor_etrigo <- cor4[1,2,] # leaving the last dimension empty implies that we want all elements

cor_etrigo <- as.xts(cor_etrigo) # imposes the xts time series format - useful for plotting. If you transformed cor_BG
to be a xts series the plot function automatically picks up the date information.

plot(cor_etrigo)

# dcc specification - GARCH(1,1) SP - Algodón

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

```

```

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

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

dcc.fit5 = dccfit(dcc.garch11.spec, data = spalgodon)

dcc.fit5

cor5 = rcor(dcc.fit5)

dim(cor5) #This tells us that cor1 stores 2516 (2x2) correlation matrices, one for each day of data.

cor5[,dim(cor5)[2]] #Let's have a look at the correlation matrix for the last day

cor_ealgodon <- cor5[1,2,] # leaving the last dimension empty implies that we want all elements

cor_ealgodon <- as.xts(cor_ealgodon) # imposes the xts time series format - useful for plotting. If you transformed
cor_BG to be a xts series the plot function automatically picks up the date information.

plot(cor_ealgodon)

#Plot correlaciones condicionales 2000-2020

plot(cor_eoro,col="gold2",ylim=c(-0.7,1),lwd=1,grid.col = NA,main="Correlaciones condicionales")

lines(cor_ecobre,col="brown2",lty=1,lwd=1)

lines(cor_epcrudo,col="black",lty=1,lwd=1)

lines(cor_etrigo,col="green4",lty=1,lwd=1)

lines(cor_ealgodon,col="turquoise2",lty=1,lwd=1)

addLegend(legend.loc = "topleft", legend.names = c("Oro","Cobre","Petróleo Crudo","Trigo","Algodón"), col =
c("gold2","brown2","black","green4","turquoise2"),ncol = 1, on = 0,lty=c(1, 1,1,1,1), lwd=c(3, 3,3,3,3))

#Plot correlaciones condicionales crisis financiera 2008

plot(cor_eoro[1800:2100],col="gold2",ylim=c(-0.7,1),lwd=1,grid.col = NA,main="Crisis financiera de 2008")

lines(cor_ecobre[1800:2100],col="brown2",lty=1,lwd=1)

```

```

lines(cor_epcrudo[1800:2100],col="black",lty=1,lwd=1)

lines(cor_etrigo[1800:2100],col="green4",lty=1,lwd=1)

lines(cor_ealgodon[1800:2100],col="turquoise2",lty=1,lwd=1)

addLegend(legend.loc = "topleft", legend.names = c("Oro","Cobre","Petróleo Crudo","Trigo","Algodón"), col =
c("gold2","brown2","black","green4","turquoise2"),ncol = 1, on = 0,lty=c(1, 1,1,1,1), lwd=c(3, 3,3,3,3))

#Plot correlaciones condicionales COVID-19

plot(cor_eoro[4800:5028],col="gold2",ylim=c(-0.7,1),lwd=1,grid.col = NA,main="COVID-19")

lines(cor_ecobre[4800:5028],col="brown2",lty=1,lwd=1)

lines(cor_epcrudo[4800:5026],col="black",lty=1,lwd=1)

lines(cor_etrigo[4800:5028],col="green4",lty=1,lwd=1)

lines(cor_ealgodon[4800:5028],col="turquoise2",lty=1,lwd=1)

addLegend(legend.loc = "topleft", legend.names = c("Oro","Cobre","Petróleo Crudo","Trigo","Algodón"), col =
c("gold2","brown2","black","green4","turquoise2"),ncol = 1, on = 0,lty=c(1, 1,1,1,1), lwd=c(3, 3,3,3,3))

#####Correlaciones incondicionales#####

# create combined data series

rendorosp = cbind(rendsp,rendoro)
rendcobresp = cbind(rendsp,rendcobre)
rendpcrudosp = cbind(rendsp,rendpcrudo)
rendtrigosp = cbind(rendsp,rendtrigo)
rendalgonosp = cbind(rendsp,rendalgon)

cor(rendorosp, method = c("pearson"))
cor(rendcobresp, method = c("pearson"))
cor(na.omit(rendpcrudosp), method = c("pearson"))
cor(rendtrigosp, method = c("pearson"))
cor(rendalgonosp, method = c("pearson"))

```

