



Asociación
Cuadernos
de economía

Cuadernos de economía

www.cude.es



ARTÍCULO

Predicción de la volatilidad en los mercados del petróleo mexicano a través de modelos CGARCH asimétricos bajo dos supuestos distribucionales

Raúl de Jesús Gutiérrez^a y Miriam Sosa Castro^b

^a Profesor de tiempo completo de la Facultad de Economía, UAEMEX. Universidad Autónoma del Estado de México

^b Profesora de Tiempo Completo de la Universidad Autónoma Metropolitana, Iztapalapa. México

JEL CODES

Q40; E30; C32; C52

KEYWORDS:

Crude oil; Volatility forecasting; CGARCH models; Superior predictive ability test

Abstract: In this paper, three symmetric and asymmetric CGARCH models are estimated to evaluate and improve volatility forecasts in Mexican crude oil markets under different distributional assumptions (Normal and Laplace). Empirical evidence shows that CGARCH and CGARCH-A2 models yield the most accurate one-five-and twenty-day out-of-sample volatility forecasts for Istmo and Maya crude oil returns in comparison to the traditional GARCH models, including the CGARCH-A1 based model. These results are supported using symmetric and asymmetric forecast error measures and the Hansen's (2005) superior predictive ability test. The improvement in volatility forecasting has important economics and financial implications for participants in Mexican crude oil markets, in particular the Mexican government.

CÓDIGOS JEL

Q40; E30; C32; C52

PALABRAS CLAVE:

Petróleo crudo; Predicción de la volatilidad; Modelos CGARCH; Prueba estadística de poder predictivo superior

Resumen: En este trabajo se estiman modelos CGARCH simétricos y asimétricos para evaluar y mejorar las predicciones de la volatilidad en los mercados del petróleo mexicano bajo diferentes supuestos distribucionales (Normal y Laplace). La evidencia empírica demuestra que los modelos CGARCH y CGARCH-A2 proporcionan las mejores predicciones de la volatilidad fuera de la muestra en los horizontes de 1, 5 y 20 días para los rendimientos del petróleo Istmo y Maya en comparación con los modelos GARCH convencionales, incluso que el modelo CGARCH-A1. Los resultados son sustentados por el uso de medidas de errores de predicción simétricas-asimétricas y la prueba estadística de poder predictivo superior de Hansen (2005). El mejoramiento de la predicción de la volatilidad tiene importantes implicaciones económicas-financieras para los participantes en los mercados del petróleo mexicano, en particular para el gobierno.

^b Autor de correspondencia. Correo electrónico: msosac87@hotmail.com

1. Introducción

La estructura del mercado del petróleo global se ha caracterizado por ser más volátil y riesgosa en comparación a la de otras materias primas, incluso con respecto a algunos índices bursátiles y divisas duras (Kroner et al., 1995; Hassan y Zaman, 2012). La intensificación de los vaivenes en los precios del petróleo a nivel global se debe a diversos factores, no solo económicos-financieros, sociopolíticos, geopolíticos y tecnológicos, sino también a eventos de carácter climático, capacidad de refinería y acuerdos institucionales internacionales para modificar la producción global. La persistencia en la volatilidad del petróleo ha generado inestabilidad económica para los países importadores y exportadores, así como incertidumbre en los mercados financieros. Igualmente, cabe mencionar que, el comportamiento dinámico de la volatilidad en los precios del petróleo es el principal componente en la valuación de productos derivados energéticos, diseño de estrategias de cobertura óptima, diversificación del riesgo de las inversiones de portafolio y administración de riesgos.

En años recientes, la modelación y predicción de la volatilidad se ha convertido en uno de los tópicos de mayor preocupación y prioridad para los participantes en los mercados de energía y académicos. Numerosos estudios han analizado la dinámica de la volatilidad condicional a través de estructuras ARCH y GARCH bajo el supuesto de innovaciones normales en los principales marcadores de referencia internacional del petróleo (Sadorsky, 2006; Narayan y Narayan, 2007; Kang et al., 2009; Wei et al., 2010; Xu y Ouenniche, 2012). Sin embargo, la forma distribucional de los rendimientos del petróleo es más picuda alrededor de la media y de colas más anchas como consecuencia del exceso de curtosis. La omisión del fenómeno de la leptocurtosis tiene importantes implicaciones teóricas y prácticas en la estimación y predicción de la volatilidad condicional. En consecuencia, la literatura sugiere el uso de distribuciones de colas anchas en la estructura GARCH. Entre las alternativas más comunes, distribuciones de error generalizado, *t*-Student simétrica y sesgada se han empleado para explicar las características no-normales de las innovaciones en los precios del petróleo.

Entre los trabajos que han extendido los modelos GARCH bajo diferentes supuestos distribucionales se puede citar a Agnolucci (2009), el cual compara la capacidad predictiva de los modelos GARCH y volatilidad implícita, evidenciando que los modelos GARCH con distribución de error generalizado proporcionan el mejor desempeño para modelar y predecir la volatilidad de los futuros sobre el petróleo WTI. Por otro lado, Cheong (2009) analiza la volatilidad dinámica del petróleo WTI y del Brent europeo utilizando los modelos ARCH -GARCH, EGARCH, APARCH y FIGARCH- para verificar la capacidad productiva de cada uno de ellos. Los resultados de la predicción fuera de la muestra evidencian que el modelo generalizado ARCH, el más simple y parsimonioso, es aquel que provee la mejor predicción para el petróleo Brent. Mohammadi y Su (2010) comparan el desempeño de 4 clases de modelos GARCH basados en la distribución de innovaciones *t*-Student sesgada. Los resultados de la evaluación muestran que los modelos EGARCH y APARCH son más apropiados para predecir la media y volatilidad condicional fuera de la muestra, a diferencia de los modelos GARCH estándar y FIGARCH.

Por su parte, Marzo y Zagaglia (2010) estimaron tres modelos de volatilidad con diferentes supuestos distribucionales para las innovaciones de los rendimientos de los futuros sobre petróleo listados en la Bolsa Mercantil de Nueva York. Los resultados del análisis fuera de la muestra sustentan que el modelo GARCH con distribución de error generalizado alcanza excelentes predicciones para los horizontes de 1 y 3 días, mientras que para horizontes de 5 y 15 días no existe modelo superior o inferior a los demás. En un trabajo más reciente, que no requiere del conocimiento inicial de la distribución para describir las innovaciones en los rendimientos del petróleo WTI y Brent, Hou y Suardi (2012) proponen un modelo GARCH no-paramétrico que mejora notablemente la capacidad predictiva fuera de la muestra, con respecto a una extensa clase de modelos GARCH con innovaciones *t*-Student, a pesar de que no especifican la característica de asimetría en el proceso de volatilidad.

