



Asimetría y flujo convectivo del riesgo en el mercado internacional de commodities.

CAMILO FERNANDO ERASSO FUERTES

Trabajo de Investigación presentado como requisito para optar al título de:
Economista

Director: Jorge Mario Uribe Gil
Profesor Asociado del Programa de Economía
Universidad del Valle

Universidad del Valle
Facultad de Ciencias Sociales y Económicas
Programa de Economía
Santiago de Cali
2017

Asimetría y flujo convectivo del riesgo en el mercado internacional de commodities.

Camilo Fernando Erasso Fuertes

Resumen

Esta investigación se incorpora al actual debate de la *Hipótesis de Master*, otorgando evidencia a favor de la existencia del proceso de *financiarización de los commodities*. Nos basamos en el modelo teórico de Cheng et al. (2015), el cual plantea la presencia de un *flujo convectivo del riesgo* entre agentes de los mercados de futuros de commodities, para syndicar que a través del canal de la *distribución de riesgo*, la especulación ha aumentado el riesgo en los precios de futuros de varios commodities en las dos décadas más recientes. Como metodología, proponemos la medida del *Valor en Riesgo Rodante* o *Rolling Value-at-Risk (RVaR)*, la cual fue estimada mediante un modelo *AR-GARCH-GNG* utilizando los avances de la *Teoría del Valor Extremo (TVE)*. Finalmente, pruebas de *causalidad prima facie a la Granger* nos dieron indicios de la existencia de un *flujo convectivo del riesgo* de especuladores hacia aseguradores en bienes como el Gasóleo para Calefacción, el WTI, el Aceite de Soja y el Maíz.

Palabras clave: Commodities, flujo convectivo del riesgo, Teoría del Valor Extremo, VaR.

Clasificación JEL: G13, G15

Abstract

This research is incorporated in the current debate of the *Master's hypothesis*, offering evidence in favor of the existence of *financialization* of commodities. We rely on the theoretical model of Cheng et al. (2015) which established the presence of a *convective risk flow* among agents of the commodity futures markets to indicate that through the channel of *risk sharing*, speculation has increased the risk in the futures prices of several commodities in the two most recent decades. As a methodology, we propose a *Rolling Value-at-Risk (RVaR)* estimated with an *AR-GARCH-GNG* model using the advances of *Extreme Value Theory (EVT)*. Finally, evidence of *prima facie Granger causality* gave us indications of the existence of a convective risk flow from speculators to hedgers in goods such as Heating Oil, WTI, Soybean Oil and Corn.

Keywords: Commodities, convective risk flow, Extreme Value Theory, VaR.

JEL classification: G13, G15

1. Introducción

Las materias primas, más comúnmente conocidas bajo el anglicismo de commodities, han sido parte del sistema financiero a través del mercado de futuros desde tiempos remotos; el primer contrato de futuros sobre el Trigo fue lanzado en 1865 por el *Chicago Board of Trade (CBOT)*, la bolsa de futuros y opciones más antigua del mundo (Declerk, 2015). La importancia de estos bienes, al pertenecer o ser transados en este tipo de mercados, se fundamenta en que estos últimos: ofrecen instrumentos para ayudar a transferir el *riesgo de fluctuación de precios* entre diferentes agentes, tales como productores, comerciantes, especuladores, etc.; tienen la función de descubrir un único precio de bienes que normalmente son producidos en diferentes áreas geográficas; son una fuente de información pública que facilita la toma de decisiones; y además, garantizan la entrega y pago de los mismos (Declerk, 2015).

Un mercado de futuros de commodities se compone básicamente de 2 tipos de operadores: aquellos que buscan protegerse del riesgo ante cambios en los precios, o también llamados aseguradores, y su contraparte, aquellos que se expone al riesgo en busca de un beneficio o prima de riesgo, conocidos como especuladores. Los primeros son normalmente productores, procesadores de alimentos, agricultores, consumidores o comerciantes de commodities que están interesados en el bien físico, pero que utilizan contratos de futuros para fijar precios, reduciendo así el riesgo existente ante una fluctuación en los mismos. Los segundos, a pesar de no estar interesados en los subyacentes de estos contratos, hacen parte fundamental de este mercado ya que, en su búsqueda de ganancias, asumen la contraparte de las posiciones libradas por los aseguradores y le ofrecen liquidez al mercado, facilitando así la formación de transacciones dentro del mismo (Declerk, 2015).

Hasta aquí, las partes mencionadas son igual de necesarias para el correcto funcionamiento de este tipo de mercados. No obstante, en la década en curso ha surgido una gran preocupación de parte de los formuladores de política a nivel mundial, debido a una excesiva fluctuación de precios que se ha extendido a casi todos los mercados de commodities. Esta fluctuación generó un ciclo de auge y declive, caracterizado por precios muy altos alcanzados en el periodo 2007-2008, seguido de una fuerte caída sincronizada con el estallido de la *Crisis SubPrime* en el 2008, para luego, una vez pasado el estado más crítico de ésta última, experimentar otra subida imprevista (2010-2011) (Cheng & Xiong, 2014) (Figuras A1-A2).

Por otro lado, no sobra decir que este fenómeno es alarmante por sí mismo, debido a que afecta directamente el bienestar de millones de personas alrededor del mundo, sobre todo, a los miles de habitantes de países en vías de desarrollo que son lanzados debajo de la línea de pobreza, ya que la adquisición de estos bienes básicos ocupa la mayor parte de sus ingresos (Irwin, 2013).

Pero lo que realmente llama la atención de diferentes dirigentes políticos, es el hecho que esta excesiva volatilidad puede estar relacionada con el surgimiento y rápido crecimiento de un tercer grupo de participantes en el mercado de futuros, los cuales son conocidos como *especuladores de índices* (Nijs, 2014). Autores como Tang & Xiong (2012) por ejemplo, identifican que en la primera década del siglo XXI se popularizaron los futuros de commodities como un nueva clase de activos financieros, lo cual dio paso a un gran aumento de inversión en estos y a una excesiva especulación en índices basados en los mismos. Este proceso es comúnmente conocido en el ámbito académico como la *financiarización de los commodities*, que a su vez está asociado, desde el ámbito político, con la también conocida *Hipótesis de Masters*. Esta última estipula que la burbuja de los precios de futuros de los commodities en 2007-2008, especialmente la de los precios de futuros del petróleo, fue causada por la fuerte especulación de inversionistas en índices de commodities (Irwin & Sanders, 2012).

De este modo, los acontecimientos mencionados han suscitado un fuerte debate en la academia, el cual se ha centrado en probar la veracidad de la *Hipótesis de Masters* desde diferentes enfoques y utilizando un gran abanico de metodologías. La mayoría de investigaciones que avalan esta hipótesis, basan sus resultados en correlaciones o efectos *spillovers* (o de *derramamiento*) hallados entre el petróleo y commodities diferentes al mercado energético (Tang & Xiong, 2012), commodities e índices de commodities (Singleton, 2014), y commodities y activos de otros mercados financieros como el accionario (de Nicola, de Pace, & Hernandez, 2016; Delatte & Lopez, 2013; Mensi, Beljid, Boubaker, & Managi, 2013).

Por otra parte, autores que rechazan esta hipótesis lo hacen bajo la premisa que no existen datos que, con una desagregación válida de las posiciones de los agentes de este mercado, permitan identificar con precisión una correlación entre estos dos fenómenos (Irwin, 2013), y que, además, correlación no implica relaciones de causalidad, por lo cual es necesario establecer teorías avaladas por modelos estructurales (Fattouh, Kilian, & Mahadeva, 2013). Por ende, estos autores concluyen que, si bien el flujo de inversión en índices aumentó notablemente durante años recientes, el aumento de los precios de los futuros de commodities se debe a cambios en los fundamentales y no, a una excesiva especulación.

Frente al vacío teórico encontrado por estos últimos autores, la presente investigación, basada en el modelo teórico presentado por Cheng, Kirilenko, & Xiong (2015), en el cual se plantea la existencia de un *flujo convectivo del riesgo* entre agentes de los mercados de futuros de commodities, y utilizando como metodología la medida del *Valor en Riesgo* (VaR, por sus siglas en inglés) en conjunción con los avances de la *Teoría del Valor Extremo (TVE)*, aporta evidencia empírica a favor de la especulación como un mecanismo de aumento del riesgo en los precios de futuros de varios commodities.

Además de esta introducción, este documento está organizado de la siguiente manera: en la sección 2 se hace una revisión de la literatura acerca del debate en torno a la *financiarización de los commodities*; en la sección 3 se expone el modelo teórico del *flujo convectivo del riesgo* de Cheng et al. (2015); la medida del VaR junto con los avances en su estimación otorgados por la Teoría del Valor Extremo se presentan como instrumento metodológico en la sección 4; el análisis empírico respecto a la medición y comparación del comportamiento del riesgo de los commodities se realiza en la sección 5; y finalmente, en la sección 6 se enuncian las conclusiones de esta investigación.

2. Estado del Arte

Respecto del debate sobre la *financiarización de los commodities* o *Hipótesis de Masters*, la literatura solo se ha puesto de acuerdo en dos aspectos. El primero, confirmar que hubo una subida dramática de los precios en la mayoría de los mercados de commodities, la cual comenzó a principios del 2000 y alcanzó su máximo pico a mitad del 2008, para luego tener una drástica caída con el estallido de la Crisis SubPrime, y finalizar con una rápida recuperación, a precios nuevamente altos, en el periodo 2010-2011. El segundo, reconocer que en este mismo periodo, más exactamente a partir del 2004, los flujos de inversiones de un nuevo grupo de operadores, conocidos como especuladores de índices, aumentaron de forma dramática en los mercados de futuros de estos mismos bienes. Sin embargo, admitir estos dos hechos no implica que exista una causalidad entre los mismos, y es precisamente en este punto donde divergen dos concepciones de lo acontecido en este periodo de turbulencia de los mercados de commodities.

Antes de profundizar en estos dos enfoques, es necesario entender que existen tres formas de participar en el mercado de futuros de commodities, enumeradas por Nijs (2014) de la manera que se explica a continuación. La primera es a través de índices de commodities, de los cuales los dos más importantes son el *S&P GSCI (Standard & Poor's Goldman Sachs Commodity Index)* y el *DJ-UBSCI (Dow Jones - Union Bank of Switzerland Commodity Index, renombrado Bloomberg Commodity Index - BCOM a partir del 2014)*. Estos índices se componen de contratos de futuros de una gran canasta de materias primas de diferentes sectores (energético, metales, agropecuario), transados en diferentes bolsas de commodities, y los cuales se ponderan dentro de cada índice dependiendo de la metodología utilizada por éste. El primero, por ejemplo, pone un gran peso sobre el mercado energético, mientras que el segundo, establece un máximo de 33% para cada sector (Irwin, 2013). Los agentes que participan de esta forma son conocidos como *comerciantes de índices de commodities* o *CITs* (por sus siglas en inglés).

Cabe anotar que debido a que el fin último al transar en estos índices no es adquirir el subyacente o bien físico, estos siguen una metodología de *rolling* o *rodante*; antes que el contrato del primer mes alcance su maduración (vencimiento para la entrega de la

mercancía física), se reemplaza por el -o se “rueda” al- contrato del segundo mes, el cual pasa a ser del primer mes, y así sucesivamente (Tang & Xiong, 2012). Por tal motivo, este tipo de inversiones solo representan la toma de posiciones en largo (de compra), es decir, solo implican un *trading pasivo*. Para ganar exposición dentro de cada índice, un inversionista realiza generalmente un acuerdo financiero bilateral con un banco u otra institución financiera (swap, por ejemplo), luego el inversionista compra partes del índice de commodities al banco, y después, el banco cubre su exposición resultante de la operación swap a través de contratos de futuros en una bolsa de commodities (Nijs, 2014).

La segunda forma de participación es llevada a cabo por los llamados *Money Managers* o *Administradores de Fondos*, de los cuales hacen parte los *fondos de cobertura* (*hedge funds*). Estos se diferencian de los inversionistas de índices en que realizan un trading más activo, tomando posiciones en corto y en largo de contratos de futuros y opciones en commodities (Nijs, 2014). Como tercera y última forma de participación, están los *productos comerciados en bolsa* o *ETPs* (*exchange-traded products*), de los cuales las *notas comerciadas en bolsa* o *exchange-traded notes* (*ETNs*) y los *fondos comerciados en bolsa* o *exchange-traded funds* (*ETFs*) hacen parte. Todos estos productos replican los retornos de un único bien, de varios, o de índices de commodities, y al funcionar como fondos mutuos, sus acciones son comercializadas en el mercado accionario¹ (Nijs, 2014).

Una vez entrado en contexto, una de las investigaciones más citadas, eje del debate de aquellos que reconocen que la excesiva especulación de los inversionistas en índices es la causante de la volatilidad extrema de los precios de los commodities, es la de Tang & Xiong (2012). Estos autores encuentran que debido a los beneficios en materia de diversificación exhibidos por los mercados de commodities antes del 2000, es decir, la correlación negativa de sus retornos con los de otros activos de mercados como el accionario o de bonos y sus atractivos retornos observados, se generó un rápido crecimiento del flujo de inversiones hacia los índices de commodities, lo cual llevó a un proceso de *financiarización* en estos mercados. Tales autores concluyen que después de 2004, y particularmente tras la caída de Lehman Brothers en septiembre de 2008, hubo un aumento de la correlación entre los precios de bienes no energéticos y los precios del petróleo, sobre todo para aquellos commodities suscritos a los índices S&P GSCI y DJ-UBSCI.

Sujeto a lo anterior, Nijs (2014) define a la *financiarización de los commodities* como “el creciente rol de motivos financieros, mercados financieros y actores financieros en la operación de mercados de commodities”, es decir, “el proceso de alineación de los retornos de los commodities con activos financieros puros que conllevó al incremento de comovimientos entre clases de activos que han seguido históricamente un patrón de causalidad distinto” (p. 428). Esto implica que el precio de estas mercancías está

¹ Existe otra forma de participar en el mercado de commodities y es mediante la compra de contratos directamente en el mercado de futuros de cada bien. No obstante, este método es utilizado por pocos individuos o instituciones financieras (Irwin, 2013).

determinado, no solo por su oferta y demanda, sino también por el apetito de riesgo hacia activos financieros y el comportamiento de inversión de los CITs (Tang & Xiong, 2012). De esta manera, este tipo de inversionistas crean un nuevo canal por el cual el riesgo de otros mercados financieros se puede transmitir hacia los mercados de commodities.

Reforzando la idea del aumento de los co-movimientos entre los retornos de commodities de diferentes mercados, y entre los commodities y el mercado accionario, desde el año 2000 en adelante, Mensi, Beljid, Boubaker, & Managi (2013), utilizando un modelo VAR-GARCH, encuentran la existencia de efectos de *derramamiento* o *contagio* desde el índice S&P 500 hacia los retornos del oro y el petróleo, los cuales aumentaron sustancialmente durante la crisis del 2008. Asimismo, por medio de una metodología de cópulas dinámicas, Delatte & Lopez (2013) establecen que durante la década del 90 y parte del 2000, los retornos del mercado accionario y el de commodities no presentaron ninguna relación en promedio. No obstante, estos autores advierten que este patrón cambia con la crisis del 2008 -y no antes según lo evidenciado por Tang & Xiong, (2012)- en la cual se aumentó considerablemente la integración entre el mercado accionario y todos los commodities, en especial, los pertenecientes al sector energético y de metales industriales.

De Nicola, de Pace, & Hernandez (2016), utilizando correlaciones condicionales así como incondicionales, encuentran resultados similares a los de Delatte & Lopez, (2013) pero a partir del 2007, asociando este fenómeno al proceso de *financiarización* experimentado por los mercados de commodities. No obstante, estos autores también tildan a la expansión de la industria del biocombustible (sustituto de la gasolina convencional), como la causante de una mayor integración entre el mercado energético (petróleo) y el agrícola (maíz y aceite de soya) durante el periodo 2007-2013.