```

##### Quantile Regression #####
#stocks
mydata<-read.table("QR.csv", header=TRUE, sep=";")

attach(mydata)
dim(mydata)
names(mydata)

rendOro <- diff(log(Oro))
rendCobre <- diff(log(Cobre))
rendPetroleo <- diff(log(Petroleo))
rendTrigo <- diff(log(Trigo))
rendAlgodon <- diff(log(Algodon))
rendSP <- diff(log(SP))

##### Oro con SP #####

#Define variables

y <- cbind(rendOro) #dependent variable
x<- cbind(rendSP) #independent variable

#Descriptive statistics

basicStats(x)
basicStats(y)

#OLS regression
olsreg <- lm(y ~ x, data=mydata)
summary(olsreg)

#Quantile regression

quantreg10 <- rq(y ~ x, data=mydata, tau=0.10)
summary(quantreg10)

quantreg95 <- rq(y ~ x, data=mydata, tau=0.95)
summary(quantreg95)

#simultaneous quantile regression
quantreg.all <- rq(y ~ x, data=mydata, tau=seq(0.05, 0.95, by = 0.05))
summary(quantreg.all)

#plotting data
quantreg.plot <- summary(quantreg.all)
plot(quantreg.plot)

##### Cobre con SP #####

#Define variables

y <- cbind(rendCobre) #dependent variable
x<- cbind(rendSP) #independent variable

#Descriptive statistics

basicStats(x)

```

```

basicStats(y)

#OLS regression
olsreg <- lm(y ~ x, data=mydata)
summary(olsreg)

#Quantile regression
quantreg10 <- rq(y ~ x, data=mydata, tau=0.10)
summary(quantreg10)

quantreg95 <- rq(y ~ x, data=mydata, tau=0.95)
summary(quantreg95)

#simultaneous quantile regression
quantreg.all <- rq(y ~ x, data=mydata, tau=seq(0.05, 0.95, by = 0.05))
summary(quantreg.all)

#plotting data
quantreg.plot <- summary(quantreg.all)
plot(quantreg.plot)

##### Petroleo con SP #####

#Define variables

y <- cbind(rendPetroleo) #dependent variable
x<- cbind(rendSP) #independent variable

#Descriptive statistics

basicStats(x)
basicStats(y)

#OLS regression
olsreg <- lm(y ~ x, data=mydata)
summary(olsreg)

#Quantile regression

quantreg10 <- rq(y ~ x, data=mydata, tau=0.10)
summary(quantreg10)

quantreg95 <- rq(y ~ x, data=mydata, tau=0.95)
summary(quantreg95)

#simultaneous quantile regression
quantreg.all <- rq(y ~ x, data=mydata, tau=seq(0.05, 0.95, by = 0.05))
summary(quantreg.all)

#plotting data
quantreg.plot <- summary(quantreg.all)
plot(quantreg.plot)

##### Trigo con SP #####

#Define variables

y <- cbind(rendTrigo) #dependent variable
x<- cbind(rendSP) #independent variable

```

```

#Descriptive statistics

basicStats(x)
basicStats(y)

#OLS regression
olsreg <- lm(y ~ x, data=mydata)
summary(olsreg)

#Quantile regression

quantreg10 <- rq(y ~ x, data=mydata, tau=0.10)
summary(quantreg10)

quantreg95 <- rq(y ~ x, data=mydata, tau=0.95)
summary(quantreg95)

#simultaneous quantile regression
quantreg.all <- rq(y ~ x, data=mydata, tau=seq(0.05, 0.95, by = 0.05))
summary(quantreg.all)

#plotting data
quantreg.plot <- summary(quantreg.all)
plot(quantreg.plot)

##### Algodon con SP #####

#Define variables

y <- cbind(rendAlgodon) #dependent variable
x<- cbind(rendSP) #independent variable

#Descriptive statistics

basicStats(x)
basicStats(y)

#OLS regression
olsreg <- lm(y ~ x, data=mydata)
summary(olsreg)

#Quantile regression

quantreg10 <- rq(y ~ x, data=mydata, tau=0.10)
summary(quantreg10)

quantreg95 <- rq(y ~ x, data=mydata, tau=0.95)
summary(quantreg95)

#simultaneous quantile regression
quantreg.all <- rq(y ~ x, data=mydata, tau=seq(0.05, 0.95, by = 0.05))
summary(quantreg.all)

#plotting data
quantreg.plot <- summary(quantreg.all)
plot(quantreg.plot)

```