La asimetría de las series financieras es una característica que, de no ser propiamente modelada, sesga la estimación y predicción de la volatilidad condicional de los rendimientos del petróleo. La asimetría hace referencia a los efectos asimétricos generados por choques positivos y negativos de la misma magnitud, también conocido en la literatura como el fenómeno del efecto de apalancamiento. El tópico de la asimetría en la volatilidad fue discutido por primera vez en el trabajo de Black (1976), quien demostró que el anuncio de malas noticias incrementa el nivel de la volatilidad, mientras que las buenas noticias la reduce. Desde entonces varios modelos de volatilidad asimétrica se han desarrollado para recoger el impacto de la información reciente en el mercado. Entre ellos se puede mencionar el modelo GARCH exponencial (EGARCH) desarrollado por Nelson (1991). Otra alternativa comúnmente utilizada para tratar los efectos de asimetría en la predicción de la volatilidad, es el modelo GARCH-GJR propuesto por Glosten et al. (1993). Sin embargo, esta familia de modelos GARCH asimétricos no tiene la capacidad para capturar los efectos asimétricos de largo plazo.

El objetivo de esta investigación es contribuir a la escasa literatura sobre predicción de la volatilidad del petróleo de baja calidad, estimando modelos CGARCH simétrico y asimétricos bajo dos distribuciones condicionales: Normal y Laplace, para mejorar la predicción de la volatilidad de los rendimientos de los precios de los petróleos Istmo y Maya en el periodo del 2 de enero de 2000 al 31 de diciembre de 2016.

El presente trabajo se diferencia del grueso de la literatura existente de la siguiente manera. En primer lugar, se identifican las características empíricas comunes de la volatilidad de los rendimientos del petróleo, introduciendo una descomposición en su estructura para distinguir los efectos en los componentes de corto y largo plazos a través de modelos CGARCH simétricos y asimétricos, adoptando dos diferentes distribuciones condicionales para las innovaciones: normal y de Laplace. Esta última distribución no se ha aplicado para el modelado de los rendimientos del petróleo de referencia internacional y crudos de baja calidad y alto contenido de azufre. Además, la distribución de Laplace¹ o

¹ En la literatura sobre finanzas, la distribución de Laplace ha sido utilizada en la modelación del comportamiento asintótico de las colas de la distribución de rendimientos para los índices accionarios S&P500, Nikkei 225 y S&P/TSX (Granger y Ding, 1995; Mitnik et al., 1998; Baker et al., 2008).

doble exponencial tiene propiedades de colas más anchas que la normal, a pesar de carecer de un parámetro de forma específico o grados de libertad como en el caso de las distribuciones *t*-Student y de error generalizado.² En segundo lugar, el desempeño predictivo fuera de la muestra de los modelos CGARCH simétrico y asimétrico bajo los diferentes supuestos distribucionales, se compara a una familia de modelos de volatilidad (GARCH, EGARCH, GARCH-GJR y APARCH), empleando medidas de errores simétricas y asimétricas. Asimismo, la validación de la significancia estadística de la predicción óptima del modelo *benchmark* se lleva a cabo mediante la prueba estadística de poder predictivo superior de Hansen (2005), utilizando el periodo del 2 de enero de 2011 al 31 de diciembre de 2016.

Esta investigación se estructura de la siguiente forma. Sección 2 presenta un análisis preliminar de los datos usados. Sección 3 discute el modelo CGARCH y su extensión para capturar los efectos asimétricos de largo plazo en la volatilidad, así como las medidas de errores simétricas y asimétricas y la prueba estadística de poder predictivo superior de Hansen (2005). Sección 4 proporciona una discusión de los hallazgos empíricos. Sección 5 proporciona las principales conclusiones.

2. Análisis preliminar de los datos

2.1 Descripción de los datos


El precio del petróleo mexicano depende en gran medida de sus características físicas y químicas; es decir, densidad y contenido de azufre³ determinado por el parámetro internacional del Instituto Americano del Petróleo (API, por sus siglas en inglés). La producción de petróleo está compuesta por una canasta de crudos entre ellos se encuentra el Maya con densidad de 22 grados API y contenido de azufre de 3.3% y el Istmo con 33.6 grados API y 1.3% de azufre. Estos dos conjuntos de datos se utilizan para el análisis de la predicción de la volatilidad en el periodo del 3 de enero de 2000 al 30 de diciembre de 2016, totalizando 4372 observaciones. Las series se obtuvieron de la base de datos de Bloomberg y la selección de la muestra fue de acuerdo con la disponibilidad de los datos.

La dinámica de los precios del petróleo nacional es ilustrada en la Figura 1. Durante el periodo 2000-2016, los precios de contado oscilaron en un rango amplio entre \$13.89 y \$142.63 para el Istmo y \$10.98-\$130.46 dólares por barril para el Maya. Aunque existen diferencias notables en la densidad y contenido de azufre en ambos tipos de petróleo, el comportamiento de los precios exhibe la misma tendencia a través del tiempo. De hecho, la naturaleza de los choques positivos y negativos en los precios de los crudos nacionales también ha sido estimulada por acontecimientos de carácter geopolítico o económico como en los merca-

dos del petróleo de referencia internacional. A partir de 2000, el petróleo Maya e Istmo iniciaron un ascenso de precios hasta alcanzar los \$27.82 y \$34.53 dólares por barril, como consecuencia de cambios estructurales de la reducción de 4.2 millones de barriles diarios entre 2000-2001 en la producción de los principales países miembros de la Organización de Países Exportadores de Petróleo (OPEP). Dicha tendencia únicamente se vio interrumpida durante el año 2001, especialmente después del atentado del 11 de septiembre contra las Torres Gemelas del *World Trade Center* cuando alcanzaron precios por debajo de los \$11.00 y \$14.00 dólares por barril, respectivamente.

Desde el conflicto militar entre Estados Unidos e Irak en 2003, los precios de los crudos Maya e Istmo han tenido un repunte importante, al grado que en julio de 2008 se registraron precios históricos de \$130.46 y \$142.63 dólares por barril, respectivamente. No obstante, este periodo de tendencia alcista en los precios del petróleo se vio interrumpido por el desplome espectacular a fines de diciembre de 2008, cuando los precios descendieron a sus niveles más bajos de \$25.34 (Maya) y \$32.10 (Istmo), precisamente cuando la economía global entró en un periodo de profunda recesión por la restricción del crédito. Pero una vez absorbido el efecto negativo de la recesión durante el 2009, otra escalada alcista de largo plazo en el petróleo Maya e Istmo se presentó en el periodo 2010-2012 cuando alcanzaron sus niveles más altos de \$117.78 y \$122.15 dólares por barril en el primer trimestre de 2012. Entre los factores importantes que explican esta alza en los energéticos, principalmente podemos mencionar los datos positivos en el mercado laboral de Estados Unidos y manufacturero en China, así como la reducción de las tasas de interés en algunos países europeos. Sin pasar por alto, los problemas en la oferta del hidrocarburo relacionados con el programa nuclear de Irán y los recortes en los niveles de producción de aproximadamente un millón de barriles diarios por parte de Siria, Sudán y Yemen.

Figura 1. Comportamiento de los precios del petróleo Maya e Istmo



En el año 2012, la reducción en la demanda por la desaceleración económica global y los problemas financieros de Europa revirtieron la tendencia alcista en ambos crudos nacionales a fines de junio, lo que implicó un descenso del

² La distribución de Laplace es un caso particular de la distribución hiperbólica cuando la curtosis alcanza un valor igual a 6. Para más detalles técnicos, véase Bibby y Sorensen (2003).