De este modo, estos nuevos trabajos profundizan los hallazgos de Tang & Xiong (2012), los cuales eran limitados ya que solo tenían en cuenta correlaciones incondicionales, desconociendo el hecho estilizado que los commodities, al igual que los activos financieros, presentan clústeres de volatilidad en sus retornos (ver Giot & Laurent, 2003, por ejemplo).

Otra forma de probar el fenómeno de la *financiarización en los commodities* ha sido a través de la relación existente entre los flujos o posiciones de los inversionistas en índices, cuya información se encuentra registrada en los reportes semanales de los *Commitments of Traders (COT)* ofrecidos por la *Commodity Futures Trading Commission (CFTC)* de USA, y su relación con los retornos de los commodities. No obstante, esta fuente de información, al ser limitada (solo a partir del 2006) y pobre en contenido (nivel de agregación muy alto y solo para los commodities del sector agrícola), ha arrojado resultados mixtos que por lo general no soportan la *Hipótesis de Masters*. Por parte de los adeptos a la hipótesis de la *financiarización*, solo Singleton (2014), tras controlar por diferentes variables, encuentra que el aumento de las posiciones de los CTIs y de las cuentas de los money managers afectaron los retornos del petróleo durante su ciclo auge-declive alrededor de 2008.

Por otra parte, Irwin (2013) hace un recuento de un gran número de estudios que ofrecen evidencia empírica contraria a los hallazgos de Singleton (2014), y en general, del proceso de *financiarización de las mercancías*. Uno de los argumentos centrales de este autor es que el aumento de las posiciones en índices, la cual se dio durante 2004-2006, y la subida de precios de los commodities, ocurrida entre 2007-2008, presentan un desfase, por tanto, estos dos hechos solo pueden ser vistos como una coincidencia; ni con pruebas de causalidad a la Granger (Aulerich, Irwin, & Garcia, 2013), ni con pruebas de regresiones de corte transversal (Irwin & Sanders, 2012), ni con pruebas de diferenciales entre precios de contratos de futuros de diferente maduración (o *spreads*) (Stoll & Whaley, 2010), es posible encontrar evidencia a favor de la *Hipótesis de Masters*.

Además, todos los artículos mencionados que están a favor de la *financiarización* caen bajo la crítica de Fattouh et al. (2013), la cual indica que correlación no implica causalidad; “los inversionistas financieros pudieron haber respondido a las mismas fuerzas del mercado que otros participantes, y tanto precios spot como futuros fueron impulsados por los mismos fundamentales económicos” (Fattouh et al., 2013, p. 6). Es por esta razón que estos autores hacen un llamado a la utilización de modelos estructurales del tipo Kilian & Murphy (2014), donde por medio de *Vectores Autorregresivos Estructurales* (SVAR, por sus siglas en inglés) es posible distinguir entre choques de oferta y demanda de un determinado bien, en este caso particular, del petróleo. La conclusión de estos últimos es que si bien han existido episodios especulativos en la historia del petróleo, estos no tienen parecido al experimentado durante el periodo 2003-2008, el cual ocurrió por un aumento inesperado de la demanda global (no especulativa) del petróleo.

Pero debido a que el debate pareciera no tener fin, Cheng & Xiong (2014) intentan abordar la disputa desde una perspectiva no polarizada, ya que desde su juicio, rechazar un punto de vista no necesariamente justifica al otro. Teniendo en cuenta lo anterior, estos autores hacen un llamado a los investigadores a enfocar su análisis en “probar si la *financiarización* ha afectado a los mercados de commodities a través de los mecanismos que garantizan el funcionamiento de los mismos: almacenamiento, descubrimiento de información y distribución del riesgo” (Cheng & Xiong, 2014, p. 420). Los dos últimos, dicen los autores, son pieza clave para entender cómo la *financiarización* ha afectado el mercado de futuros de commodities.

Por un lado, la función de *descubrimiento de información* se entiende como la capacidad que tiene un mercado de futuros de agregar la información de todos los participantes de un mercado de commodities, la cual se encuentra dispersa a través de diferentes regiones o países alrededor del mundo; “esto convierte a los precios de futuros de commodities en señales de precio importantes que guían la demanda de commodities, y así, en un canal de retroalimentación importante [...] que afecta tanto a la demanda de commodities como a sus precios spot” (Cheng & Xiong, 2014, p. 429). Es por este motivo que Cheng & Xiong (2014) advierten que “ruidos generados por el comercio en los mercados de futuros pueden

afectar las expectativas de los productores respecto a la fuerza de la economía global, y por lo tanto, repercutir en la demanda de commodities y los precios spot de los mismos” (Cheng & Xiong, 2014, p. 431)

Por el otro, la función de *distribución del riesgo* es una de las razones fundamentales por la cual existen los mercados de futuros de commodities; a través de estas plataformas, productores y consumidores de diferentes commodities se protegen ante aumentos en los precios de los bienes de su interés, y así, facilitan una distribución del riesgo más eficiente entre un amplio grupo de agentes (Cheng & Xiong, 2014). No obstante, debido a que algunos especuladores, como los CITs, solo toman posiciones en largo e inyectan una gran cantidad de liquidez a estos mercados, es posible que se creen distorsiones que provoquen que estas plataformas se vuelvan menos efectivas en su principal propósito económico, el cual es ofrecer protección ante el riesgo de precio a los aseguradores (Nijs, 2014).

A través de este último mecanismo, Cheng et al. (2015) señalan la importancia que tiene el *motivo* por el cual aseguradores o especuladores comercian en el mercado de futuros de commodities y la relevancia que tiene para esclarecer los hallazgos hasta ahora encontrados respecto a la relación entre posiciones de los participantes del mercado de futuros y los precios de futuros de los commodities. Los motivos de los aseguradores han sido bien documentados por la teoría de *hedging pressure* o *presión por asegurarse* desarrollada por Keynes (1923), Hicks (1939) y más tarde Hirshleifer (1988), la cual establece que los aseguradores usualmente realizan posiciones en corto (venden contratos) en el mercado de futuros para protegerse del riesgo de una caída de precios, y a cambio, ofrecen una prima de riesgo positiva para atraer a especuladores que asuman la contraparte de su posición (comprende contratos o realicen posiciones en largo) (Cheng & Xiong, 2014).

No obstante, el aporte de Cheng et al. (2015) se basa en demostrar que los especuladores también tienen sus propios motivos para participar en el mercado de commodities, tales como la *diversificación de portafolios* y la *gestión del riesgo*. Debido a esto, el apetito por el riesgo asumido por estos en el mercado de futuros de commodities, puede variar dependiendo de los choques recibidos en otros mercados financieros, de los cuales también hacen parte (como el accionario). Estos autores evidencian que durante la crisis del 2008, los inversionistas redujeron su capacidad de absorber riesgo debido a la incertidumbre experimentada en la mayoría de mercados financieros, y por lo tanto, también restringieron sus posiciones en largo en el mercado de commodities. Esto generó que el precio de equilibrio dentro del mercado de futuros cayera, haciendo que los aseguradores terminaran afrontando más riesgo del que antes tenían, un fenómeno al cual Cheng et al. (2015) denominaron *flujo convectivo de riesgo*. Es así como los especuladores, además de brindar liquidez al mercado de futuros de commodities, también son consumidores de ésta cuando se enfrentan a periodos de turbulencia económica (Cheng & Xiong, 2014).

Estos hallazgos hacen parte de una nueva literatura que reconoce que los precios de los futuros de commodities son conducidos por aquel grupo que tiene los mayores incentivos para comerciar; si bien la teoría de la presión por asegurarse propone a los aseguradores como los integrantes de este grupo, estos pueden ser reemplazados por los inversionistas financieros dependiendo del periodo en el que se esté. En otras palabras, en el mercado de commodities de futuros existe un apetito por el riesgo que varía con el tiempo (Cheng & Xiong, 2014).

En resumen, lo suscrito por Cheng et al. (2015) servirá como base teórica para soportar los hallazgos empíricos encontrados en esta investigación, los cuales, a través de una metodología que se expondrá más adelante, refuerzan la idea de la *convectividad del flujo del riesgo* en el mercado de commodities. En este sentido, este estudio se incorpora al actual debate de la *financiarización de los commodities*, otorgando evidencia a favor de la existencia de este fenómeno, y se diferencia de otros estudios, en que hasta ahora, la metodología aquí propuesta, no ha sido utilizada para el análisis de este hecho, lo cual reporta ventajas significativas que se documentaran a lo largo del texto.

3. Marco Teórico

Para soportar los hallazgos empíricos de esta investigación, a continuación se expondrá el modelo teórico desarrollado por Cheng et al. (2015), el cual simboliza el funcionamiento del *flujo convectivo del riesgo*. Estos autores, siguiendo las premisas de Hirshleifer (1988, 1990), consideran un mercado de futuros con dos grupos de participantes, aseguradores (*hedgers*) y especuladores (*financial traders*), en el cual los primeros venden futuros (van en corto) para cubrirse ante el riesgo de precio, y los segundos asumen la contraparte (van en largo o compran). Estos últimos además, afrontan sus propios choques que provocan cambios en sus posiciones.

Se considera entonces, un periodo en el cual ambos grupos reciben choques que hacen cambiar sus posiciones, y cada uno afronta una función de demanda de la forma:

$$dx_h = -\beta_h dF - \gamma_h z - u_h, \quad (1)$$

$$dx_f = -\beta_f dF - \gamma_f z, \quad (2)$$

donde dx_h y dx_f son los cambios en las posiciones de futuros de aseguradores y especuladores, conservando la misma simbología de los autores en la cual h proviene de hedgers y f de financial traders. Asimismo, dF es el cambio en el precio de los futuros, y $\beta_h \geq 0$ y $\beta_f \geq 0$ son las pendientes de las demandas de cada grupo; un β_f alto implica que para la misma caída de los precios de futuros, los especuladores están dispuestos a absorber una posición más larga vendida por los aseguradores. En el mismo modo, β_h mide la

sensibilidad de los aseguradores ante cambios en el precio. Estos últimos, escogerán una posición de cobertura más pequeña cuando los precios bajen.

Por otra parte, u_h es un choque idiosincrático que hace que los aseguradores incrementen sus posiciones en corto, y z es otro choque que hace que los especuladores reduzcan sus posiciones; la crisis financiera del 2008 puede servir como ejemplo de este último. Además, $\gamma_f > 0$ mide la exposición al choque por parte de los especuladores, y γ_h lo hace para los aseguradores; si se supone que $\gamma_f > \gamma_h$, los especuladores tienen una mayor exposición al choque z que los aseguradores. La condición de equilibrio de mercado implica que $dx_h + dx_f = 0$, y por tanto el precio de equilibrio está determinado por:

$$dF = -\frac{1}{\beta_h + \beta_f} u_h - \frac{1}{\beta_h + \beta_f} (\gamma_h + \gamma_f) z, \quad (3)$$

lo cual implica que los cambios en las posiciones de cada grupo son:

$$dx_h = -\frac{\beta_f}{\beta_h + \beta_f} u_h + \frac{\beta_h \gamma_f - \beta_f \gamma_h}{\beta_h + \beta_f} z, \quad (4)$$

$$dx_f = -dx_h = \frac{\beta_f}{\beta_h + \beta_f} u_h - \frac{\beta_h \gamma_f - \beta_f \gamma_h}{\beta_h + \beta_f} z. \quad (5)$$

Cheng et al. (2015) señalan que la ecuación (3) enmarca la teoría de la presión por asegurarse, en el sentido que la presencia de los especuladores hace que se reduzca el impacto del choque idiosincrático de los aseguradores u_h . Esto quiere decir, que un valor más alto de β_f conlleva a una menor exposición del precio del futuro ante el choque u_h , gracias a la mayor capacidad de los especuladores de distribuir el choque de los aseguradores.

Por otro lado, las ecuaciones (4) y (5) expresan el *flujo convectivo del riesgo* inducido por el choque z de parte de los especuladores hacia los aseguradores. Si el choque z no afectara a los aseguradores ($\gamma_h = 0$) por ejemplo, estos sin embargo, tendrían que incrementar sus posiciones de futuros en $\frac{\beta_h \gamma_f}{\beta_h + \beta_f} z$ debido a la reducción del precio de los futuros en $\frac{1}{\beta_h + \beta_f} \gamma_f z$ producida por el choque z . Lo anterior quiere decir que el precio baja tanto, que a los aseguradores les es benéfico retomar parte del riesgo depositado en un principio. En general, siempre que se cumpla que $\beta_h \gamma_f - \beta_f \gamma_h > 0$, los aseguradores encontrarán deseable recuperar o absorber de vuelta alguna parte del riesgo depositado.

Los autores por tanto, partiendo de la premisa que un grupo de participantes (los especuladores) tiene una exposición más grande al choque z que el otro (los aseguradores) y que las posiciones de ambos son sensibles a cambios en los precios, definen al *flujo convectivo del riesgo* como el cambio en la distribución del riesgo que están dispuestos a tomar los diferentes grupos que interactúan en el mercado de futuros. En este caso, el *flujo*

convectivo reduce la distribución del riesgo ofrecida por los especuladores, aun cuando estos siguen teniendo posiciones netas en largo y continúan compartiendo algún riesgo de los aseguradores (Cheng et al., 2015).

Este modelo tiene como implicación central que el choque de los aseguradores u_h , como el z de los especuladores, hacen que el cambio de precios de futuros dF y el cambio en las posiciones de los especuladores dx_f tengan correlaciones opuestas; “cuando los especuladores comercian para incorporar el choque de los aseguradores u_h , comparten el riesgo de los aseguradores y el cambio en sus posiciones está correlacionada negativamente con el cambio en el precio. Por otra parte, cuando ellos comercian en respuesta a sus propios choques, demandan que los aseguradores compartan su riesgo y el cambio de sus posiciones está correlacionado positivamente con el cambio en precios” (Cheng et al., 2015, p. 9). Esta implicación por tanto, servirá para explicar los hallazgos empíricos desarrollados en esta investigación.

4. Metodología

El *Valor en Riesgo* o *VaR* (por sus siglas en inglés) es una herramienta muy intuitiva y fácil de interpretar, sobre todo para personas ajenas al campo de la economía financiera; nos dice cuánto (dinero) podemos esperar perder, con una probabilidad dada y en un cierto periodo de tiempo (1 o más días). Diariamente, corredores de todo el mundo efectúan este tipo de cálculos antes de realizar cualquier operación bursátil para así saber a cuánto podría ascender la pérdida de su posición a tomar. Esta versatilidad ha hecho que esta medida sea extendida a un gran número de series financieras; algunos de los primeros autores que sugirieron implementarla en el mercado de commodities fueron Manfredo & Leuthold (1999), argumentando que el uso de esta herramienta con precios agrícolas podría presentar un comportamiento distintito al encontrado con precios de activos financieros.

Una de las desventajas de esta medida es que no cumple con las características propias de una *medida de riesgo coherente* según lo descrito por Artzner, Delbaen, Eber, & Heath (1999). Más específicamente, su falencia reside en no satisfacer la propiedad de subaditividad, lo que en otras palabras significa que el VaR de un portafolio diversificado puede ser mayor que la suma de los VaR de portafolios individuales. Lo anterior, al ir en contravía de los postulados de la teoría de portafolio moderna, dio paso al surgimiento de la medida del *Déficit o Pérdida Esperada* en las colas (*ES*, por sus siglas en inglés) como un reemplazo de la misma. Sin embargo, gracias a que Danielsson, Jorgensen, Sarma, & de Vries (2006) demuestran que para distribuciones de colas pesadas, como las de series de retornos de commodities, medidas como el VaR y el ES ordenan el riesgo de la misma manera. Por esta razón, en el presente estudio dejamos a un lado el ES como medida alternativa, para enfocarnos en el VaR como nuestra medida de riesgo de referencia.