³ El grado de densidad se puede clasificar de extra ligero a pesado, mientras que el contenido de azufre se caracteriza como dulce o ácido. En este sentido, los petróleos crudos con alta densidad y bajo contenido de azufre son cotizados en los mercados internacionales a precios más altos que los pesados y corrosivos.


28% en promedio con respecto a los niveles máximos de 2012. En el periodo 2013-2014, otra vez los altos precios del Maya e Istmo comienzan a oscilar entre \$84.70-\$108.54 y \$92.80-\$115.56 dólares por barril, debido al avance de las tropas del Estado Islámico en Irak. Después de este importante repunte, los precios del petróleo nuevamente inician un episodio bajista al alcanzar los niveles de \$37.54 y \$43.05 dólares por barril en enero de 2015, lo que conlleva a una depreciación semestral del petróleo en una magnitud del 61.54% y 59.07%. Este hecho es principalmente alentado por las frecuentes interrupciones del suministro y el control de la producción ejercido por la OPEP. Durante el segundo trimestre de 2015, una tendencia al alza es registrada de nueva cuenta, pero rápidamente es corregida en julio, lo que obliga a mantener los precios internacionales persistentemente a la baja con una caída del petróleo Maya e Istmo de aproximadamente 65.81% y 60.80% durante junio de 2015, seguido por un ascenso en los precios del petróleo para cerrar el 2016 en \$47.75 y \$55.64 dólares por barril, respectivamente. Entre los factores que alimentan esta recuperación en los precios del petróleo, se destaca la decisión de reducir los inventarios mundiales de petróleo debido al ajuste en los recortes de la producción en aproximadamente 1.2 millones de barriles diarios por parte de los miembros de la OPEP.

2.2 Estadísticas descriptivas

Un hecho innegable es que los precios del petróleo se caracterizan por ser series no estacionarias así que, para el análisis empírico es importante transformar los precios a series estacionarias, calculando los rendimientos continuos a través de los cambios logarítmicos de los precios de cierre de dos días consecutivos de operación; es decir, $r_t = 100 \ln(P_t / P_{t-1})$. Las estadísticas básicas de los rendimientos para los dos tipos de petróleo son reportadas en la Tabla 1. Los rendimientos promedios y desviaciones estándar son muy similares y positivos en ambas series. Este hecho indica una relación rendimiento-riesgo positiva y una mayor exposición al riesgo para los participantes en los mercados del petróleo. Además, las series de los rendimientos son negativamente sesgadas y exhiben exceso de curtosis para el periodo de análisis, esto es, propiedades de colas más anchas y largas que la distribución normal, particularmente la cola izquierda. El valor negativo del coeficiente sesgo revela que los rendimientos extremos negativos tienen mayor probabilidad de ocurrir que los rendimientos extremos positivos. El rechazo del supuesto de normalidad es confirmado por el valor- p del estadístico Jarque-Bera.

Los resultados de la prueba de Ljung-Box, $Q^2(20)$ confirman la fuerte presencia de heterocedasticidad condicional en los rendimientos cuadrados del petróleo Maya e Istmo, lo que implica la necesidad de la estimación de un modelo GARCH para su modelación apropiada. Este fenómeno es mejor ilustrado en la Figura 2, que muestra la dinámica de los rendimientos para ambos tipos de petróleo a través del tiempo, caracterizada por volatilidad en aglomeraciones; es decir, periodos de alta volatilidad seguido de periodos de relativa tranquilidad. Además, cabe resaltar que la intensidad del fenómeno de la heterocedasticidad condicional es más pronunciada en los periodos después del estallido de la burbuja financiera del Índice NASDAQ en marzo de 2000 y el atentado terrorista del 11 de septiembre a las Torres Gemelas en 2001, la recesión económica de los Estados Unidos en 2008-2009, la crisis de deuda soberana de la zona euro en 2010-2012 y en 2015-2016, en donde los rendimientos el petróleo Maya e Istmo experimentaron una sucesión de movimientos atípicos positivos y negativos en cortos intervalos de tiempo.

Figura 2. Dinámica de los rendimientos de los precios del petróleo Maya e Istmo



En consecuencia, el análisis preliminar de los datos sugiere el uso de procesos CGARCH asimétricos y la incorporación de distribuciones de colas pesadas en la modelación y predicción de la volatilidad condicional en las innovaciones de los rendimientos del petróleo mexicano.

Tabla 1. Estadísticas básicas de los rendimientos del petróleo Maya e Istmo

Petróleo	Media	Máximo	Mínimo	Desv. Est	Sesgo	Curtosis	JB	Q2(20)
Maya	0,0439	17,8751	-22,0272	2,7630	-0,1033	8,6315	5491(0)	1694(0)
Istmo	0,0427	16,8384	-22,4620	2,6692	-0,3114	8,4813	5263(0)	1193(0)

Nota: Las estadísticas básicas son expresadas en porcentajes para el periodo del 2 de enero de 2000 al 31 de diciembre de 2016.

Desv.Est. representa la desviación estándar de los rendimientos. *JB* es el valor del estadístico Jarque-Bera de la prueba de normalidad y $Q^2(20)$ indica el valor de la prueba estadística de Ljung-Box con valores- p entre paréntesis.

3. Metodología Econométrica

3.1 Modelo GARCH de dos componentes

En la literatura es reconocido que la volatilidad de largo plazo no puede ser recogida por los modelos GARCH tradicionales, por lo que en la modelación se debe descomponer la volatilidad en dos componentes para describir el comportamiento de la persistencia en el corto y largo plazos.

Una especificación alternativa que puede capturar la volatilidad de corto y largo plazos en la serie de los rendimientos del petróleo es el modelo CGARCH propuesto por Engle y Lee (1999). Esta aproximación descompone la volatilidad condicional en dos componentes, lo que permite analizar apropiadamente el comportamiento de decaimiento de la persistencia en la volatilidad en el corto y largo plazos (Christoffersen et al., 2006). El primer componente captura el impacto de las innovaciones en el corto plazo alimentado por los diversos eventos exógenos relacionados a aspectos económicos, geopolíticos e incluso de carácter especulativo, que fluctúa en forma cíclica. El segundo componente recoge el impacto de largo plazo de las innovaciones esperadas.

La especificación CGARCH (1,1) se puede expresar de la siguiente forma:

$$r_t = \mu_t + \varphi r_{t-1} + \varepsilon_t = \mu_t + \varphi r_{t-1} + \sqrt{h_t} z_t \quad (1)$$

$$h_t = q_t + \alpha (\varepsilon_{t-1}^2 - q_{t-1}) + \beta (h_{t-1} - q_{t-1}) \quad (2)$$

$$q_t = \omega + \rho (\mu_{t-1}^2 - h_{t-1}) + \phi (q_{t-1} - \omega) \quad (3)$$

donde μ_t representa la media condicional, ε_t indica las innovaciones en la ecuación de la media, el componente q_t captura el nivel de la volatilidad en el largo plazo (tendencia), mismo que converge más lentamente al nivel de la volatilidad incondicional ω a una velocidad de $(\alpha + \beta) < \phi < 1$. El error de predicción rezagado $(\varepsilon_{t-1}^2 - h_{t-1})$ funciona como impulsor dinámico para capturar el movimiento del componente de largo plazo dependiente del tiempo, mientras que la diferencia entre la varianza condicional y su volatilidad de largo plazo previa $(h_{t-1} - q_{t-1})$ indica el componente de corto plazo de la varianza condicional, el cual converge a cero a una velocidad $(\alpha + \beta)$. De esta manera, la volatilidad condicional de largo plazo controla las predicciones de la varianza condicional a medida que el horizonte de predicción se incrementa.

El modelo CGARCH es una alternativa apropiada para recoger los efectos de corto y largo de la persistencia en la volatilidad condicional. Sin embargo, su potencial se reduce ante la presencia de efectos asimétricos, puesto que choques negativos (noticias malas) tendrán un impacto diferente, no sólo en la volatilidad de corto plazo, sino también en la volatilidad de largo plazo que choques positivos (noticias buenas) de la misma magnitud.

3.2 Modelo CGARCH-A1

La flexibilidad del modelo CGARCH permite capturar los efectos asimétricos en el corto y largo plazos, con sólo agregar parámetros de asimetría a su estructura econométrica. La estructura asimétrica o modelo CGARCH-A1 se define de la siguiente manera:

$$h_t = q_t + \alpha (\varepsilon_{t-1}^2 - q_{t-1}) + \gamma (I(\varepsilon_{t-1} < 0) \varepsilon_{t-1}^2 - q_{t-1}) + \beta (h_{t-1} - q_{t-1}) \quad (4)$$

$$q_t = \omega + \rho (\mu_{t-1}^2 - h_{t-1}) + \psi (I(\varepsilon_{t-1} < 0) \mu_{t-1}^2 - h_{t-1}) + \phi (q_{t-1} - \omega) \quad (5)$$

donde la variable dummy está gobernada por la función indicadora de Heaviside $I(\bullet)$, la cual es igual a 1 si $\varepsilon_{t-1} < 0$ y cero en otro caso. El efecto de asimetría es observado si $\gamma > 0$ y $\psi > 0$, lo que indica mayor impacto de las malas noticias con valores $(\alpha + \gamma)$ y $(\rho + \psi)$ sobre ε_{t-1}^2 en el corto y largo plazos, mientras que el efecto de las noticias buenas es medido por α y ρ .

3.3 Modelo CGARCH-A2

La segunda alternativa o modelo CGARCH-A2 captura los efectos asimétricos en el corto y largo plazos de la siguiente manera:

$$h_t = q_t + \alpha (|\varepsilon_{t-1}| - q_{t-1}) + \gamma (\varepsilon_{t-1} - q_{t-1}) + \beta (h_{t-1} - q_{t-1}) \quad (6)$$

$$q_t = \omega + \rho (|\mu_{t-1}| - h_{t-1}) + \psi (\mu_{t-1} - h_{t-1}) + \phi (q_{t-1} - \omega) \quad (7)$$

donde los parámetros de asimetría γ y ψ son negativos a diferencia del modelo CGARCH-A1, lo que indica mayor impacto de las noticias malas en las volatilidades de corto y largo plazos que las noticias buenas de la misma magnitud. El efecto total en las volatilidades de corto y largo plazos está determinado por $(\alpha - \gamma)|\varepsilon_{t-1}|$ y $(\rho - \psi)|\varepsilon_{t-1}|$ si $\varepsilon_{t-1} < 0$ y $(\alpha + \gamma)|\varepsilon_{t-1}|$ y $(\rho + \psi)|\varepsilon_{t-1}|$ cuando $\varepsilon_{t-1} > 0$.

3.4 Evaluación del desempeño predictivo de los modelos CGARCH simétrico y asimétricos

En esta sección se describen las medidas de errores para la evaluación del desempeño predictivo de los modelos de volatilidad. En general, este proceso se lleva a cabo fuera de la muestra porque los participantes en los mercados de energía fósil se interesan más en la capacidad de reacción de los modelos cuando llega nueva información al mercado.

Las medidas de errores predictivos se clasifican en simétricas y asimétricas. Entre las medidas simétricas más comunes se encuentran el error cuadrático medio (MSE) y el error absoluto medio (MAE), las cuales son definidas de la siguiente forma:

$$\text{MSE} = T^{-1} \sum_{t=1}^T (h_t - \hat{h}_{k,t})^2 \quad (8)$$

$$\text{MAE} = T^{-1} \sum_{t=1}^T |h_t - \hat{h}_{k,t}| \quad (9)$$

donde T indica el número de predicciones, h_t es una variable proxy para la volatilidad no observable, que generalmente se obtiene de los rendimientos cuadrados y $\hat{h}_{k,t}$ es la volatilidad estimada generada por el modelo k en el día t , respectivamente.

Patton (2011) demostró que estas medidas minimizan el error predictivo, pero ninguna de ellas proporciona información adicional sobre la asimetría en los errores cuando los modelos subestiman o sobreestiman la volatilidad. La relajación de la asimetría en los errores puede tener consecuencias importantes para los participantes en los mercados de energía, así como para los compradores y vendedores de opciones.

De acuerdo con Brailsford y Faff (1996), las medidas de errores asimétricas asignan diferente peso a las predicciones subestimadas y sobreestimadas de la volatilidad de magnitud similar, y son definidas de la siguiente forma:

$$\text{MME}(U) = T^{-1} \left[\sum_{t=1}^O |h_t - \hat{h}_{k,t}| + \sum_{t=1}^U \sqrt{|h_t - \hat{h}_{k,t}|} \right] \quad (10)$$

$$\text{MME}(O) = T^{-1} \left[\sum_{t=1}^O \sqrt{|h_t - \hat{h}_{k,t}|} + \sum_{t=1}^U |h_t - \hat{h}_{k,t}| \right] \quad (11)$$

donde U y O representan las subestimaciones y sobreestimaciones, y su suma indica el número total de predicciones, T .

Por otra parte, uno de los inconvenientes de estas medidas es que, a diferencia de las pruebas de contraste de hipótesis, no proporcionan un análisis robusto estadísticamente del desempeño predictivo entre dos modelos estimados con el simple hecho de comparar sus errores predictivos. Para sobreponer esta limitante, el presente trabajo emplea la prueba de poder predictivo superior (PPS) de Hansen (2005). Esta prueba estadística permite evaluar el desempeño de dos o más modelos estimados a diferencia de las pruebas estadísticas de Diebold-Mariano (1995) y White (2000).

La prueba estadística PPS consiste en determinar el modelo base con el mejor desempeño predictivo. En el periodo t , el desempeño predictivo del modelo alternativo k con relación al modelo base se define como

$$d_{k,t} = L_{0,t} - L_{k,t}, \quad k = 1, \dots, m; \quad t = 1, \dots, n \quad (12)$$

donde $L_{0,t}$ es el error de predicción determinado por las ecuaciones (8), (9), (10) y (11) para el modelo base M_0 y $L_{k,t}$ es el error de predicción para cada modelo alternativo M_k .