Uno de los avances realizados en el cálculo del VaR tiene que ver con la inclusión de la *Teoría del Valor Extremo (TVE)*, un método paramétrico de estimación, el cual “se ajusta asintóticamente sobre los valores extremos de las distribuciones y se encarga de definir hacia dónde convergen las distribuciones de valor máximo de una variable aleatoria, dependiendo de lo que se defina como valor extremo” (Uribe & Ulloa, 2012, p. 98). Esta teoría complementa muy bien al VaR, ya que ambas se centran en explicar las colas de la distribución de las series, lugar donde se encuentran los datos atípicos causantes de aumentar la exposición al riesgo de las mismas.

De la implementación de la TVE al VaR, especial atención en la literatura ha recibido el método de dos pasos propuesto por McNeil & Frey (2000). Estos autores, reconociendo que las series financieras presentan clústeres de volatilidad, hecho incompatible con los requerimientos de la TVE, plantean como primer paso, realizar un proceso de filtración de los datos mediante un modelo de varianza condicionada GARCH, para después, con series independiente e idénticamente distribuidas (iid), pasar a ajustar alguna de las distribuciones propuestas por la TVE.

Este último método, para el caso de los commodities, ha sido utilizado en muy pocos trabajos, dentro de los cuales se encuentran Byström (2005), Fong & Gray (2006), Marimoutou, Raggad, & Trabelsi (2009) y Youssef, Belkacem, & Mokni (2015). Sin embargo, estos autores solo buscan probar hechos estilizados de las series financieras, como lo son, asimetría, colas pesadas, clústeres de volatilidad, entre otros, que se hacen extensibles a los commodities, lo cual no es lo que busca esta investigación. Además, la estructura de sus estudios consiste en comparar el desempeño de varios modelos para una estimación más robusta del VaR, desconociendo toda la teoría que subyace los mercados de commodities, en especial la de los futuros, y por ende, dejando a un lado todo el debate que actualmente se está dando respecto al proceso de *financiarización* de los mismos.

Es por esta razón que este estudio es innovador al proponer al VaR, una medida ampliamente utilizada en la literatura financiera y estimada robustamente gracias a la TVE, particularmente al método de McNeil & Frey (2000), para otorgar nueva evidencia a favor del proceso de *financiarización de los commodities* a través del canal de la distribución de riesgo entre los distintos agentes de los mercados de futuros de estos bienes.

4.1. Teoría del Valor Extremo (TVE)

En principio, partimos del hecho bien establecido que las series financieras presentan colas pesadas (leptocurtosis), es decir, condensan un mayor número de eventos atípicos en los extremos de su función de distribución. Estos son de gran importancia, ya que en una serie de retornos de commodities -como es nuestro caso- es donde se encuentran las caídas drásticas en los precios (cola inferior) o las subidas repentinas en los mismos (cola superior). Por esta razón, esta información es valiosa para estimar el riesgo en precio al cual se encuentran expuestos nuestros commodities.

Para medir este riesgo, es de gran ayuda la Teoría del Valor Extremo (TVE), ya que se encarga de asignar (asintóticamente) una distribución de probabilidad a las observaciones presentes en estas colas y así, modelar su comportamiento. La importancia de esta teoría recae en que no se tienen en cuenta todos los datos de la serie, sino solo aquellos que están en los extremos de su función de distribución, lugar donde realmente reside el riesgo. La base teórica para realizar este tipo de modelación surge de los trabajos de Fisher & Tippet (1928) y Gnedenko (1943).

El teorema de la TVE tiene una gran similitud con el teorema del límite central debido a que ambos utilizan la *ley de los grandes números* para acercarse a la verdadera distribución de los datos mediante un proceso de convergencia. La teoría del límite central nos dice que una suma de variables aleatorias independientes e idénticamente distribuidas (iid), al ser estandarizada y su número de variables tender al infinito, converge en distribución hacia una normal estándar. Siguiendo lo expuesto por Rocco (2011), si nos centramos ahora en los *máximos* de una serie de n variables aleatorias iid $X_1, \dots, X_n$, tales que $M_n = \max\{X_1, \dots, X_n\}$, el interés es encontrar la función de distribución acumulada de M_n , la cual es desconocida y denominaremos F^n . Esta última se debe diferenciar de la función de distribución de todas las $X_1, \dots, X_n$, llamada F . Fisher & Tippet (1928), estandarizando M_n de la forma $\frac{M_n - d_n}{c_n}$, donde d_n es un parámetro de localización y $c_n > 0$ es un parámetro de escala, se encargaron de encontrar la distribución *no degenerada*² $H(x)$, la cual está dada por:

$$\Pr\left\{\frac{M_n - d_n}{c_n} \leq x\right\} \rightarrow H(x) \text{ a medida que } n \rightarrow \infty. \quad (6)$$

Por otra parte, asumiendo que los parámetros d_n y c_n existen, Gnedenko (1943) demostró que $H(x)$ converge a una de las siguientes 3 familias de distribuciones no degeneradas:

$$\text{Fréchet: } H_\varepsilon(x) = \begin{cases} 0, & \text{si } x \leq 0 \\ \exp\{-x^{-1/\varepsilon}\}, & \text{si } x > 0 \end{cases} \text{ además } \varepsilon > 0; \quad (7)$$

$$\text{Gumbel: } H_0(x) = \exp\{-\exp(-x)\}, \quad x \in \mathbb{R} \quad \text{además } \varepsilon = 0; \quad (8)$$

$$\text{Weibull: } H_\varepsilon(x) = \begin{cases} \exp\{-(-x)^{1/\varepsilon}\}, & \text{si } x \leq 0 \\ 1, & \text{si } x > 0 \end{cases} \text{ además } \varepsilon < 0. \quad (9)$$

$H_\varepsilon(x)$ es entonces, quien anida estas tres familias de distribuciones y por esto se denomina distribución de *Valor Extremo Generalizada (GEV)*, por sus siglas en inglés). La selección de cada familia es determinada según el valor del *parámetro de forma* ε , el cual determina el comportamiento de las colas de la distribución. Este parámetro también se puede encontrar en la literatura en su representación $\alpha = 1/\varepsilon$, la cual hace mención al *índice de cola*.

² Una función de distribución F es no degenerada si existe un valor x tal que $G(x) \in]0,1[$.

Por tanto, si lo anterior se cumple, F está en el *máximo dominio de atracción* (MDA, por sus siglas en inglés) de H_ε , o matemáticamente $F \in MDA(H_\varepsilon)$ (ver McNeil, Frey, & Embrechts, 2005, p. 266). Es por esta razón que el parámetro ε mide el peso de la función de la cola derecha de F (Gomes & Guillou, 2015), es decir $\bar{F} := 1 - F$.

Haciendo alusión a las diferentes familias de distribuciones mencionadas, es de resaltar la relevancia que tiene la *Fréchet* para este trabajo, y en general, para la modelación de series financieras. Ésta posee la característica de que a su vez anida otras distribuciones que exhiben un lento decaimiento de sus colas, es decir, que tienen colas pesadas. Algunas de las distribuciones que se derivan de este grupo son la distribución *t-student*, *log-gamma* y *de Pareto*. Por otra parte, a pesar de que la cola de las distribuciones de la familia *Gumbel* es infinita hacia su lado derecho, su decaimiento es más rápido que el de las distribuciones de la familia *Fréchet* y por lo tanto, su aplicabilidad a series financieras es limitada; la distribución *normal*, *log-normal*, *gamma*, *chi-cuadrado*, entre otras, hacen parte de este grupo. Finalmente, la familia *Weibull* es descartada para el análisis de series financieras ya que su cola derecha es acotada.

Rocco (2014) resalta como ventaja de la Teoría del Valor Extremo, que la distribución asintótica final resultante no depende de la función exacta de distribución acumulativa de los retornos. Además, la TVE se centra solamente en las colas de la distribución que es donde realmente reside el riesgo. Y por último, se pueden analizar las dos colas de la distribución de forma separada, ofreciendo la posibilidad de calcular distintos patrones de asimetría en los datos.

4.2. Modelo GPD

Existen tres métodos³ para modelar $H_\varepsilon(x)$ y estimar el parámetro *de forma* ε : dos métodos paramétricos, los cuales reciben el nombre de *máximos por bloques* o *modelo GEV* y *superación del umbral* o *modelo GPD*; y uno no paramétrico, conocido como el *estimador de Hill*⁴. Sin embargo, para esta investigación nos enfocaremos en el de superación del umbral, ya que según lo descrito por Rocco (2011), “permite un uso más parsimonioso de los datos y depende de una base teórica igual de sólida que en el caso del método máximos por bloques” (p. 24).

Dentro de algunas desventajas halladas en los otros dos métodos, McNeil et al. (2005) indican por ejemplo, que el de máximos por bloques desperdicia muchos datos. Por otro lado, Rocco (2011) advierte que el estimador de Hill solo es aplicable cuando $\varepsilon > 0$, es decir, solo cuando se sabe con certeza que las colas de la distribución son pesadas, y que su estimación es muy sensible a la selección del parámetro k , el cual representa el corte entre

³ Estos 3 métodos no son los únicos, ya que también existen generalizaciones tales como el *enfoque del proceso de puntos*, la *distribución Box-Cox-GEV*, entre otros (ver Rocco, 2011). No obstante, los métodos arriba nombrados son los más populares dentro de la literatura de eventos extremos.

⁴ Otros métodos no paramétricos son: *estimador de Pickands*, *estimador DEdH*, entre otros (ver Rocco, 2011).

las observaciones del centro de la distribución y las de las colas. Sin embargo, como veremos más adelante, la escogencia de este corte representará un gran desafío para todos los métodos, incluyendo el del modelo GPD.

Otra razón para escoger este método se encuentra sustentada en el trabajo de McNeil & Frey (2000), quienes demuestran mediante simulación, que a pesar de que el estimador de Hill es reconocido como el estimador más eficiente de ε , éste no provee la mejor estimación cuando se trata de cuantiles. Bajo esta circunstancia, estos autores concluyen que el modelo GDP es el mejor para la estimación de cuantiles altos, como el VaR.

Intuitivamente, el método de superación del umbral nos dice que para definir nuestros valores extremos, debemos escoger las observaciones que excedan un determinado umbral al que llamaremos u (Figura 1). Formalmente, siguiendo a McNeil et al. (2005) y Rocco (2011), siendo X una variable aleatoria con función de distribución F , la distribución de los excesos por encima de un umbral u , F_u , la definimos como:

$$F_u(x) = \Pr(X - u \leq x | X > u) = \frac{F(x+u) - F(u)}{1 - F(u)}, \quad 0 \leq x < x_F - u, \quad x_F = \sup\{x \in \mathbb{R}: F(x) < 1\}. \quad (10)$$

Asimismo, F_u sigue una distribución asintótica $G_{\varepsilon, \beta}$, la cual lleva el nombre de *Distribución Generalizada de Pareto (GPD)*, por sus siglas en inglés), y está definida por:

$$G_{\varepsilon, \beta}(x) = \begin{cases} 1 - (1 + \varepsilon x / \beta)^{-1/\varepsilon}, & \varepsilon \neq 0 \\ 1 - \exp(-x / \beta), & \varepsilon = 0 \end{cases} \quad (11)$$

donde $\beta > 0$. Además $x \geq 0$ cuando $\varepsilon \geq 0$ y $0 \leq x \leq -\beta/\varepsilon$ cuando $\varepsilon < 0$. Es de notar que en esta distribución, además del parámetro de forma, tenemos un *parámetro de escala* β .




Figura 1. Selección de los valores extremos dado un umbral u según el modelo GDP. Los puntos rojos se conocen como excesos sobre el umbral y representan los valores extremos de nuestra distribución. Fuente: Rocco (2011).

Llegado a este punto, Balkema & de Haan (1974) y Pickands (1975) se dieron a la tarea de relacionar esta distribución resultante con la distribución GEV expuesta en el numeral anterior. Su resultado se ve enmarcado en el teorema que señala que para cualquier $\varepsilon \in \mathbb{R}$, existe una función positiva y medible $\beta(u)$, tal que:

$$\lim_{u \rightarrow x_F} \sup_{0 < x < x_F - u} |F_u(x) - G_{\varepsilon, \beta(u)}(x)| = 0, \quad (12)$$

si y solo si $F \in MDA(H_\varepsilon)$, donde H_ε es la distribución GEV con el mismo parámetro de forma ε que en la nueva distribución $G_{\varepsilon, \beta(u)}$. Lo anterior indica que la función de distribución de excesos sobre el umbral F_u converge hacia la distribución GDP con parámetro ε , a medida que u crece hasta el punto final de la derecha de x_F . Asimismo, estas dos distribuciones están dentro del máximo dominio de atracción de la distribución GEV, y por ende, comparten exactamente el mismo parámetro ε , el cuál es el encargado de relacionar las dos teorías (Rocco, 2011). Por último, este modelo GDP también es conocido como el *modelo tradicional del umbral fijo*.

4.3. Modelo GARCH

Según lo ya expuesto, la TVE fue erigida bajo el supuesto que todas las series de variables aleatorias modeladas se comportan *independiente e idénticamente distribuidas (iid)*. No obstante, un hecho estilizado de las series financieras, que se extiende a los commodities, indica que éstas presentan clústeres de volatilidad. Por tal motivo, según lo propuesto por McNeil & Frey (2000), es posible utilizar un modelo GARCH para modelar la estructura de dependencia de las series, y así, trabajar con los residuales resultantes, los cuales son iid.

El modelo *Autorregresivo Generalizado de Heterocedasticidad Condicional (GARCH)*, por sus siglas en inglés), quien pertenece a la familia de modelos GARCH lineales, fue desarrollado por Bollerslev (1986) y es -como su nombre lo indica- una generalización del famoso modelo ARCH de Engle (1982). Estos modelos son de gran ayuda para la modelación de la volatilidad de series financieras ya que ésta varía con el tiempo y presenta agrupamientos o clústeres (Chkili, Hammoudeh, & Nguyen, 2014).

Por lo tanto, si tenemos una serie de retornos r_t por cada uno de nuestros commodities, un modelo GARCH(1,1)⁵ puede ser representado mediante:

$$r_t = \mu_t + \varepsilon_t \quad (13)$$

$$\varepsilon_t = \sigma_t z_t, \quad z_t \sim NID(0,1) \quad (14)$$

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2, \quad (15)$$

donde μ_t denota la media incondicional y σ_t^2 la varianza condicional de nuestros retornos. Además, se debe cumplir que $\omega > 0$, $\alpha_1 \geq 0$, $\beta_1 \geq 0$ y que $\alpha_1 + \beta_1 < 1$ para que la varianza condicional de nuestro modelo sea positiva y estacionaria.

4.4. Modelo ARMA

Así como la varianza condicional puede ser modelada a través de un GARCH, la ecuación (13) puede ser extendida para modelar la media condicional de la serie de retornos r_t . Esto se puede hacer utilizando un modelo *Autorregresivo de Media Móvil ARMA(p,q)* del tipo:

⁵ Para la versión GARCH(p,q) y una ampliación del tema referirse a Bollerslev (1986) o McNeil et al. (2005).

$$r_t = \phi_0 + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (16)$$

Donde p y q son enteros positivos, y todas las raíces características de (16) están por fuera del círculo unitario.

4.5. Selección del Umbral y el modelo compuesto GNG

La estimación de la GPD por el método de superación del umbral tiene dos grandes limitaciones: la escogencia del umbral y la cuantificación de la incertidumbre detrás de su escogencia (Zhao, Scarrott, Oxley, & Reale, 2010). Zhao et al. (2010) advierten por ejemplo, que el umbral debe ser lo suficientemente alto para asegurar que las observaciones por encima de éste converjan asintóticamente a la distribución de la familia Pareto Generalizada. No obstante, debido a que entre más alto es el umbral, más reducida es la muestra de los datos que lo sobrepasan, se crea un sesgo en los parámetros estimados ya que su varianza será más alta. Es por esto que el *trade-off* existente entre estas dos condiciones vuelve aún más difícil la selección del umbral.

Según lo reseñan Scarrott & MacDonald (2012), en la literatura de la TVE existen diferentes métodos para escoger este umbral. El primero, utiliza diagnósticos de gráficas para evaluar visualmente el ajuste del modelo y así, establecer un umbral fijo *a priori*; sin embargo, este método, además de requerir una vasta experiencia, es subjetivo y toma mucho tiempo. Otra forma de hacerlo es a través de *reglas empíricas* propuestas por diferentes autores, las cuales establecen un porcentaje fijo de la cantidad de datos que deberían superar el umbral; lo anterior, dicen Scarrott & MacDonald (2012), es inapropiado desde un punto de vista teórico. Otros métodos, como el estimador de Hill, dependen también de criterios de gráficas. Y por último, enfoques computacionales por medio de *bootstrap*, fallan al no contabilizar la incertidumbre asociada con la escogencia del umbral.

Para solucionar estos inconvenientes, un grupo de autores se han dado a la tarea de desarrollar los que serían conocidos bajo el nombre de *modelos compuestos de valor extremo o extreme value mixture models*. Su principio es combinar un modelo de umbral flexible que se ajuste a las colas de la distribución, como el GDP, con un modelo flexible que se ajuste a la masa o centro de la distribución, como la distribución normal. Con esto se busca que el umbral se estime automáticamente como un parámetro más, de forma implícita o explícita, y que la incertidumbre asociada a éste se incorpore dentro de la inferencia (Scarrott & MacDonald, 2012). Dentro de una extensa gama de modelos de este tipo que hasta ahora existen en la literatura, este estudio se enfoca en el modelo paramétrico desarrollado por Zhao (2010) y Zhao et al. (2010) gracias a su aplicabilidad a series del sector financiero.

Zhao (2010) y Zhao et al. (2010) proponen un modelo compuesto, en el cual se ajusta una distribución normal al centro de la distribución de los datos, y dos GDP independientes en cada una de las colas de la distribución, por esto es que es nombrado *GPD-Normal-GPD* o

modelo compuesto de dos colas GNG. Ellos escogen la distribución normal debido a su aplicabilidad a series financieras y a su forma unimodal, aproximadamente simétrica y de forma cuadrática alrededor de la moda. Y como quiera que en los retornos importan tanto las pérdidas como las ganancias, se ajusta simultáneamente una distribución GPD a cada una de las colas, lo cual permite una contabilización de la incertidumbre al momento de estimar el umbral, y otorga flexibilidad para observar comportamientos asimétricos de las mismas. Lo anterior es central dentro de los resultados del estudio.

Siguiendo a Zhao (2010), siendo X una variable aleatoria iid, la función de distribución de un modelo compuesto, $P(X < x) = F(x)$ tiene la forma:

$$F(x | m, s, \varepsilon_r, \sigma_r, u_r, \varepsilon_l, \sigma_l, u_l) = \begin{cases} \Phi(u_l | m, s) [1 - G(-x | \varepsilon_l, \sigma_l, -u_l)], & x \leq u_l \\ \Phi(x | m, s), & u_l < x < u_r \\ \Phi(u_r | m, s) + [1 - \Phi(u_r | m, s)] G(x | \varepsilon_r, \sigma_r, u_r), & x \geq u_r \end{cases} \quad (17)$$

Donde $\Phi(x | m, s)$ es la distribución normal acumulada con media m y varianza s^2 :

$$\Phi(x | m, s) = \frac{1}{s\sqrt{2\pi}} \int_{-\infty}^x \exp\left\{-\frac{(t-m)^2}{2s^2}\right\} dt, \quad x \in \mathcal{R}, \quad (18)$$

y $G(x | \varepsilon, \sigma, u)$ es la función de distribución de la GPD con parámetro de forma ε , de escala σ y umbral u :

$$G(x | \varepsilon, \sigma, u) = \begin{cases} 1 - \left[1 + \varepsilon \left(\frac{x-u}{\sigma}\right)\right]^{-1/\varepsilon}, & \varepsilon \neq 0 \\ 1 - \exp\left[-\frac{x-u}{\sigma}\right], & \varepsilon = 0 \end{cases}, \quad (19)$$

que debe cumplir con que $x \geq u$, $1 + \varepsilon \left(\frac{x-u}{\sigma}\right) > 0$ y $\sigma > 0$.

Además, los subíndices de los parámetros de la GPD y de los umbrales son “ l ” refiriéndose a la cola izquierda o las pérdidas extremas, y “ r ” refiriéndose a la cola derecha o las ganancias extremas. Esta nueva función de distribución GNG toma la forma de la figura 2.




Figura 2. Ejemplo de la función de distribución compuesta GPD-Normal-GPD o GNG. En los dos extremos se ajustan la distribución GPD y en el centro de la distribución una normal. Las dos líneas verticales que separan cada una de las distribuciones son los umbrales, izquierdo (inferior) y derecho (superior), respectivamente. Fuente: Zhao et al. (2010).

Para estimar este modelo los autores proponen usar un método Bayesiano, ya que éste tiene la ventaja del uso de una distribución a priori, lo que puede generar estimaciones precisas de los parámetros, debido a la escasez de los datos extremos. Además, “la distribución posterior contiene más información de los parámetros del modelo comparada con el método de ML, ya que el análisis bayesiano trata a los parámetros como variables aleatorias y considera la incertidumbre de los parámetros en la inferencia”⁶ (Zhao, 2010, p. 18).

Dentro de las principales ventajas de este modelo, Zhao et al. (2010) enumeran: primero, no hay una escogencia subjetiva del umbral, ya que se estima automáticamente como un parámetro más; segundo, la incertidumbre de su escogencia es tomada en cuenta dentro del proceso de inferencia; tercero, al estimar las dos colas con distribuciones GPD independientes se pueden apreciar comportamientos asimétricos en las mismas; cuarto, este modelo permite capturar la distribución de las dos colas simultáneamente. Asimismo, estos autores conservan la metodología de dos pasos de McNeil & Frey (2000), por lo que su modelo se convierte en un GARCH-GNG. Finalmente, también se reconocen algunas desventajas del modelo, como la complejidad agregada al proceso de inferencia debido al extenso número de parámetros a estimar, la escogencia a priori de la distribución normal para el centro de la distribución y, que ésta última pueda afectar el ajuste de las colas de la distribución.

4.6. Valor en Riesgo (VaR)

El VaR nos dice cuánto (dinero) podemos perder con una probabilidad dada y en un cierto periodo de tiempo (1 o más días). Matemáticamente, McNeil et al. (2005) definen al VaR, con un nivel de confianza de $p \in]0,1[$ y teniendo una función de distribución de pérdidas $F(x) = P(X \leq x)$, como:

$$VaR_\alpha = \inf\{x \in \mathbb{R}: P(X \leq x) \leq 1 - p\} = \inf\{x \in \mathbb{R}: F(x) \geq p\}, \quad (20)$$

es decir, el número más pequeño x , tal que la probabilidad de que la pérdida L exceda a x , no sea más grande que $1 - p$. En otras palabras, el VaR es un cuantil de la distribución de pérdidas.

Según lo demuestra Zhao (2010), esta medida se puede calcular desde el modelo GNG expuesto en el punto anterior, escalando la distribución condicional GPD a la probabilidad de estar encima del umbral $p^* = P(X > u_r)$, tal que:

$$p(X < x) = P(X < x | X > u_r)P(X > u_r) = G(x | \varepsilon_r, \sigma_r, u_r) p^* \quad (21)$$

Al invertir la ecuación anterior, se obtiene el cuantil $1 - p$, q_p , tal que:

$$q_p = \begin{cases} u - \frac{\sigma}{\varepsilon} \left[1 - \left(\frac{p}{p^*} \right) \right]^{-\varepsilon}, & \varepsilon \neq 0 \\ u - \sigma \log \left(\frac{p}{p^*} \right), & \varepsilon = 0 \end{cases}. \quad (22)$$

⁶ Para más información del método de estimación utilizado, el lector puede referirse a Zhao (2010).

La ecuación (22) es estimada bajo el enfoque tradicional del modelo GPD, suponiendo que $p^* = P(X > u_r)$ es el estimador empírico simple (ver McNeil et al., 2005, p. 283). Pero debido a que el modelo GNG describe la distribución de toda la muestra, el cuantil para ambas colas puede ser estimado más fácilmente utilizando la inversa de la función de distribución GNG o $GNG^{-1}(x)$. Esta es otra ventaja que ofrece este modelo comparado con el tradicional. Lo anterior también aplica para el cuantil p de la cola inferior.

4.7. Prueba de Causalidad de Granger

Siguiendo el recuento de literatura hecho por Grosche (2014), una variable X puede causar otra variable Y , si la probabilidad de pronosticar correctamente a Y_{t+1} , con $t = 1, \dots, T$, incrementa debido a la inclusión de la información sobre X_t en el conjunto de información específico para el periodo t , conocido como Ω_t . Cuando la causalidad se da en ambos sentidos, es decir, X_t ayuda a predecir Y_{t+1} y Y_t ayuda a predecir X_{t+1} , se dice que hay un efecto de retroalimentación entre ambas variables. Más formalmente, X_t causa en media a Y_{t+1} , si:

$$E[Y_{t+1}|\Omega_t] \neq E[Y_{t+1}|\Omega'_t], \quad (23)$$

donde Ω_t es un conjunto que contiene toda la información disponible en el mundo a excepción de la información de X , y Ω'_t es un conjunto de información extendido que sí contiene la información de X . No obstante, debido a que la información en Ω_t es limitada, solo se puede establecer una *causalidad prima facie o a primera vista*, es decir, X_t causa Y_{t+1} hasta tanto nueva información incluida en el conjunto de información demuestre lo contrario. Formalmente, X_t causa en media a primera vista a Y_{t+1} , si:

$$MSE\{E[Y_{t+1}|J_t]\} > MSE\{E[Y_{t+1}|J'_t]\}, \quad (24)$$

donde MSE es el error cuadrático medio, J_t es un nuevo conjunto de información que incluye solo información del pasado y presente de Y , y J'_t extiende la información J_t , incluyendo la información de X_t .

Una de las formas de probar la ecuación (24) es a través de una prueba estadística utilizando como proceso generador de datos un *Vector Autorregresivo (VAR)* bivariado de la forma:

$$Y_t = c_1 + \sum_{i=1}^m \alpha_i Y_{t-i} + \sum_{j=1}^n \beta_j X_{t-j} + \varepsilon_{1t}, \quad (25)$$

$$X_t = c_2 + \sum_{i=1}^m \gamma_i Y_{t-i} + \sum_{j=1}^n \delta_j X_{t-j} + \varepsilon_{2t}, \quad (26)$$

para $t = 1, \dots, T$, donde m y n denotan la cantidad de rezagos, c_1 y c_2 son constantes, $\alpha, \beta, \gamma, \delta$ son los coeficientes de la regresión y $\varepsilon_{1t}, \varepsilon_{2t}$ son procesos ruido blanco. De la ecuación (25), estableciendo la hipótesis nula $H_0: \beta_1 = \beta_2 = \dots = \beta_n = 0$, podemos probar si X ayuda a predecir Y , y lo contrario se puede probar con $H_0: \gamma_1 = \gamma_2 = \dots = \gamma_m = 0$ en la ecuación (26). Debido a las hipótesis anteriores, esta es una prueba de *no causalidad prima facie*, la cual se puede probar mediante un test de Wald.

5. Resultados

5.1. Los Datos

Para llevar a cabo la parte empírica de esta investigación, se utilizaron 27 series de precios de futuros de commodities descargados de la base de datos *Stevens Continuous Futures (SCF)* del portal *Quandl.com* (Tabla A1). Las series tienen una periodicidad diaria, y corresponden a precios oficiales de cierre del día (*settlement price*), con un promedio de 5.087 datos por cada una. La irregularidad de las mismas se debe a los diferentes días de funcionamiento de las bolsas donde es transado cada bien, por tanto, la muestra de este trabajo aborda un periodo aproximado de enero de 1996 a mayo de 2016 (a excepción del Gas ICE y la Leche, los cuales tienen un periodo menor debido a la disponibilidad de los datos) (Tabla A1). Para crear series de contratos continuos, la base de datos sigue una metodología de *Precios Ajustados Ponderados por Calendario (Calendar-Weighted Adjusted Prices)*, *Rodados cada Primer Mes (Roll on First of Month)*.

Por otro lado, siguiendo a Eller & Sagerer (2008), los commodities fueron agrupados por sectores según tres categorías, las cuales se despliegan siguiendo su categoría directamente anterior (Tabla A2). Estas categorías abarcan la mayoría de sectores de los commodities más transados en el mundo. Sin embargo, es de aclarar que las transacciones de los mercados de futuros de estas mercancías son centralizadas en bolsas de Estados Unidos y Europa, en donde sobresalen los monopolios conformados por el *CME Group* y el *ICE (Intercontinental Exchange)*. Por último, se utilizan precios de futuros y no precios *spot* o *de contado*, gracias a la función de los mercados de futuros de formar y descubrir precios a través de contratos estandarizados, los cuales sirven como referencia para la toma de decisiones de distintos agentes alrededor del mundo.

Todas las series de precios se encuentran exhibidas según la categoría 1 en las figuras A1-A2, donde también se resalta con una línea vertical el 15 de septiembre de 2008, día que corresponde a la quiebra de Lehman Brothers en Estados Unidos, el cual sirve como referencia para simbolizar el estallido de la crisis financiera del 2008 o *Crisis SubPrime*. Asimismo, las figuras A3-A4 grafican los *retornos continuamente compuestos* de los commodities de nuestra muestra, los cuales se derivan de los precios siguiendo la fórmula $r_t = \ln(P_t) - \ln(P_{t-1})$. Estos últimos son utilizados ampliamente en la literatura financiera debido a su sentido económico (valores por encima de cero reflejan ganancias, y por debajo, pérdidas), y a que ayudan a resolver problemas de raíces unitarias presentes en los datos.

5.2. Rolling VaR o RVaR

Debido a que es del interés de esta investigación observar la evolución del riesgo a través del tiempo, proponemos, adicional a la metodología ya expuesta, un procedimiento de *Rolling VaR (RVaR)* o *VaR Rodante*, el cual consiste en establecer una ventana móvil de 1.000 observaciones (4 años aprox.), la cual se irá corriendo (*rodando*) cada 5 observaciones (una semana aprox.) a medida que se vaya estimando el VaR. Este procedimiento se asemeja al que se lleva a cabo durante la realización de pruebas de

backtesting al VaR convencional, con la diferencia que en este caso no se realizarán predicciones fuera de muestra, sino estimaciones dentro de la muestra. Por otro lado, el ancho de la ventana se establece de forma arbitraria siguiendo lo reseñado en Nieto & Ruiz (2016), estudios como el de Zhao et al. (2010), y a las diferentes pruebas de simulación realizadas en Zhao (2010).

Hay que recordar que respecto al tamaño de la ventana existe un trade-off entre utilizar muestras grandes para garantizar la estabilidad de los parámetros, o muestras pequeñas para que los parámetros estimados se adapten a condiciones recientes del mercado (Nieto & Ruiz, 2016). Lo anterior también tiene implicaciones para la estimación de modelos de la TVE; muestras muy grandes introducen mucho ruido a los extremos al incluir periodos de turbulencias económicas que obedecen a causas distintas, y por tanto, pueden tornarse en una mala fuente de información para predicciones hacia el futuro; y por el contrario, debido a que los eventos extremos son solo una pequeña fracción de la muestra, tamaños pequeños de la misma implican estimaciones sesgadas de los parámetros de la distribución de las colas.

Por otra parte, utilizamos una frecuencia aproximadamente semanal en el rolling, ya que así evitamos ruidos relacionados a la microestructura de los datos diarios (Cheng et al., 2015). Además, otra razón de peso para realizar estimaciones semanales tiene que ver con la alta capacidad computacional que exige un procedimiento de este tipo; dependiendo del procesador con el que se cuente, realizar esta estimación para una muestra como ésta y bajo las especificaciones establecidas, puede demorarse hasta un día completo (o más).