Bajo el supuesto de que el vector $d_{k,t}$ es estrictamente estacionario, la hipótesis nula de interés, de que ninguno de los modelos alternativos tiene superior desempeño predictivo con relación al modelo base, puede plantearse como

$$H_0: \mu_{\max} \equiv \max_{k=1, \dots, m} \mu_k \leq 0 \quad (13)$$

Aquí, el uso del estimador $\mu_k \equiv E[d_{k,t}]$ permite reducir el impacto de los modelos con desempeño predictivo débil, pero al mismo tiempo controla el impacto de los modelos alternativos con $\mu_k = 0$ como documentó Hansen (2005).

$$\mu_k^c = \bar{d}_k 1_{\left\{ \sqrt{n} \bar{d}_k / \hat{\omega}_k \geq -\sqrt{2 \log \log n} \right\}}, \quad k = 1, \dots, m \quad (14)$$

donde $1_{\{\cdot\}}$ es una función indicadora. Además, un resultado inmediato del supuesto de estacionariedad es que la selección del umbral $\sqrt{2 \log \log n}$ garantiza la consistencia del estimador μ_k^c cuando n es muy grande, incluso para los modelos alternativos con $\mu_k = 0$.

El estadístico PPS de la hipótesis nula está definido por

$$T_n^{\text{PPS}} = \max \left\{ \left(\max_{k=1, \dots, m} \frac{\sqrt{n} \bar{d}_k}{\hat{\omega}_k} \right), 0 \right\} \quad (15)$$

donde $\hat{\omega}_k^2$ es un estimador consistente de $\omega_k^2 \equiv \lim_{n \rightarrow \infty} \text{Var}(\sqrt{n} \bar{d}_k)$ y $\bar{d}_k = n^{-1} \sum_{t=1}^n d_{k,t}$.

Para obtener el estimador consistente de ω_k^2 y el valor de la probabilidad del estadístico T_n^{PPS} , Hansen (2005) sugiere el uso del procedimiento *bootstrap* estacionario basado en Politis y Romano (1994) para generar muestras *bootstrap* $(d_{b,1}^*, \dots, d_{b,n}^*)$ con $b = 1, \dots, B$. Para encontrar la distribución del estadístico bajo la hipótesis nula, una replicación *bootstrap* con d -variables está definida por $Z_{k,b,t}^i = d_{k,b,t}^* - g_i(\bar{d}_k)$ para $i = l, c, u$, donde $g_l(\bar{d}_k) \equiv \max(\bar{d}_k, 0)$, $g_u(\bar{d}_k) \equiv \bar{d}_k$ y $g_c(\bar{d}_k) = \bar{d}_k 1_{\left\{ \sqrt{n} \bar{d}_k / \hat{\omega}_k \geq -\sqrt{2 \log \log n} \right\}}$. Para alcanzar resultados

confiables que no afecten a las muestras actuales, B debe ser muy grande.

Suponiendo que $E[Z_{k,b,t}^i | d_1, \dots, d_n] = \hat{\mu}_k^i \leq 0$ para $i = l, c, u$, la distribución del estadístico $T_{b,n}^{\text{PPS}}$ se puede aproximar mediante la distribución empírica de $T_{b,n}^{\text{PPS},i} = \max \left\{ \left(\max_{k=1, \dots, m} \sqrt{n} \bar{Z}_{k,b,t}^i / \hat{\omega}_k \right), 0 \right\}$ para cada una de las muestras *bootstrap* $b = 1, \dots, B$, y $\bar{Z}_{k,b,t}^i = n^{-1} \sum_{t=1}^n Z_{k,b,t}^i$. De esta

manera, el valor de la probabilidad *bootstrap* está definido por

$$\text{valor}_p^{\text{PPS},i} = B^{-1} \sum_{b=1}^B 1_{\{T_{b,n}^{\text{PPS},i} > T_n^{\text{PPS}}\}}, \quad i = l, c, u \quad (16)$$

La hipótesis nula se rechaza cuando las probabilidades alcanzan valores pequeños.

4. Evidencia empírica para petróleos de tipo Istmo y Maya

4.1 Estimación de los modelos de volatilidad dentro de la muestra

En esta sección se reportan los resultados de los parámetros estimados de la media condicional y varianza condicional de los modelos GARCH, EGARCH, GARCH-GJR, APARCH y CGARCH simétrico y asimétricos, y algunas pruebas de diagnóstico. En el proceso de estimación dentro de la muestra se utilizan los rendimientos diarios del petróleo Istmo y Maya del 3 de enero de 2000 al 31 de diciembre de 2016 y el método de cuasi-máxima verosimilitud que proporciona errores estándar más robustos.

Los resultados de los parámetros estimados de las siete estructuras GARCH y sus errores estándar son reportados en las Tablas 2 y 3. Al analizar los parámetros estimados de la media condicional de los rendimientos del petróleo Maya se puede observar que no se reporta el parámetro del término autorregresivo de orden 1 bajo innovaciones normales y de Laplace. Esto se atribuye a que la especificación simple es suficiente para eliminar la correlación serial en los residuales estandarizados simples. Además, durante el procedimiento de estimación se propusieron procesos autorregresivos del orden 1 hasta 4, y los resultados proporcionaron parámetros estimados negativos y estadísticamente no significativos. Por su parte, todos los estimadores, c son estadísticamente significativos al 1% y 5%, excepto para los modelos EGARCH y CGARCH-A2 con innovaciones normales. Asimismo, el coeficiente del proceso de la media condicional no es significativo estadísticamente para los rendimientos del Istmo en las especificaciones EGARCH, GJR y CGARCH-A2 basadas en la distribución normal. El parámetro estimado del término AR(1) es estadísticamente significativo en los niveles convencionales bajo innovaciones de Laplace, pero con valor negativo.

En cuanto a los parámetros del proceso de la varianza condicional, todos los modelos GARCH capturan exitosamente los patrones dinámicos de la volatilidad dinámica ampliamente documentado en la literatura, dado que la mayoría de los estimadores son positivos y estadísticamente significativos en los niveles convencionales, excepto para el parámetro ω de los modelos CGARCH simétrico y asimétricos con innovaciones de Laplace del petróleo Istmo y Maya. Por su parte, el valor de los coeficientes de persistencia $\alpha + \beta$ oscila entre 0.9451-0.9982 y 0.9560-0.9998 para los rendimientos del Istmo y Maya. Este hallazgo implica la presencia de un alto grado de persistencia en la volatilidad condicional en ambas series de rendimientos, aunque existen algunos casos como en los modelos CGARCH y CGARCH-A1 que reportan un grado de persistencia entre 0.7781-0.8100. Este hecho es sustentado por los parámetros estimados ϕ que confirman que el componente de la volatilidad de largo plazo es más persistente que el componente de corto plazo. Por ejemplo, 0.9486 contra 0.8047 y 0.9537 contra 0.7861 para los modelos CGARCH y CGARCH-A1 con innovaciones normales. En el caso de los rendimientos del Istmo, 0.9646 contra 0.7905 y 0.9649 contra 0.7893 en el mismo orden, pero con innovaciones de Laplace. En contraste, el modelo

CGARCH-A2 sustenta que el componente de la volatilidad de corto plazo suele ser más persistente que el componente de largo plazo en ambas series de rendimientos y bajo cualquier distribución de innovaciones. Este hecho puede ser atribuido en parte a los resultados mixtos en los efectos asimétricos temporales y de largo plazo.