Una desventaja de este procedimiento es que no es posible obtener información del VaR durante las primeras 1.000 observaciones de cada bien de la muestra. Sin embargo, las dimensiones de las series se ajustaron para que la primera estimación del VaR correspondiera exactamente al 03/01/2000 hasta aprox. el 05/05/2016, periodo alrededor del cual ha girado todo el debate de la *financiarización de los commodities*. Es por este motivo que las series expuestas en la tabla 1A tienen un periodo de inicio distinto pero aproximado a enero de 1996. Lo anterior no fue posible hacerlo para el Gas ICE y para la Leche debido a la disponibilidad de los datos.

Por otra parte, debido a que el VaR es un cuantil que puede establecerse a varias probabilidades, en esta investigación nos enfocamos en los valores 0,01, correspondiente al VaR de la cola izquierda, y 0,99, al de la cola derecha. Estas medidas son las más utilizadas para medir el riesgo en los mercados financieros y, aunque no aplica para este estudio, estas también son las requeridas por los acuerdos de Basilea para monitorear el riesgo de las entidades financieras (Nieto & Ruiz, 2016). Otras probabilidades, como las de 0,001 y 0,999, son utilizadas para pruebas de estrés de los mercados, pero por motivos de espacio y tiempo en la estimación, en este trabajo nos limitamos a presentar solo los resultados de las primeras.

5.3. Estimación automatizada.

Una de las grandes preocupaciones de esta investigación ha sido la de optimizar el tiempo empleado para la estimación del VaR para todas las 27 series siguiendo la metodología descrita; esto equivale a realizar unos 820 cálculos aprox. por cada serie (debido al rolling) y un total de 22.140 para todos los 27 commodities. A lo anterior también se debe agregar los cálculos implícitos requeridos por los modelos que ayudan a estimar esta medida: la escogencia de los rezagos del modelo ARMA, la estimación del GARCH y la estimación del GNG. Por este motivo, gracias a la ayuda de diferentes librerías ofrecidas por el programa *R*, se diseñó una estimación automatizada del modelo empírico el cual llevará por nombre *AR-GARCH-GNG-VaR*.

La primera tarea que se realiza en este tipo de investigaciones es probar si los datos exhiben un comportamiento distinto al de una distribución normal que amerite la utilización de métodos alternativos de estimación como los de la TVE. Para esto, medimos la asimetría y la curtosis de los retornos de cada una de nuestras series siguiendo el procedimiento de ventana móvil del numeral anterior. Como se puede observar en las figuras A5-A8, en la mayoría de los periodos rodantes de nuestra muestra los datos exhiben asimetrías variantes entre positivas y negativas, así como una curtosis que en varios casos supera el valor de 3, indicándonos la presencia de distribuciones leptocúrticas (colas pesadas). Por último, para dar un soporte formal de la no normalidad de nuestros datos, se ejecutaron Pruebas Jarque-Bera las cuales soportan la utilización del modelo GNG (Figuras A9-A10).

Seguidamente, el paquete *forecast* de Hyndman (2016), por medio de su función *auto.arima*, es el encargado de estimar automáticamente el modelo de media condicional ARMA, utilizando como proceso de selección el criterio de información AIC, junto con un algoritmo de automatización expuesto en Hyndman & Khandakar (2008). Debido a que es imposible mostrar los resultados de las 22.140 estimaciones, los mismos son simplificados en las figuras A11-A12, donde solo se exponen los rezagos p y q escogidos en cada periodo estimado. Este procedimiento tiene la ventaja de ofrecernos -basado en una prueba ADF- el número de diferencias requeridas en caso de existir raíces unitarias. Estos valores también se pueden observar en las figuras A11-A12, los cuales dan fe de la estacionariedad de nuestras sub-muestras.

Lamentablemente, en la literatura no existe un proceso similar al anterior que sirva para estimar la varianza condicional de múltiples series escogiendo dentro de una gama de modelos de la familia GARCH. Esto se debe a que, primero, existe una extensa variedad de modelos de este tipo (ver Francq & Zakoïan (2010), por ejemplo). Segundo, el proceso de comparación y escogencia de estos modelos se hace a través de backtesting, lo cual complejiza la automatización. Tercero, algunos autores como Chkili et al. (2014), comparando el ajuste de varios modelos de esta familia en los mercados de commodities, encuentran que ninguno es superior al otro; la única diferencia que hallan es entre modelos GARCH lineales y no lineales.

Siendo consecuentes con lo anterior, en este trabajo hacemos uso de un modelo GARCH(1,1) gracias a su flexibilidad en el ajuste de la volatilidad de una gran variedad de

series de altas frecuencias, además de su amplia utilización en la literatura financiera. Igualmente, este modelo es utilizado como referencia en el procedimiento de dos pasos de McNeil & Frey (2000), y del mismo modo, es replicado en trabajos que utilizan la TVE aplicada a mercados de commodities (ver Byström, 2005; Marimoutou et al., 2009; entre otros). Para estimar este modelo, utilizamos el paquete *fGarch* de Wuertz & Chalabi (2016), y la significancia de los parámetros estimados es simplificada en las figuras A13-A14.

Finalmente, el modelo GNG otorga la última pieza para que la estimación del VaR de esta gran cantidad de series pueda hacerse de forma robusta y automática. Debido a que la escogencia del umbral era subjetiva y requería mucho tiempo, ahora se hace de forma automática al ser el umbral estimado dentro del modelo. En las figuras A15-16 se presentan los valores del umbral escogidos para cada una de las colas de las distribuciones durante el periodo de nuestra muestra. Este modelo, y el VaR son estimados mediante el paquete *evmix* de Scarrott & Hu (2015).

5.4. Panorama general del riesgo en el mercado de commodities.

Una vez estimado el VaR de ambas colas de la distribución de nuestras series, la figura 3 nos ofrece una primera comparación del riesgo de los precios de futuros entre los dos grupos más grandes de materias primas: *hard* o commodities duros, y *soft* o commodities livianos.

Lo primero que salta a la vista en esta gráfica es que en ambas colas de la distribución, los bienes duros siempre exhiben niveles más altos de riesgo que los livianos. También se puede observar que el riesgo no ha sido constante durante el periodo de la muestra; a partir de mediados del 2008 y hasta mediados del 2012 aprox., los niveles se disparan, sobre todo en el grupo de los pesados. Lo anterior coincide de forma cercana con el estallido de la crisis SubPrime de 2008, si se toma como referencia la quiebra de Lehman Brothers el 15 de septiembre de 2008 (línea roja vertical punteada). Por último, es difícil ver si el VaR de la cola izquierda (VaR.l), el cual ha sido invertido para una comparación visual más fácil (-VaR.l), presenta un riesgo superior a su homólogo de la cola derecha; el del Gas_ICE y el Gas_NIMEX son los únicos que se podría decir, presentan diferencias notables.

Si comenzamos a desagregar la clasificación de nuestros commodities, la figura 4 reafirma que los sectores más riesgosos de la muestra son el energético y el de metales, ambos componentes de la categoría *hard*, sobre todo después del segundo semestre del 2008. Aquí también se puede apreciar cómo el riesgo se mueve en paralelo entre algunos bienes dentro de cada sector, sincronizándose en periodos de turbulencia económica. Sin embargo, pareciera que el comportamiento atípico de los dos gases obedeciera a patrones diferentes comparado con otros bienes dentro de su categoría; este comportamiento no esperado se analizará más adelante.




Figura 3. Panorama general del riesgo de las commodities según la categoría 1. *Panel a*, representa las estimaciones del VaR de la cola izquierda; *Panel b*, representa las estimaciones del VaR de la cola derecha. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008. Fuente: Elaboración propia.



Figura 4. Panorama general del riesgo de las commodities según la categoría 2. Panel a, representa las estimaciones del VaR de la cola izquierda; Panel b, representa las estimaciones del VaR de la cola derecha. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008. Fuente: Elaboración propia.

No sobra decir que todos los valores expuestos han sido suavizados para una visualización más clara, teniendo en cuenta que los datos semanales, que se alcanzan a apreciar en el fondo de cada gráfica, siguen conservando una variabilidad bastante alta, sobre todo en el mercado energético y de metales.

Ya teniendo la primera impresión del comportamiento del riesgo de los diferentes mercados de commodities, es necesario resaltar la importancia de analizar las dos colas de la distribución de las series pertenecientes a los mercados de futuros. Por un lado, la literatura financiera le atribuye al VaR de la cola izquierda, el riesgo de incurrir en grandes pérdidas; tratar de modelar su comportamiento es lo que más ha estado bajo el escrutinio académico. Por otro lado, al VaR de la cola derecha se le conoce como el “riesgo” de ganancias inesperadas, empero, este último concepto difiere dependiendo del mercado con el cual se esté trabajando. Como el énfasis de esta investigación recae sobre el mercado de futuros, es muy importante advertir que dependiendo del operador desde donde se observe, ambas colas entrarán a representar el riesgo de presentar *pérdidas*. Esto se debe a que un mercado de futuros representa un *juego de suma cero*, en el cual existen dos distintos jugadores tomando cuatro distintas posiciones, y las ganancias de uno son iguales a las pérdidas del otro.

Los dos grandes grupos de operadores de este mercado, como ya se ha mencionado, corresponden a aseguradores y especuladores. Los aseguradores pueden tomar posiciones en corto (vender contratos de futuros) y presentan pérdidas si al momento del vencimiento del contrato, el precio de contado del subyacente ha aumentado por encima del valor de recompra del contrato; ganan si pasa lo contrario. Este asegurador también puede realizar posiciones en largo (comprar contratos), por lo cual, gana en caso de caída de precios y pierde en caso contrario. Los primeros son normalmente granjeros, agricultores o productores, y los segundos son procesadores de alimentos u otra clase de consumidores que utilizan estas materias primas como input en sus procesos de producción; en cualquiera de los dos casos, estos agentes no apuestan a ganar o perder, sino que utilizan el mercado de futuros para fijar precios y así protegerse ante caídas en los precios del mercado de contado o spot (primer caso), o subidas de los mismos (segundo caso).

Lo anterior ofrece la impresión de que quienes utilizan los commodities como materia prima pueden actuar como contraparte de las posiciones efectuadas por los agricultores. Sin embargo, Cheng & Xiong (2014) documentan que fue Hirshleifer (1988) quien identificó que los consumidores, quienes conforman la contraparte natural de las posiciones de los productores, no se protegen debido a que tienen que afrontar el riesgo de una gran gama de productos, lo cual se traduce en costos fijos elevados por participar en cada uno de los mercados de futuros que requieran. Los productores, en cambio, debido a que concentran el riesgo de precios en un bien específico, solo afrontan los costos fijos de un solo mercado, por tanto, tienen más incentivos de participar dentro del mismo.

Es así como surge la importancia del rol de los especuladores, quienes actúan como contraparte de estos dos agentes, efectuando igualmente posiciones en largo y en corto, y

conservando las mismas implicaciones ya mencionadas. Quienes toman posiciones solo en largo son los CITs a través de los índices de commodities, y en cambio, los money managers -junto con otros especuladores- toman posiciones en ambos lados estableciendo un trading más activo (ya sea a través de hedge funds o ETPs). La diferencia que tienen estos operadores con los aseguradores, es que los primeros *apuestan* a la posibilidad de obtener ganancias, y a su vez, otorgan liquidez a estos mercados para mantenerlos “vivos”.

En la práctica, según lo exponen Tang & Xiong (2012), Cheng & Xiong (2014), entre otros, es posible observar que los aseguradores por lo general, realizan posiciones en corto netas (posiciones en corto > posiciones en largo), y por el otro lado, los especuladores realizan posiciones en largo igualmente netas (posiciones en largo > posiciones en corto). Por tanto, tomamos este hecho para suponer que el VaR izquierdo corresponde al riesgo de pérdidas que afrontan los especuladores y el VaR derecho es el riesgo de pérdidas que soportan los aseguradores.

5.5. Asimetría del riesgo.

Una vez analizado el VaR de cada una de las colas de los commodities por separado, el paso lógico a seguir es realizar un análisis conjunto de los mismos. La figura 5 extrae el comportamiento asimétrico del riesgo de los dos extremos de la distribución de cada uno de los retornos de las mercancías clasificadas según la categoría 3. Estas tendencias son el resultado de sumar (restar) el VaR izquierdo con el derecho, los cuales se muestran conjuntamente en las figuras A17-A18. Este comportamiento asimétrico se puede entender como los cambios en la asignación o repartición del riesgo, los cuales son inducidos por el grupo con menos capacidad de soportar riesgo hacia el grupo con más capacidad de hacerlo, a la Cheng et al. (2015) y su *flujo convectivo de riesgo*.

Se esperaría por tanto, que en un mercado equilibrado y tranquilo, la presión de soportar riesgo fuera balanceada entre aseguradores y especuladores, y así, la suma entre el VaR.l y el VaR.r se mantuviera cercana a 0. Sin embargo y según la figura 5, un comportamiento de este tipo solo ocurre en pocos mercados durante el periodo de estudio. Por el contrario, una fuerte asimetría jalonada por el riesgo afrontado por los especuladores se puede ver en la gran mayoría de sectores, la cual comienza en algunos casos, antes del estallido de la crisis financiera y se podría adecuar -en parte- al comienzo del proceso de la *financiarización* propuesto por Tang & Xiong (2012).

Ejemplo de lo anterior, es el caso del sector energético (con excepción del gas natural ICE o NIMEX), los metales preciosos, algunas semillas para la producción de sustitutos del petróleo y algunos semi-refinados. Por otra parte, en sectores como el de granos y otras cuantas mercancías, este comportamiento inusual se sincroniza casi exactamente con el estallido de la crisis (línea vertical roja).




Figura 5. Asimetría del riesgo de los retornos de los futuros de commodities según la categoría 3. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008 y la línea horizontal punteada representa plena simetría en el comportamiento del riesgo de ambas colas. Fuente: Elaboración propia.

No obstante, estas gráficas tienen el limitante de solo representar la existencia del riesgo asimétrico entre ambas colas, sin otorgar pruebas respecto a la dirección en la cual éste podría estar *fluyendo* de un grupo de agentes hacia al otro. Es por eso que para observar este tipo de relación, hacemos uso de pruebas de causalidad a la Granger para determinar si es posible encontrar evidencias respecto a la trayectoria en la cual se da este fenómeno; si es de los aseguradores hacia los especuladores, como lo predice la teoría de la presión por asegurarse, o si por el contrario, es de los especuladores hacia los aseguradores, según lo descrito por Cheng & Xiong (2014).

5.6. Prueba de Granger.

Antes de realizar las pruebas respectivas, es preciso señalar que el alcance de las mismas se limitará a encontrar indicios del tipo *causalidad prima facie*, es decir, de si el VaR de una cola *ayuda a predecir* el VaR de la otra. De ninguna forma se establecerán relaciones de causalidad en el amplio sentido de la palabra, las cuales solo podrían llegar a demostrarse mediante modelos estructurales donde (casi) toda la información relevante para este fenómeno se encuentra disponible.

Para realizar esta prueba, primero se dividió la muestra en cuatro periodos distintos, los cuales hacen referencia a hechos que la literatura del debate de la *financiarización* considera relevantes: el primero, ocupa toda la muestra del 03/01/2000 al 06/05/2016; el segundo, cubre el periodo anterior al estallido de la crisis financiera del 03/01/2000 al 14/09/2008; el tercero, abarca la etapa post-crisis del 15/09/2008 al 06/05/2016; y el último, es una fase intermedia, la cual comienza el 01/01/2004, fecha establecida por Tang & Xiong (2012) como el inicio de la *financiarización de los commodities*, hasta el 31/12/2012, periodo intermedio a la tercera división. Cada uno de los últimos tres periodos trata de guardar una longitud equivalente para tener estimados comparables entre sí.

La tabla 1 exhibe los valores p de los resultados de la prueba, los cuales fueron calculados por medio del paquete *vars* de Pfaff & Stigler (2015). Para realizar esta tarea, primero se estimó un modelo VAR(n), cuyos rezagos fueron seleccionados automáticamente siguiendo el criterio AIC, y después se probó la hipótesis nula de no causalidad del VaR.l al VaR.r y del VaR.r al VaR.l. Los rezagos utilizados para la selección del modelo VAR, así como la prueba de no estacionariedad de las series VaR son exhibidos en la tabla A3.