Con relación al coeficiente del impacto asimétrico de las noticias, la mayoría de los parámetros estimados γ , con la excepción de los modelos GJR, CGARCH y CGARCH-A1 basados en la distribución de Laplace para las innovaciones del petróleo Maya, son significativamente diferentes de cero al 1% y 5%. Este hallazgo indica que los choques negativos tienen mayor impacto en la volatilidad condicional de corto que los choques positivos de la misma magnitud. En el caso de los efectos asimétricos de largo plazo, la característica de volatilidad asimétrica es estadísticamente significativa para el modelo CGARCH-A1 bajo el supuesto distribucional normal. El signo y la significancia del parámetro de asimetría en el modelo CGARCH-A1 muestran fuerte evidencia de efectos de apalancamiento en los rendimientos del Istmo y Maya. En consecuencia, los choques negativos disminuyen notablemente el grado de persistencia en la volatilidad de corto plazo, mientras que la incrementa significativamente en el largo plazo. (Tabla 2)

Basado en ambos supuestos distribucionales para las innovaciones, los coeficientes del término de potencia del modelo APARCH son significativamente diferentes de cero con valores de 1.4536 y 1.2749 para el crudo Maya, respectivamente. En el caso del Istmo, el mismo parámetro estimado alcanza valores significativos de 1.3309 y 1.1863.

Los valores de δ son mayores a uno, pero diferentes de dos en ambos tipos de crudo bajo cualquier supuesto distribucional. Este hecho sugiere que, en lugar de modelar la varianza condicional, resulta más importante el modelado de la desviación estándar condicional. Además, este hallazgo revela la presencia de correlación más alta entre los rendimientos absolutos que en los rendimientos cuadrados, una característica común observada en las series financieras de frecuencia alta, también conocida como memoria larga (Ding et al., 1993). (Tabla 3)

Para comparar la calidad de ajuste de los siete modelos de volatilidad se utiliza los valores de la función de verosimilitud, los criterios AIC y BIC en términos absolutos. Los valores más pequeños de los primeros dos criterios de información revelan el potencial de los modelos CGARCH-A2 bajo innovaciones normales condicionales para explicar las características de la volatilidad condicional en ambos tipos de petróleo, seguido por el modelo CGARCH-A1. Aunque los valores pequeños del criterio de información de Schwarz confirman que los modelos EGARCH y GJR presentan el mejor desempeño predictivo. Esto se atribuye al hecho de que el BIC penaliza a los modelos con parámetros adicionales. En el caso del supuesto distribucional de Laplace, el modelo CGARCH-A2 continúa proporcionando resultados superiores al resto de las especificaciones, seguido por el modelo EGARCH para describir las características de la volatilidad condicional en ambas series del petróleo. Pese a que el criterio de información BIC selecciona a los modelos GARCH y EGARCH para los rendimientos del Maya e Istmo, respectivamente.

Tabla 2. Resultados de los modelos estimados del petróleo Maya

	Distribución Normal							Distribución de Laplace						
	GARCH	EGARCH	GJR	APARCH	CGARCH	CGARCH-A1	CGARCH-A2	GARCH	EGARCH	GJR	APARCH	CGARCH	CGARCH-A1	CGARCH-A2
c	0.0757** (0.0331)	0.0343 (0.0333)	0.0643** (0.0337)	0.0826* (0.0325)	0.0895* (0.0332)	0.0670** (0.0342)	0.0317 (0.0336)	0.1052* (0.0254)	0.0821* (0.0254)	0.0956* (0.0256)	0.0999* (0.0254)	0.0963* (0.0254)	0.0880* (0.0254)	0.0877* (0.0253)
ω	0.1192* (0.0151)	-0.0712* (0.0055)	0.1085* (0.0133)	0.0670* (0.0121)	0.0170* (0.0064)	0.0165* (0.0061)	-0.0105* (0.0028)	0.0983* (0.0303)	-0.0669* (0.0116)	0.1028* (0.0305)	0.0454** (0.0178)	0.0160 (0.0157)	0.0147 (0.0122)	-0.0130 (0.0109)
α	0.0748* (0.0049)	0.1346* (0.0075)	0.0400* (0.0051)	0.0848* (0.0052)	0.0769* (0.0135)	0.0602* (0.0130)	0.0886* (0.0101)	0.0689* (0.0104)	0.1228* (0.0176)	0.0432* (0.0124)	0.0722* (0.0114)	0.0685** (0.0293)	0.0571*** (0.0307)	0.0982* (0.0235)
β	0.9102* (0.0059)	0.9843* (0.0019)	0.9160* (0.0049)	0.9146* (0.0056)	0.7278* (0.0580)	0.7261* (0.0538)	0.9899* (0.0020)	0.9243* (0.0106)	0.9888* (0.0043)	0.9251* (0.0111)	0.9276* (0.0103)	0.7377* (0.1710)	0.7210* (0.1419)	0.9921* (0.0035)
ρ					0.0285* (0.0068)	0.0092 (0.0061)	0.1225* (0.0207)					0.0334*** (0.0204)	0.0157 (0.0148)	0.0966** (0.0437)
φ					0.9486* (0.0079)	0.9537* (0.0082)	0.7985* (0.0443)					0.9493* (0.0174)	0.9555* (0.1172)	0.7758* (0.1172)
γ		-0.2932* (0.0423)	0.0596* (0.0078)	-0.2531* (0.0403)		0.0427** (0.0174)	-0.4305* (0.0762)		-0.2832* (0.0979)	0.0472 (0.0167)	-0.2529 (0.0914)		0.0464 (0.0423)	-0.3565*** (0.1492)
ψ						0.0294* (0.0062)	0.0681 (0.0786)					0.0244 (0.0158)	-0.0784 (0.2580)	
δ					1.4536* (0.1225)					1.2749* (0.2441)				
α+β	0.9858	0.9843	0.9560	0.9994	0.8047	0.7861	0.9899	0.9932	0.9888	0.9683	0.9998	0.8062	0.7781	0.9921
Log(L)	-9593	-9579	-9580	-9574	-9587	-9572	-9570	-9440	-9430	-9435	-9429	-9437	-9431	-9425
AIC	1,9194	1,9168	1,9169	1,9188	1,9187	1,9160	1,9157	1,8887	1,8869	1,8880	1,8879	1,8886	1,8878	1,8867
BIC	1,9219	1,9200	1,9201	1,9219	1,9225	1,9211	1,9208	1,8912	1,8901	1,8912	1,8911	1,8924	1,8929	1,8918
Q(20)	14,4059	12,0500	12,1833	14,5283	14,4857	12,3330	12,4650	14,0693	11,6360	12,1572	14,3531	14,3515	12,3336	11,9358
	[0.8093]	[0.9143]	[0.9096]	[0.8027]	[0.8050]	[0.9041]	[0.8991]	[0.8270]	[0.9280]	[0.9106]	[0.8121]	[0.8122]	[0.9041]	[0.9183]
Q2(20)	19,6573	26,6746	25,2887	21,0476	15,7264	19,1832	17,1820	21,5711	29,8688	25,3471	23,7890	16,6125	20,1409	20,5002
	[0.4795]	[0.1447]	[0.1906]	[0.3943]	[0.7334]	[0.5099]	[0.6411]	[0.3642]	[0.0720]	[0.1885]	[0.2517]	[0.6780]	[0.4491]	[0.4271]

Nota: Log(L) es el valor máximo de la función de verosimilitud logarítmica. AIC y BIC representan los criterios de información de Akaike y Schwarz, respectivamente. Q(20) y Q²(20) indican los estadísticos de la prueba de Ljung-Box para los residuos simples y cuadrados con 12 rezagos y valores-p entre corchetes cuadrados. Los términos *, ** y *** indican significancia en niveles del 1%, 5% y 10%, respectivamente. Los errores estándar se reportan entre paréntesis.

Tabla 3. Resultados de los modelos estimados del petróleo Istmo

	Distribución Normal							Distribución de Laplace						
	GARCH	EGARCH	GJR	APARCH	CGARCH	CGARCH-A1	CGARCH-A2	GARCH	EGARCH	GJR	APARCH	CGARCH	CGARCH-A1	CGARCH-A2
c	0.0935*	0.0366	0.0535	0.0847*	0.0912*	0.0590***	0.0354	0.0979*	0.0846*	0.0901*	0.0982*	0.0973*	0.0923*	0.0877*
	(0.0332)	(0.0335)	(0.0346)		(0.0338)	(0.0346)	(0.0337)	(0.0259)	(0.0257)	(0.0260)	(0.0258)	(0.0259)	(0.0261)	(0.0257)
σ				-0.0257***				-0.0238**	-0.0239*	-0.0223***	-0.0232***	-0.0226***	-0.0249**	-0.0232***
				(0.0156)				(0.0123)	(0.0121)	(0.0124)	(0.0126)	(0.0128)	(0.0127)	(0.0126)
ω	0.1334*	-0.0668*	0.1667*	0.0719*	0.0155*	0.0147*	-0.0076*	0.0751**	-0.0591*	0.0969*	0.0380**	0.0118	-0.0105	-0.0115
	(0.0161)	(0.0060)	(0.0183)	(0.0129)	(0.0057)	(0.0055)	(0.0024)	(0.0258)	(0.0116)	(0.0295)	(0.0157)	(0.0103)	(0.0085)	(0.0087)
α	0.0742*	0.1359*	0.0434*	0.0897*	0.0862*	0.0513*	0.0774*	0.0540*	0.1124*	0.0327*	0.0723*	0.0736*	0.0216	0.0854*
	(0.0050)	(0.0093)	(0.0062)	(0.0055)	(0.0110)	(0.0119)	(0.0101)	(0.0089)	(0.0179)	(0.0121)	(0.0108)	(0.0253)	(0.0285)	(0.0209)
β	0.9080*	0.9805*	0.9017*	0.9097*	0.7238*	0.7294*	0.9888*	0.9411*	0.9884*	0.9362*	0.9366*	0.7169*	0.7677*	0.9923*
	(0.0063)	(0.0024)	(0.0067)	(0.0062)	(0.0512)	(0.0511)	(0.0021)	(0.0098)	(0.0038)	(0.0106)	(0.0101)	(0.1498)	(0.1055)	(0.0034)
ρ					0.0193*	0.0088***	0.1099*					0.0237**	0.0211	0.0913**
					(0.0050)	(0.0054)	(0.0182)					(0.0116)	(0.0146)	(0.0424)
φ					0.9599*	0.9618*	0.8250*					0.9646*	0.9649*	0.7658*
					(0.0073)	(0.0072)	(0.0484)					(0.0118)	(0.0132)	(0.1543)
γ	-0.2889*	0.0611*	-0.2648*		0.0549*	-0.4771*			-0.3171*	0.0452*	-0.3117*	0.0927**	-0.3319**	
	(0.0483)	(0.0091)	(0.0446)		(0.0174)	(0.0942)			(0.1171)	(0.0162)	(0.1134)	(0.0409)	(0.1639)	
ψ					0.0197*	-0.0750						0.0014	-0.4017	
					(0.0064)	(0.0947)						(0.0163)	(0.3270)	
δ				1.3309*							1.1863*			
				(0.1253)							(0.2598)			
α+β	0.9822	0.9805	0.9451	0.9816	0.8100	0.7804	0.9888	0.9951	0.9884	0.9689	0.9982	0.7905	0.7893	0.9923
Log(L)	-9552	-9539	-9541	-9535	-9543	-9532	-9531	-9443	-9432	-9438	-9431	-9438	-9433	-9427
AIC	1,9112	1,9088	1,9092	1,9104	1,9097	1,9079	1,9078	1,8896	1,8876	1,8889	1,8888	1,8892	1,8884	1,8874
BIC	1,9137	1,9120	1,9123	1,9142	1,9135	1,9129	1,9128	1,8927	1,8914	1,8927	1,8926	1,8943	1,8941	1,8930
Q(20)	9,2905	9,7352	10,5870	9,2023	9,5509	10,3324	9,8572	8,3792	8,6774	8,8780	8,5103	8,6132	9,3296	8,9236
	[0.9793]	[0.9727]	[0.9562]	[0.9804]	[0.9756]	[0.9617]	[0.9707]	[0.9890]	[0.9864]	[0.9843]	[0.9879]	[0.9870]	[0.9788]	[0.9838]
Q2(20)	17,4506	19,6275	19,0505	14,8589	9,7070	12,4782	11,1667	21,4301	22,3130	22,9273	18,8848	9,7448	12,2414	12,9210
	[0.6235]	[0.4814]	[0.5185]	[0.7844]	[0.9732]	[0.8986]	[0.9418]	[0.3722]	[0.3238]	[0.2924]	[0.5293]	[0.9726]	[0.9075]	[0.8807]

Nota: Log(L) es el valor máximo de la función de verosimilitud logarítmica. AIC y BIC representan los criterios de información de Akaike y Schwarz, respectivamente. Q(20) y Q²(20) indican los estadísticos de la prueba de Ljung-Box para los residuales simples y y cuadrados con 12 rezagos y valores-p entre corchetes cuadrados. Los términos *, ** y *** indican significancia en niveles del 1%, 5% y 10%, respectivamente. Los errores estándar se reportan entre paréntesis.