Para el primer periodo o *muestra total* es posible observar que la relación corre en ambos sentidos para la gran mayoría de mercancías; el Gasóleo para Calefacción, el Maíz, la Harina de Soja y la Madera, por el contrario, indican que el flujo del riesgo fue conducido de especuladores hacia aseguradores, y el Azúcar y el Cacao en el sentido contrario. En la *pre-crisis*, bienes como el Brent, el WTI, la Harina y el Aceite de Soja presentan el primer patrón de causalidad, pero son más los bienes que siguen la teoría de la presión por asegurarse.

Tabla 1Prueba de *causalidad prima facie* a la Granger para todos los commodities clasificados según la categoría 3.

Commodities	Muestra total		Pre-crisis		Post-crisis		Intermedio	
	VaR.l ↔VaR.r	VaR.r ↔VaR.l	VaR.l ↔VaR.r	VaR.r ↔VaR.l	VaR.l ↔VaR.r	VaR.r ↔VaR.l	VaR.l ↔VaR.r	VaR.r ↔VaR.l
	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p
<i>Energía Fósil</i>								
Brent	0,00	0,00	0,00	0,12	0,00	0,00	0,00	0,00
Diesel	0,00	0,00	0,21	0,14	0,00	0,20	0,02	0,05
Gas_ICE	0,00	0,00	0,20	0,01	0,01	0,03	0,00	0,00
Gas_NIMEX	0,01	0,00	0,04	0,02	0,07	0,01	0,36	0,04
Gasoleo_calef	0,00	0,16	0,12	0,16	0,00	0,15	0,03	0,72
WTI	0,00	0,03	0,00	0,11	0,00	0,27	0,00	0,08
<i>Metales Base</i>								
Cobre	0,00	0,00	0,00	0,00	0,10	0,13	0,00	0,00
<i>Metales Preciosos</i>								
Oro	0,00	0,00	0,65	0,43	0,04	0,04	0,00	0,00
Paladio	0,00	0,00	0,52	0,00	0,06	0,07	0,00	0,00
Plata	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00
Platino	0,00	0,00	0,08	0,00	0,00	0,00	0,00	0,00
<i>Granos</i>								
Arroz	0,06	0,00	0,32	0,01	0,12	0,03	0,41	0,01
Avena	0,00	0,00	0,00	0,00	0,23	0,00	0,01	0,00
Maíz	0,01	0,24	0,66	0,52	0,07	0,70	0,00	0,34
Trigo	0,03	0,00	0,48	0,00	0,02	0,65	0,18	0,03
<i>Semillas para crear aceite</i>								
Aceite_soja	0,00	0,05	0,03	0,84	0,00	0,18	0,00	0,23
Harina_soja	0,00	0,19	0,00	0,29	0,17	0,03	0,02	0,72
Soja	0,00	0,00	0,64	0,35	0,01	0,00	0,01	0,00
<i>Semi-refinados</i>								
Azúcar	0,21	0,00	0,64	0,07	0,91	0,01	0,56	0,00
Café	0,04	0,00	0,04	0,00	0,44	0,85	0,10	0,00
Cocoa	0,32	0,03	0,10	0,19	0,04	0,33	0,59	0,03
Jugo_naranja	0,00	0,00	0,80	0,41	0,22	0,20	0,66	0,04
<i>Agro-animal</i>								
Cerdos	0,00	0,01	0,53	0,10	0,59	0,33	0,00	0,05
Ganado	0,06	0,05	0,09	0,34	0,45	0,00	0,93	0,40
Leche	0,00	0,01	0,19	0,01	0,11	0,16	0,01	0,09
<i>Agro-industrial</i>								
Algodón	0,00	0,00	0,82	0,06	0,00	0,02	0,25	0,00
Madera	0,00	0,06	0,46	0,03	0,01	0,25	0,00	0,01

Nota: El periodo de muestra total se extiende del 03/01/2000 al 06/05/2016; el de pre-crisis de 03/01/2000 al 14/09/2008; el de post-crisis de 15/09/2008 al 06/05/2016; y el de intermedio de 01/01/2004-31/12/2012. VaR.l ↔ VaR.r representan la hipótesis nula de no causalidad del VaR.l al VaR.r y VaR.r ↔ VaR.l representa lo contrario. Los valores sombreados representan causalidad en ambas direcciones y en negrita causalidad en una dirección. Valores en cursiva significan rechazo al 10%.

Uno de los periodos más importantes, el de la *post-crisis*, destaca que mercados como el energético (a excepción del gas natural) y productos como el Trigo, el Maíz, y el Aceite de Soja, fueron de una forma indirecta los más afectados por la crisis, ya que es posible observar que la transmisión del riesgo pasó muy probablemente de otros mercados financieros hacia estos a través de los especuladores. Por último, el periodo *intermedio*, enfatiza los resultados obtenidos en los dos periodos anteriores, sobre todo para definir la dirección VaR.l hacia VaR.r en algunos bienes del mercado energético, otros de las semillas para biocombustibles y productos como el Maíz, y asimismo, la dirección contraria, en la mayoría de mercancías de los semi-refinados, el gas natural NIMEX y algunos granos.

Si realizamos un consenso de todos los periodos, podemos observar que existen fuertes indicios respecto a la existencia de un *flujo convectivo del riesgo* de especuladores hacia aseguradores -sobre todo en fases de turbulencia económica- en bienes como el Gasóleo para Calefacción, el WTI, el Aceite de Soja, el Maíz, y en una menor instancia, en bienes como la Harina de Soja, el Diésel, la Madera y el Trigo. Un aspecto que coincide con la evidencia aquí señalada, es que la mayoría de estos bienes hacen parte del S&P GCSI, uno de los índices tildado de ser el responsable de promover la *financiarización de los commodities* (ver Tang & Xiong, 2012). La composición de este índice para algunos años de interés es exhibida en la tabla A4, donde se puede ver la gran proporción que ocupa el mercado energético dentro del mismo.

Por otra parte, para obtener un resultado más robusto, se realizaron estas mismas pruebas, pero considerando la heterocedasticidad presente en las series, siguiendo lo propuesto por Hafner & Herwartz (2009). Los resultados obtenidos se encuentran en la tabla A5 y van en el mismo sentido que los ya mencionados. Sin embargo, reconocemos que la prueba llevada a cabo en esta sección tiene la desventaja de no contar con la incertidumbre generada durante el proceso de estimación del VaR y por tanto, puede afectar la distribución de los estadísticos del test y así, otorgar resultados con varianzas sesgadas (ver Candelon, Joëts, & Tokpavi, 2013).

Una solución a lo anterior se puede encontrar a través de la realización de un procedimiento de *bootstrapping* o mediante *pruebas Monte Carlo*, las cuales no obstante, trascienden los límites de esta investigación. Otra salida útil es utilizando pruebas aplicadas directamente a los retornos, pero poniendo énfasis en los cuantiles extremos de su distribución. Ejemplo de lo anterior es la prueba de *Causalidad de Granger en Riesgo* propuesto por Hong, Liu, & Wang (2009) y aplicado al mercado del petróleo por Du & He (2015), o *pruebas de causalidad en las colas de la distribución o por cuantiles*, aplicadas igualmente al mercado del petróleo en los trabajos de Candelon et al. (2013) y Ding, Kim, & Park (2014). Estos últimos, que también están por fuera de los alcances de este trabajo, serán centro de futuras investigaciones.

5.7. El mercado del Gas Natural

Como se ha observado a lo largo de este análisis, el mercado del gas ha actuado como un *outlier* dentro del sector energético; su asimetría en riesgo ha sido contraria a la de sus

homólogos, exhibiendo además, unos niveles positivos muy altos. No obstante, a pesar de tener un comportamiento contrario, este bien refuerza la idea del *flujo convectivo del riesgo*, pero en el sentido aseguradores hacia especuladores, lo que siempre da por hecho la teoría de la presión por asegurarse. El evento clave para explicar este comportamiento en el Gas NIMEX por ejemplo, comienza a partir de la primera década del 2000, y en particular del 2006, donde USA incrementó sus niveles de reservas de gas dramáticamente debido a lo que la literatura reconoce como la *Revolución del Gas de Lulita o de Esquisto (Shale Gas)* (Cummins & Murphy, 2015).

Este hecho está directamente relacionado con la implementación del *fracking* o *fracturación hidráulica* como un método novedoso de extracción de hidrocarburos, causando una sobreoferta de este bien junto con una caída drástica de sus precios de futuros transados en el NIMEX (de referencia para USA) (Figura A1). Esta caída, por tanto, ha disparado el nivel de riesgo al que se enfrentan los aseguradores, y ha aumentado su presión por asegurarse, lo que explica la asimetría positiva de su riesgo, y además, siguiendo la tabla 1, ha provocado una redirección del flujo del riesgo de aseguradores hacia especuladores.

Por otra parte, el Gas ICE de referencia para Reino Unido y Europa -a pesar de no tener un aumento de las reservas como en USA pues no sufrió una “revolución” semejante-, por el hecho de llegar a ser sustituto del NIMEX (ver Cummins & Murphy, 2015), ha venido comportándose de manera similar al mismo, con una asimetría positiva parecida y con una dirección en el flujo del riesgo de aseguradores a especuladores en el periodo pre-crisis (Tabla 1).

Finalmente, este hecho refuerza la idea del *flujo convectivo del riesgo*, no obstante causado por un motivo distinto: los fundamentales. Por lo tanto, queda como material de futuras investigaciones, entrar a indagar los hechos específicos que pudieron causar la asimetría del riesgo en cada bien, y no a manera de panorama general de todo el mercado de commodities, como lo hace este trabajo.

6. Conclusiones

Esta investigación se incorpora al actual debate de la *Hipótesis de Master*, otorgando evidencia a favor de la existencia del proceso de *financiarización de los commodities*. Más específicamente, nos basamos en el modelo teórico presentado por Cheng et al. (2015), el cual plantea la presencia de un *flujo convectivo del riesgo* entre agentes de los mercados de futuros de commodities, para syndicar que a través del canal de la distribución de riesgo, la especulación ha aumentado el riesgo en los precios de futuros de varios commodities en las dos décadas más recientes.

Nos diferenciamos de otros estudios en que la metodología aquí expuesta no ha sido utilizada para el análisis de este hecho. Esta metodología consistió en emplear la medida del *Valor en Riesgo Rodante* o “RVaR” (*Rolling Value-at-Risk*) estimada mediante los

avances de la *Teoría del Valor Extremo (TVE)*; de la TVE, resaltamos la implementación del modelo *GPD-Normal-GPD (GNG)* de Zhao (2010), el cual nos permitió hallar aspectos importantes respecto al comportamiento asimétrico del riesgo de las colas de la distribución de nuestras series de futuros de commodities.

Como hecho empírico clave, se encontró la existencia de fuertes asimetrías negativas entre el VaR de la cola izquierda y el VaR de la cola derecha durante casi todo el periodo de muestra, en especial, alrededor de la crisis financiera del 2008. Esto nos dio un indicativo de la presión que ejercen los diferentes grupos que interactúan en el mercado de futuros de commodities para conducir el riesgo que soportan dentro de dicho mercado.

Asimismo, se utilizaron pruebas de *causalidad a la Granger* que, sin ánimos de buscar causalidades en el amplio sentido de la palabra, nos dieron indicios respecto a la existencia de un *flujo convectivo del riesgo* de especuladores hacía aseguradores -sobre todo en fases de turbulencia económica- en bienes como el Gasóleo para Calefacción, el WTI, el Aceite de Soja, el Maíz, y en una menor instancia, en bienes como la Harina de Soja, el Diésel, la Madera y el Trigo.

No obstante, también reconocemos que las pruebas que se llevaron a cabo tienen la desventaja de no contar con la incertidumbre generada durante el proceso de estimación del VaR y por tanto, pudieron haber otorgado resultados con varianzas sesgadas. Es por eso que futuras investigaciones buscaran probar otros enfoques existentes en la literatura, como *pruebas de causalidad de Granger en riesgo o por cuantiles*, para reafirmar o refutar los resultados aquí encontrados.

Finalmente, para otorgarle más robustez a los hallazgos de este trabajo, proponemos como buena práctica de investigación, la reproducción de los resultados aquí expuestos, pero utilizando ventanas móviles de amplitudes más grandes, 3.000 o 5.000 observaciones, y cambiando la frecuencia de los rodamientos, a 1 o más de 5 días. Asimismo, el desarrollo de un método automatizado de *backtesting* dentro del rolling sería de gran interés para reafirmar la solidez de nuestro modelo *AR-GARCH(1,1)-GNG-VaR*.

7. Referencias

- Artzner, P., Delbaen, F., Eber, J. M., & Heath, D. (1999). Coherent measures of risk. *Mathematical Finance*, 9(3), 203-228. Recuperado a partir de <http://www.scopus.com/inward/record.url?eid=2-s2.0-0033412999&partnerID=tZOtx3y1>
- Aulerich, N., Irwin, S., & Garcia, P. (2013). *Bubbles, Food Prices, and Speculation: Evidence from the CFTC's Daily Large Trader Data Files*. Cambridge, MA. Recuperado a partir de <http://www.nber.org/papers/w19065.pdf>
- Balkema, A. A., & de Haan, L. (1974). Residual Life Time at Great Age. *The Annals of Probability*, 2(5), 792-804. Recuperado a partir de <http://www.jstor.org/stable/2959306>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327. [http://doi.org/10.1016/0304-4076\(86\)90063-1](http://doi.org/10.1016/0304-4076(86)90063-1)
- Byström, H. N. E. (2005). Extreme value theory and extremely large electricity price changes. *International Review of Economics & Finance*, 14(1), 41-55. [http://doi.org/10.1016/S1059-0560\(03\)00032-7](http://doi.org/10.1016/S1059-0560(03)00032-7)
- Candelon, B., Joëts, M., & Tokpavi, S. (2013). Testing for Granger causality in distribution tails: An application to oil markets integration. *Economic Modelling*, 31, 276-285. <http://doi.org/10.1016/j.econmod.2012.11.049>
- Cheng, I.-H., Kirilenko, A., & Xiong, W. (2015). Convective Risk Flows in Commodity Futures Markets. *Review of Finance*, 19(5), 1733-1781. <http://doi.org/10.1093/rof/rfu043>
- Cheng, I.-H., & Xiong, W. (2014). Financialization of Commodity Markets. *Annual Review of Financial Economics*, 6(1), 419-441. <http://doi.org/10.1146/annurev-financial-110613-034432>
- Chkili, W., Hammoudeh, S., & Nguyen, D. K. (2014). Volatility forecasting and risk management for commodity markets in the presence of asymmetry and long memory. *Energy Economics*, 41, 1-18. <http://doi.org/10.1016/j.eneco.2013.10.011>
- Cummins, M., & Murphy, B. (2015). Natural Gas Markets and Products. En A. Roncoroni, G. Fusai, & M. Cummins (Eds.), *Handbook of Multi-Commodity Markets and Products: Structuring, Trading and Risk Management* (pp. 135-180). Chichester, UK: John Wiley & Sons.
- Daniélsson, J., Jorgensen, B. N., Sarma, M., & de Vries, C. G. (2006). Comparing downside risk measures for heavy tailed distributions. *Economics Letters*, 92(2), 202-208. <http://doi.org/10.1016/j.econlet.2006.02.004>
- de Nicola, F., de Pace, P., & Hernandez, M. A. (2016). Co-movement of major energy, agricultural, and food commodity price returns: A time-series assessment. *Energy Economics*, 57, 28-41. <http://doi.org/10.1016/j.eneco.2016.04.012>
- Declerk, F. (2015). Agricultural and Soft Markets. En *Handbook of Multi-Commodity Markets and Products* (pp. 399-498). Chichester, UK: John Wiley & Sons, Ltd. <http://doi.org/10.1002/9781119011590.ch9>
- Delatte, A.-L., & Lopez, C. (2013). Commodity and equity markets: Some stylized facts from a copula approach. *Journal of Banking & Finance*, 37(12), 5346-5356. <http://doi.org/10.1016/j.jbankfin.2013.06.012>
- Ding, H., Kim, H.-G., & Park, S. Y. (2014). Do net positions in the futures market cause spot

- prices of crude oil? *Economic Modelling*, 41, 177-190.
<http://doi.org/10.1016/j.econmod.2014.05.008>
- Du, L., & He, Y. (2015). Extreme risk spillovers between crude oil and stock markets. *Energy Economics*, 51, 455-465. <http://doi.org/10.1016/j.eneco.2015.08.007>
- Eller, R., & Sagerer, C. (2008). An Overview of Commodity Sectors. En F. J. Fabozzi, R. Fuss, & D. G. Kaiser (Eds.), *The Handbook of Commodity Investing* (pp. 681-711). Hoboken, NJ, USA: Wiley.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
<http://doi.org/10.2307/1912773>
- Fattouh, B., Kilian, L., & Mahadeva, L. (2013). The Role of Speculation in Oil Markets: What Have We Learned So Far? *The Energy Journal*, 34(3), 7-33.
<http://doi.org/10.5547/01956574.34.3.2>
- Fisher, R. A., & Tippett, L. H. C. (1928). Limiting forms of the frequency distribution of the largest or smallest member of a sample. *Mathematical Proceedings of the Cambridge Philosophical Society*, 24(2), 180. <http://doi.org/10.1017/S0305004100015681>
- Fong, K., & Gray, P. (2006). Using extreme value theory to measure value-at-risk for daily electricity spot prices. *International Journal of Forecasting*, 22(2), 283-300.
<http://doi.org/10.1016/j.ijforecast.2005.10.002>
- Francq, C., & Zakoïan, J.-M. (2010). *GARCH Models*. Chichester, UK: John Wiley & Sons, Ltd. <http://doi.org/10.1002/9780470670057>
- Giot, P., & Laurent, S. (2003). Market risk in commodity markets: a VaR approach. *Energy Economics*, 25(5), 435-457. [http://doi.org/10.1016/S0140-9883\(03\)00052-5](http://doi.org/10.1016/S0140-9883(03)00052-5)
- Gnedenko, B. (1943). Sur La Distribution Limite Du Terme Maximum D'Une Serie Aleatoire. *The Annals of Mathematics*, 44(3), 423. <http://doi.org/10.2307/1968974>
- Gomes, M. I., & Guillo, A. (2015). Extreme Value Theory and Statistics of Univariate Extremes: A Review. *International Statistical Review*, 83(2), 263-292.
<http://doi.org/10.1111/insr.12058>
- Grosche, S.-C. (2014). What Does Granger Causality Prove? A Critical Examination of the Interpretation of Granger Causality Results on Price Effects of Index Trading in Agricultural Commodity Markets. *Journal of Agricultural Economics*, 65(2), 279-302.
<http://doi.org/10.1111/1477-9552.12058>
- Hafner, C. M., & Herwartz, H. (2009). Testing for linear vector autoregressive dynamics under multivariate generalized autoregressive heteroskedasticity. *Statistica Neerlandica*, 63(3), 294-323. <http://doi.org/10.1111/j.1467-9574.2009.00424.x>
- Hicks, J. R. (1939). *Value and capital : an inquiry into som fundamental principles of economic theory*. Oxford: The Clarendon Press.
- Hirshleifer, D. (1988). Residual Risk, Trading Costs, and Commodity Futures Risk Premia. *The Review of Financial Studies*, 1(2), 173-193. Recuperado a partir de <http://www.jstor.org/stable/2962008>
- Hirshleifer, D. (1990). Hedging Pressure and Futures Price Movements in a General Equilibrium Model. *Econometrica*, 58(2), 411. <http://doi.org/10.2307/2938209>
- Hong, Y., Liu, Y., & Wang, S. (2009). Granger causality in risk and detection of extreme risk

- spillover between financial markets. *Journal of Econometrics*, 150(2), 271-287.
<http://doi.org/10.1016/j.jeconom.2008.12.013>
- Hyndman, R. J. (2016). forecast: Forecasting functions for time series and linear models. R package version 7.3. Recuperado a partir de <http://github.com/robjhyndman/forecast>
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1-22.
<http://doi.org/10.18637/jss.v027.i03>
- Irwin, S. H. (2013). Commodity index investment and food prices: does the «Masters Hypothesis» explain recent price spikes? *Agricultural Economics*, 44(s1), 29-41.
<http://doi.org/10.1111/agec.12048>
- Irwin, S. H., & Sanders, D. R. (2012). Testing the Masters Hypothesis in commodity futures markets. *Energy Economics*, 34(1), 256-269. <http://doi.org/10.1016/j.eneco.2011.10.008>
- Keynes, J. M. (1923). Some Aspects of Commodity Markets. *Manchester Guardian Commercial, European Reconstruction Series Section 13*.
- Kilian, L., & Murphy, D. P. (2014). The Role of Inventories and Speculative Trading in the Global Market for Crude Oil. *Journal of Applied Econometrics*, 29(3), 454-478.
<http://doi.org/10.1002/jae.2322>
- Labuszewski, J. W. (2006). Revisions to GSCI Composition and Weights for 2007. CME - Chicago Mercantile Exchange. Recuperado a partir de <http://www.cftc.gov/files/submissions/rules/selfcertifications/2006/rul110706cme001.pdf>
- Manfredo, M. R., & Leuthold, R. M. (1999). Value-at-Risk Analysis: A Review and the Potential for Agricultural Applications. *Applied Economic Perspectives and Policy*, 21(1), 99-111. <http://doi.org/10.2307/1349974>
- Marimoutou, V., Raggad, B., & Trabelsi, A. (2009). Extreme Value Theory and Value at Risk: Application to oil market. *Energy Economics*, 31(4), 519-530.
<http://doi.org/10.1016/j.eneco.2009.02.005>
- McNeil, A. J., & Frey, R. (2000). Estimation of tail-related risk measures for heteroscedastic financial time series: an extreme value approach. *Journal of Empirical Finance*, 7(3-4), 271-300. [http://doi.org/10.1016/S0927-5398\(00\)00012-8](http://doi.org/10.1016/S0927-5398(00)00012-8)
- McNeil, A. J., Frey, R., & Embrechts, P. (2005). *Quantitative risk management: concepts, techniques and tools*. Princeton, N.J.: Princeton University Press.
- Mensi, W., Beljid, M., Boubaker, A., & Managi, S. (2013). Correlations and volatility spillovers across commodity and stock markets: Linking energies, food, and gold. *Economic Modelling*, 32, 15-22. <http://doi.org/10.1016/j.econmod.2013.01.023>
- Nieto, M. R., & Ruiz, E. (2016). Frontiers in VaR forecasting and backtesting. *International Journal of Forecasting*, 32(2), 475-501. <http://doi.org/10.1016/j.ijforecast.2015.08.003>
- Nijs, L. (2014). Commodities III: Speculation on (Agricultural) Commodity Derivatives and Financialization of Commodity-Price Formation. En *The Handbook of Global Agricultural Markets* (pp. 401-442). London: Palgrave Macmillan UK.
<http://doi.org/10.1057/9781137302342>
- Pfaff, B., & Stigler, M. (2015). vars: VAR Modelling. R package version 1.5-2. Recuperado a partir de <https://cran.r-project.org/web/packages/vars/index.html>
- Pickands, J. (1975). Statistical Inference Using Extreme Order Statistics. *The Annals of*

- Statistics*, 3(1), 119-131. Recuperado a partir de <http://www.jstor.org/stable/2958083>
- Rocco, M. (2011). Extreme value theory for finance: a survey. *Questioni di economia e finanza (Occasional papers)*, (99). Recuperado a partir de http://www.bancaditalia.it/pubblicazioni/qef/2011-0099/QEF_99.pdf
- Rocco, M. (2014). Extreme value theory in finance: A survey. *Journal of Economic Surveys*, 28(1), 82-108. <http://doi.org/10.1111/j.1467-6419.2012.00744.x>
- S&P Global. (2016). *S&P GSCI Methodology*. Recuperado a partir de <http://us.spindices.com/indices/commodities/sp-gsci>
- Scarrott, C., & Hu, Y. (2015). evmix: Extreme Value Mixture Modelling, Threshold Estimation and Boundary Corrected Kernel Density Estimation. R package version 2.6. Recuperado a partir de <https://cran.r-project.org/web/packages/evmix/index.html>
- Scarrott, C., & MacDonald, A. (2012). A review of extreme value threshold estimation and uncertainty quantification. *Revstat Statistical Journal*, 10(1), 33-60. Recuperado a partir de <https://www.ine.pt/revstat/pdf/rs120102.pdf>
- Singleton, K. J. (2014). Investor Flows and the 2008 Boom/Bust in Oil Prices. *Management Science*, 60(2), 300-318. <http://doi.org/10.1287/mnsc.2013.1756>
- Stoll, H. R., & Whaley, R. E. (2010). Commodity Index Investing and Commodity Futures Prices. *Journal of Applied Finance (Formerly Financial Practice and Education)*, 20(1), 7-46. Recuperado a partir de https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2693084
- Tang, K., & Xiong, W. (2012). Index Investment and the Financialization of Commodities. *Financial Analysts Journal*, 68(6), 54-74. <http://doi.org/10.2469/faj.v68.n6.5>
- Uribe, J. M., & Ulloa, I. (2012). La medición del riesgo en eventos extremos. Una revisión metodológica en contexto. *Lecturas de Economía*, (76), 87-117. Recuperado a partir de http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-25962012000100004&lng=en&tlng=es
- Wuertz, D., & Chalabi, Y. (2016). fGarch: Rmetrics - Autoregressive Conditional Heteroskedastic Modelling. R package version 3010.82.1. Recuperado a partir de <https://cran.r-project.org/web/packages/fGarch/index.html>
- Youssef, M., Belkacem, L., & Mokni, K. (2015). Value-at-Risk estimation of energy commodities: A long-memory GARCH-EVT approach. *Energy Economics*, 51, 99-110. <http://doi.org/10.1016/j.eneco.2015.06.010>
- Zhao, X. (2010). *Extreme value modelling with application in finance and neonatal research*. University of Canterbury. Recuperado a partir de <https://ir.canterbury.ac.nz/handle/10092/4024>
- Zhao, X., Scarrott, C., Oxley, L., & Reale, M. (2010). Extreme value modelling for forecasting market crisis impacts. *Applied Financial Economics*, 20(1-2), 63-72. <http://doi.org/10.1080/09603100903262947>

8. Apéndice.

Tabla A1

Listado de series de commodities de futuros.

ID	Código Quandl	Nombre del Futuro	Nombre Corto	Fecha Inicio	Fecha Final	Datos
1	SCF/ICE_B1_FW	ICE Brent Crude Oil Futures #1 (B1)	Brent	18/01/1996	06/05/2016	5187
2	SCF/ICE_G1_FW	ICE Gasoil Futures #1 (G1)	Diesel	18/01/1996	06/05/2016	5192
3	SCF/ICE_M1_FW	ICE UK Natural Gas Futures #1 (M1)	Gas_ICE	03/02/1997	06/05/2016	4917
4	SCF/CME_NG1_FW	NYMEX Natural Gas Futures #1 (NG1)	Gas_NIMEX	09/01/1996	06/05/2016	5093
5	SCF/CME_HO1_FW	NYMEX Heating Oil Futures #1 (HO1)	Gasoleo_calef	09/01/1996	06/05/2016	5092
6	SCF/CME_CL1_FW	NYMEX WTI Crude Oil Futures #1 (CL1)	WTI	09/01/1996	06/05/2016	5102
7	SCF/CME_HG1_FW	COMEX Copper Futures #1 (HG1)	Cobre	09/01/1996	06/05/2016	5082
8	SCF/CME_GC1_FW	NYMEX Gold Futures #1 (GC1)	Oro	09/01/1996	06/05/2016	5101
9	SCF/CME_PA1_FW	NYMEX Palladium Futures #1 (PA1)	Paladio	09/01/1996	06/05/2016	5129
10	SCF/CME_SI1_FW	NYMEX Silver Futures #1 (SI1)	Plata	09/01/1996	06/05/2016	5094
11	SCF/CME_PL1_FW	NYMEX Platinum Futures #1 (PL1)	Platino	09/01/1996	06/05/2016	5120
12	SCF/CME_RR1_FW	CBOT Rough Rice Futures #1 (RR1)	Arroz	16/01/1996	06/05/2016	5107
13	SCF/CME_O1_FW	CBOT Oats Futures #1 (O1)	Avena	16/01/1996	06/05/2016	5110
14	SCF/CME_C1_FW	CBOT Corn Futures #1 (C1)	Maiz	16/01/1996	06/05/2016	5110
15	SCF/CME_W1_FW	CBOT Wheat Futures #1 (W1)	Trigo	16/01/1996	06/05/2016	5112
16	SCF/CME_BO1_FW	CBOT Soybean Oil Futures #1 (BO1)	Aceite_soja	16/01/1996	06/05/2016	5107
17	SCF/CME_SM1_FW	CBOT Soybean Meal Futures #1 (SM1)	Harina_soja	16/01/1996	06/05/2016	5097
18	SCF/CME_S1_FW	CBOT Soybeans Futures #1 (S1)	Soja	16/01/1996	06/05/2016	5113
19	SCF/ICE_SB1_FW	ICE Sugar No. 11 Futures #1 (SB1)	Azucar	02/01/1996	06/05/2016	5094
20	SCF/ICE_KC1_FW	ICE Coffee C Futures #1 (KC1)	Cafe	02/01/1996	06/05/2016	5095
21	SCF/ICE_CC1_FW	ICE Cocoa Futures #1 (CC1)	Cocoa	02/01/1996	06/05/2016	5095
22	SCF/ICE_OJ1_FW	ICE Orange Juice Futures #1 (OJ1)	Jugo_naranja	03/01/1996	06/05/2016	5098
23	SCF/CME_LN1_FW	CME Lean Hogs Futures #1 (LN1)	Cerdos	16/01/1996	06/05/2016	5098
24	SCF/CME_LC1_FW	CME Live Cattle Futures #1 (LC1)	Ganado	16/01/1996	06/05/2016	5098
25	SCF/CME_DA1_FW	CME Class III Milk Futures #1 (DA1)	Leche	22/07/1997	06/05/2016	4719
26	SCF/ICE_CT1_FW	ICE Cotton Futures #1 (CT1)	Algodon	04/01/1996	06/05/2016	5096
27	SCF/CME_LB1_FW	CME Random Length Lumber Futures #1 (LB1)	Madera	16/01/1996	06/05/2016	5096

Tabla A2

Listado de series de commodities de futuros según categoría.

ID	Nombre Futuro	Nombre Corto	Categoría 1	Categoría 2	Categoría 3
1	ICE Brent Crude Oil Futures #1 (B1)	Brent	Hard	Energía	Energía Fossil
2	ICE Gasoil Futures #1 (G1)	Diesel	Hard	Energía	Energía Fossil
3	ICE UK Natural Gas Futures #1 (M1)	Gas_ICE	Hard	Energía	Energía Fossil
4	NYMEX Natural Gas Futures #1 (NG1)	Gas_NIMEX	Hard	Energía	Energía Fossil
5	NYMEX Heating Oil Futures #1 (HO1)	Gasoleo_calef	Hard	Energía	Energía Fossil
6	NYMEX WTI Crude Oil Futures #1 (CL1)	WTI	Hard	Energía	Energía Fossil
7	COMEX Copper Futures #1 (HG1)	Cobre	Hard	Metales	Metales Base
8	NYMEX Gold Futures #1 (GC1)	Oro	Hard	Metales	Metales Preciosos
9	NYMEX Palladium Futures #1 (PA1)	Paladio	Hard	Metales	Metales Preciosos
10	NYMEX Silver Futures #1 (SI1)	Plata	Hard	Metales	Metales Preciosos
11	NYMEX Platinum Futures #1 (PL1)	Platino	Hard	Metales	Metales Preciosos
12	CBOT Rough Rice Futures #1 (RR1)	Arroz	Soft	Alimentos y comestibles	Granos
13	CBOT Oats Futures #1 (O1)	Avena	Soft	Alimentos y comestibles	Granos
14	CBOT Corn Futures #1 (C1)	Maiz	Soft	Alimentos y comestibles	Granos
15	CBOT Wheat Futures #1 (W1)	Trigo	Soft	Alimentos y comestibles	Granos
16	CBOT Soybean Oil Futures #1 (BO1)	Aceite_soja	Soft	Alimentos y comestibles	Semillas para gasóleo
17	CBOT Soybean Meal Futures #1 (SM1)	Harina_soja	Soft	Alimentos y comestibles	Semillas para gasóleo
18	CBOT Soybeans Futures #1 (S1)	Soja	Soft	Alimentos y comestibles	Semillas para gasóleo
19	ICE Sugar No. 11 Futures #1 (SB1)	Azucar	Soft	Alimentos y comestibles	Semi-refinados
20	ICE Coffee C Futures #1 (KC1)	Cafe	Soft	Alimentos y comestibles	Semi- refinados
21	ICE Cocoa Futures #1 (CC1)	Cocoa	Soft	Alimentos y comestibles	Semi- refinados
22	ICE Orange Juice Futures #1 (OJ1)	Jugo_naranja	Soft	Alimentos y comestibles	Semi- refinados
23	CME Lean Hogs Futures #1 (LN1)	Cerdos	Soft	Insumos Agropecuarios	Agro-animal
24	CME Live Cattle Futures #1 (LC1)	Ganado	Soft	Insumos Agropecuarios	Agro-animal
25	CME Class III Milk Futures #1 (DA1)	Leche	Soft	Insumos Agropecuarios	Agro-animal
26	ICE Cotton Futures #1 (CT1)	Algodon	Soft	Insumos Agropecuarios	Agro-industrial
27	CME Random Length Lumber Futures #1 (LB1)	Madera	Soft	Insumos Agropecuarios	Agro-industrial




Figura A1. Series de precios de futuros de commodities clasificados como *hard* o pesados. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A2. Series de precios de futuros de commodities clasificados como *soft* o *livianos*. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A3. Series de retornos de futuros de commodities clasificados como *hard* o pesados La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A4. Series de retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A5. Asimetría de los retornos de futuros de commodities clasificados como *hard* o pesados. La línea de color azul refleja asimetría negativa en la distribución de los datos (< 0), y la naranja asimetría positiva (> 0). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A6. Asimetría de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea de color azul refleja asimetría negativa en la distribución de los datos (< 0), y la naranja asimetría positiva (> 0). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A7. Curtosis de los retornos de futuros de commodities clasificados como *hard* o pesados. La línea de color violeta refleja una distribución leptocúrtica de los datos (> 3). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A8. Curtosis de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea de color violeta refleja una distribución leptocúrtica de los datos (> 3). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A9. Prueba Jarque-Bera de los retornos de futuros de commodities clasificados como *hard* o *pesados*. La línea verde refleja el valor p menor a 0.05, el cual rechaza la hipótesis nula de normalidad en los datos y la línea violeta lo contrario. Valores por encima de 0.125, fueron fijados en 0.125. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A10. Prueba Jarque-Bera de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea verde refleja el valor p menor a 0.05, el cual rechaza la hipótesis nula de normalidad en los datos y la línea violeta lo contrario. Valores por encima de 0.125, fueron fijados en 0.125. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A11. Selección automática del modelo ARIMA(p,d,q) de los retornos de futuros de commodities clasificados como *hard* o *pesados*. La línea azul refleja la escogencia del rezago p, la verde el número de diferencias, y la violeta el rezago q. Todos estos valores están configurados para alcanzar un máximo de 5. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A12. Selección automática del modelo ARIMA(p,d,q) de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea azul refleja la escogencia del rezago p, la verde el número de diferencias, y la violeta el rezago q. Todos estos valores están configurados para alcanzar un máximo de 5. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A13. Valores p de los parámetros estimados del modelo GARCH(1,1) de los retornos de futuros de commodities clasificados como *hard* o pesados. La línea azul hace referencia al valor p de la constante omega (ω), la violeta al parámetro alpha1 (α_1), y la verde al parámetro (β_1). Valores por encima de 0.125, fueron fijados en 0.125. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A14. Valores p de los parámetros estimados del modelo GARCH(1,1) de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea azul hace referencia al valor p de la constante omega (ω), la violeta al parámetro alpha1 (α_1), y la verde al parámetro (β_1). Valores por encima de 0.125, fueron fijados en 0.125. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A15. Ajuste de los umbrales estimados por el modelo GNG de los retornos de futuros de commodities clasificados como *hard* o pesados. La línea azul representa al umbral de la cola izquierda (u_l), y la violeta al de la cola derecha (u_r). Los valores del umbral izquierdo fueron invertidos para una mejor visualización ($-u_l$). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A16. Ajuste de los umbrales estimados por el modelo GNG de los retornos de futuros de commodities clasificados como *soft* o *livianos*. La línea azul representa al umbral de la cola izquierda (u_l), y la violeta al de la cola derecha (u_r). Los valores del umbral izquierdo fueron invertidos para una mejor visualización ($-u_l$). La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A17. Relación asimétrica entre el riesgo de los extremos de la distribución de los retornos de commodities clasificados como *hard* o pesados. La línea violeta representa el VaR de la cola izquierda, y la línea azul representa el VaR de la cola derecha. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.




Figura A18. Relación asimétrica entre el riesgo de los extremos de la distribución de los retornos de commodities clasificados como *soft* o *livianos*. La línea violeta representa el VaR de la cola izquierda, y la línea azul representa el VaR de la cola derecha. La línea vertical punteada representa la quiebra de Lehman Brothers el 15 de septiembre de 2008, simbolizando el estallido de la crisis financiera de 2008. Fuente: Elaboración Propia.

Tabla A3

Rezagos n del VAR y pruebas ADF de las series VaR de los commodities clasificados según la categoría 3.

Commodities	Muestra total			Pre-crisis			Post-crisis			Intermedio		
	VAR (n)	ADF VaR.l	ADF VaR.r	VAR (n)	ADF VaR.l	ADF VaR.r	VAR (n)	ADF VaR.l	ADF VaR.r	VAR (n)	ADF VaR.l	ADF VaR.r
		Valor p	Valor p		Valor p	Valor p		Valor p	Valor p		Valor p	
<i>Energía Fósil</i>												
Brent	13	0,01	0,01	20	0,01	0,01	12	0,01	0,01	13	0,01	0,01
Diesel	19	0,01	0,01	3	0,01	0,01	19	0,01	0,01	9	0,01	0,01
Gas_ICE	18	0,01	0,01	6	0,01	0,01	3	0,01	0,01	16	0,01	0,01
Gas_NIMEX	5	0,01	0,01	5	0,01	0,01	4	0,01	0,01	5	0,01	0,01
Gasoleo_cale	10	0,01	0,01	4	0,01	0,01	9	0,01	0,01	4	0,01	0,01
WTI	11	0,01	0,01	15	0,01	0,01	12	0,01	0,01	18	0,01	0,01
<i>Metales Base</i>												
Cobre	9	0,01	0,01	9	0,01	0,01	3	0,01	0,01	9	0,01	0,01
<i>Metales Preciosos</i>												
Oro	9	0,01	0,01	9	0,01	0,01	7	0,01	0,01	16	0,01	0,01
Paladio	12	0,01	0,01	7	0,01	0,01	3	0,01	0,01	6	0,01	0,01
Plata	13	0,01	0,01	7	0,01	0,01	11	0,01	0,01	12	0,01	0,01
Platino	12	0,01	0,01	5	0,01	0,01	10	0,01	0,01	10	0,01	0,01
<i>Granos</i>												
Arroz	12	0,01	0,01	5	0,01	0,01	5	0,01	0,01	6	0,01	0,01
Avena	10	0,01	0,01	10	0,01	0,01	5	0,01	0,01	10	0,01	0,01
Maíz	8	0,01	0,01	4	0,01	0,01	4	0,01	0,01	9	0,01	0,01
Trigo	5	0,01	0,01	4	0,01	0,01	5	0,01	0,01	5	0,01	0,01
<i>Semillas para crear gasóleo</i>												
Aceite_soja	7	0,01	0,01	4	0,01	0,01	7	0,01	0,01	7	0,01	0,01
Harina_soja	7	0,01	0,01	7	0,01	0,01	6	0,01	0,01	7	0,01	0,01
Soja	7	0,01	0,01	3	0,01	0,01	10	0,01	0,01	8	0,01	0,01
<i>Semi-refinados</i>												
Azúcar	9	0,01	0,01	5	0,01	0,01	5	0,01	0,01	5	0,01	0,01
Café	11	0,01	0,01	10	0,01	0,01	3	0,01	0,01	4	0,01	0,01
Cocoa	4	0,01	0,01	4	0,01	0,01	4	0,01	0,01	5	0,01	0,01
Jugo_naranja	17	0,01	0,01	3	0,01	0,01	5	0,01	0,01	6	0,01	0,01
<i>Agro-animal</i>												
Cerdos	7	0,01	0,01	3	0,01	0,01	2	0,01	0,01	20	0,01	0,01
Ganado	13	0,01	0,01	14	0,01	0,01	5	0,01	0,01	3	0,01	0,01
Leche	12	0,01	0,01	6	0,01	0,01	20	0,01	0,01	12	0,01	0,01
<i>Agro-industrial</i>												
Algodón	8	0,01	0,01	5	0,01	0,01	8	0,01	0,01	6	0,01	0,01
Madera	17	0,01	0,01	4	0,01	0,01	7	0,01	0,01	17	0,01	0,01

Nota: El periodo de muestra total se extiende del 03/01/2000 al 06/05/2016; el de pre-crisis de 03/01/2000 al 14/09/2008; el de post-crisis de 15/09/2008 al 06/05/2016; y el de intermedio de 01/01/2004-31/12/2012. n representa el valor del rezago seleccionado automáticamente según el criterio AIC para estimar el VAR. Este valor tiene un máximo establecido de 20. La prueba ADF utiliza como hipótesis nula la no estacionariedad de las series, cuyo valor p es el representado en la tabla.

Tabla A4

Composición del Índice S&P GCSI de los commodities clasificados según la categoría 3.

Commodities	2007	2008	2016
	% en Dólares	% en Dólares	% en Dólares
<i>Energía Fósil</i>			
Brent	14,98	N/A	20,43
Diesel	5,27	N/A	5,82
Gas_ICE	-	-	-
Gas_NIMEX	9,89	7,6	3,24
Gasoleo_calef	6,09	5,3	5,21
WTI	36,86	40,6	23,04
<i>Metales Base</i>			
Cobre	3,41	2,6	3,85
<i>Metales Preciosos</i>			
Oro	1,84	1,5	3,24
Paladio	-	-	-
Plata	0,23	0,2	0,41
Platino	-	-	-
<i>Granos</i>			
Arroz	-	-	-
Avena	-	-	-
Maíz	2,12	3,6	4,23
Trigo	2,21	3	3,53
<i>Semillas para crear gasóleo</i>			
Aceite_soja	-	-	-
Harina_soja	-	-	-
Soja	1,44	0,9	2,95
<i>Semi-refinados</i>			
Azúcar	1,77	2,7	1,59
Café	0,65	0,5	0,94
Cocoa	0,18	0,2	0,45
Jugo_naranja			
<i>Agro-animal</i>			
Cerdos	1,49	0,8	2,30
Ganado	2,61	1,6	4,79
Leche	-	-	-
<i>Agro-industrial</i>			
Algodón	0,87	0,7	1,19
Madera	-	-	-

Nota: La fuente del año 2007 es Labuszewski (2006), la del año 2008 es Tang & Xiong (2012) y la del año 2016 proviene directamente del S&P Global (2016). “N/A” significa que no hay información disponible para ese bien y “-” que la mercancía no es tomada en cuenta en el índice. Otros bienes que conforman este índice, pero que no fueron utilizados en este trabajo son: Trigo de Kansas, Ganado de Engorde, Gasolina RBOB, Aluminio, Plomo, Níquel y Zinc.

Tabla A5

Prueba de *causalidad prima facie* a la Granger Robusta para todos los commodities clasificados según la categoría 3.

Commodities	Muestra total		Pre-crisis		Post-crisis		Intermedio	
	VaR.l ≠ VaR.r	VaR.r ≠ VaR.l	VaR.l ≠ VaR.r	VaR.r ≠ VaR.l	VaR.l ≠ VaR.r	VaR.r ≠ VaR.l	VaR.l ≠ VaR.r	VaR.r ≠ VaR.l
	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p	Valor p
<i>Energía Fósil</i>								
Brent	0,00	0,03	0,01	0,40	0,00	0,02	0,00	0,06
Diesel	0,00	0,06	0,17	0,13	0,00	0,31	0,03	0,08
Gas_ICE	0,02	0,01	0,26	0,09	0,06	0,10	0,00	0,04
Gas_NIMEX	0,01	0,00	0,04	0,00	0,06	0,01	0,38	0,03
Gasoleo_calef	0,00	0,22	0,18	0,20	0,00	0,23	0,05	0,72
WTI	0,00	0,38	0,01	0,17	0,00	0,47	0,00	0,42
<i>Metales Base</i>								
Cobre	0,00	0,00	0,02	0,00	0,10	0,15	0,01	0,01
<i>Metales Preciosos</i>								
Oro	0,00	0,00	0,47	0,21	0,02	0,04	0,03	0,00
Paladio	0,01	0,00	0,55	0,00	0,10	0,09	0,00	0,00
Plata	0,00	0,00	0,02	0,00	0,02	0,02	0,00	0,00
Platino	0,00	0,00	0,09	0,01	0,05	0,01	0,01	0,00
<i>Granos</i>								
Arroz	0,17	0,00	0,35	0,02	0,29	0,08	0,46	0,02
Avena	0,03	0,00	0,02	0,00	0,39	0,00	0,12	0,01
Maíz	0,02	0,26	0,64	0,45	0,13	0,75	0,01	0,33
Trigo	0,03	0,01	0,46	0,00	0,02	0,61	0,15	0,04
<i>Semillas para crear gasóleo</i>								
Aceite_soja	0,00	0,21	0,07	0,87	0,01	0,40	0,02	0,43
Harina_soja	0,01	0,21	0,01	0,41	0,16	0,05	0,03	0,70
Soja	0,00	0,00	0,65	0,28	0,03	0,00	0,03	0,01
<i>Semi-refinados</i>								
Azúcar	0,31	0,00	0,54	0,03	0,92	0,02	0,67	0,01
Café	0,26	0,01	0,18	0,00	0,45	0,81	0,15	0,04
Cocoa	0,35	0,07	0,14	0,22	0,05	0,42	0,56	0,02
Jugo_naranja	0,00	0,00	0,83	0,39	0,16	0,12	0,61	0,05
<i>Agro-animal</i>								
Cerdos	0,06	0,13	0,67	0,34	0,53	0,27	0,03	0,24
Ganado	0,24	0,34	0,25	0,57	0,38	0,01	0,95	0,52
Leche	0,05	0,08	0,17	0,02	0,18	0,19	0,09	0,25
<i>Agro-industrial</i>								
Algodón	0,00	0,01	0,84	0,16	0,00	0,01	0,19	0,00
Madera	0,01	0,23	0,59	0,06	0,02	0,23	0,08	0,10

Nota: El periodo de muestra total se extiende del 03/01/2000 al 06/05/2016; el de pre-crisis de 03/01/2000 al 14/09/2008; el de post-crisis de 15/09/2008 al 06/05/2016; y el de intermedio de 01/01/2004-31/12/2012. VaR.l ≠ VaR.r represen la hipótesis nula de no causalidad del VaR.l al VaR.r y VaR.r ≠ VaR.l representa lo contrario. Los valores sombreados representan causalidad en ambas direcciones y en negrita causalidad en una dirección. Valores en cursiva significan rechazo al 10%.