En el diagnóstico de los residuales estandarizados simples, los resultados de la prueba de Ljung-Box con 20 rezagos confirman suficiente evidencia a favor de la especificación correcta de la media condicional para explicar apropiadamente el comportamiento de los rendimientos del petróleo bajo cualquier supuesto distribucional. Esto obedece a los altos valores- p que rechazan la presencia de correlación serial en los residuales estandarizados a un nivel de significancia del 5%. En el caso de los residuales estandarizados cuadrados, las probabilidades altas de la prueba de Ljung-Box confirman la capacidad de los modelos de volatilidad para capturar los efectos GARCH observados en los rendimientos del petróleo Maya e Istmo bajo cualquier supuesto distribucional. Por lo que, no existe evidencia estadísticamente significativa de error de especificación en los modelos estimados.

4.2 Evaluación de la predicción óptima de la volatilidad fuera de la muestra

Para evaluar el desempeño predictivo de los modelos de volatilidad fuera de la muestra, utilizamos el periodo del 2 de enero de 2011 al 30 de diciembre de 2016 para reestimar la varianza condicional a través de una ventana móvil. Este procedimiento consiste en remover la observación más remota y agregar la observación más reciente en el periodo muestral. Esta predicción se compara con la volatilidad no observable, la cual es medida por la variable proxy de los rendimientos cuadrados.⁴ El proceso se repite hasta obtener el error de predicción del 31 de diciembre de 2016 para los horizontes de predicción de 1, 5 y 20 días. De esta manera, el tamaño de la muestra se mantiene fijo durante la reestimación de los modelos de volatilidad y las predicciones fuera de la muestra no se traslapan.

En la Tabla 4 se reportan las probabilidades *bootstrap* de la prueba estadística de poder predictivo superior para los horizontes de predicción de 1 día. En este análisis se estiman los valores- p consistente (PPSc), límite inferior (PPSI) y límite superior (PPSu) de la prueba estadística PPS para cada uno de los modelos de volatilidad estimados, las cuales se obtuvieron sobre una base de 10,000 muestras *bootstrap* estacionarias de la prueba empírica bajo las diferentes medidas de errores predictivos. De acuerdo con Hansen (2005), la distribución del estadístico es sensible y no es única bajo la hipótesis nula por la inclusión de modelos inapropiados o con pobre poder predictivo. Además, cada modelo de volatilidad es turnado para tomar su lugar como modelo base (*benchmark*) durante la implementación de la prueba estadística PPS bajo las diferentes medidas de errores predictivos SME, MAE, MME(U) y MME(O).

De acuerdo con la significancia estadística del poder predictivo de los modelos de volatilidad estimados para los rendimientos del Istmo, los valores- p de la prueba estadística PPSI indican que la mayoría de los modelos base no tienen la capacidad suficiente para superar el desempeño predictivo de los modelos alternativos para el horizonte de 1 día, bajo cualquier medida de error predictivo

y supuesto distribucional. Aunque, asumiendo normalidad existen algunas excepciones como los modelos CGARCH-A1 bajo las medidas MAE y MME(O) y el modelo CGARCH con la medida MME(U). En el caso de la distribución de Laplace, los modelos base que presentan el mejor desempeño predictivo fuera de la muestra son el CGARCH y CGARCH-A2 basados en la medida MME(U) y el APARCH basado en la medida MME(O). En el caso del petróleo Maya, el modelo CGARCH con innovaciones normales proporciona el mejor desempeño predictivo bajo la medida MME(U), mientras que las medidas MSE y MAE evidencian la capacidad predictiva de los modelos EGARCH y CGARCH con innovaciones de Laplace, respectivamente. (Tabla 4)

Por su parte, los altos valores- p de las pruebas estadísticas PPSc y PPSu confirman notablemente el poder predictivo de los modelos CGARCH con innovaciones de Laplace y normales bajo las diferentes medidas y para el horizonte de 1 día del petróleo Istmo. Dichos modelos, en cuanto a poder predictivo, son seguidos por los CGARCH-A1 y CGARCH-A2 bajo las medidas de error predictivo asimétricas. Asimismo, este hecho es sustentado para el caso del petróleo Maya, puesto que el modelo CGARCH-A2 bajo cualquier supuesto distribucional parece ser la especificación más apropiada para predecir la volatilidad condicional fuera de la muestra, bajo cualquier medida de error predictivo, seguido por los modelos EGARCH, CGARCH y APARCH con innovaciones de Laplace bajo las medidas MSE, MAE y MME(O), respectivamente. Un hallazgo importante en el análisis es que el modelo CGARCH-A1 presenta el peor desempeño predictivo entre los modelos de volatilidad de dos componentes, debido a que solamente en 3 casos de 16 alcanza valores- p significativos, pero relativamente pequeños para superar a los modelos que alcanzan el mejor desempeño predictivo con valores- p más grandes.

La Tabla 5 presenta los resultados de las pruebas estadísticas PPS para el horizonte de 5 días de las diferentes medidas de errores predictivos. Al analizar las probabilidades *bootstrap* de la prueba estadística de límite inferior (PPSI), se puede observar que es difícil que algún modelo de referencia presente mejor desempeño predictivo con respecto a los modelos alternativos en ambas series de rendimientos del petróleo. Aunque el desempeño predictivo de los modelos alternativos es ampliamente superado por los modelos EGARCH y APARCH con innovaciones de Laplace y el modelo CGARCH-A1 con innovaciones normales para el petróleo Istmo, debido a que la hipótesis nula no se puede rechazar bajo las medidas MSE, MME(U), MAE y MMME(O), respectivamente. En tanto que, para los rendimientos del petróleo Maya, únicamente el modelo CGARCH con innovaciones de Laplace proporciona el mejor desempeño predictivo con respecto a los modelos alternativos bajo la medida MAE, puesto que el valor- p es relativamente más grande que la probabilidad del modelo CGARCH-A2 con innovaciones normales. Con respecto a la probabilidad consistente (PPSc) y límite superior (PPSu), los resultados muestran claramente el poder predictivo de los modelos CGARCH y CGARCH-A2 aunque con resultados mixtos de acuerdo con el supuesto distribucional.

⁴ Este medida proxy es la más común utilizada en la literatura porque si el modelo estimado está correctamente especificado, el error cuadrado representa un estimador insesgado de la varianza diaria.

Tabla 4. Resultados de la prueba de poder predictivo superior para un día.

Modelos	Función	I S T M O				M A Y A			
		MSE	MAE	MME(U)	MME(O)	MSE	MAE	MME(U)	MME(O)
GARCH-N	PPSI	0,0125	0,0000	0,0244	0,0000	0,0715	0,0715	0,0031	0,0015
	PPSc	0,0453	0,0000	0,0244	0,0000	0,1534	0,1534	0,0031	0,0033
	PPSu	0,0453	0,0000	0,0244	0,0000	0,1534	0,1534	0,0031	0,0035
EGARCH-N	PPSI	0,0546	0,0224	0,3663	0,0296	0,0410	0,0244	0,0142	0,0236
	PPSc	0,0801	0,0224	0,3663	0,0296	0,1933	0,1739	0,0142	0,0428
	PPSu	0,0801	0,0224	0,3663	0,0296	0,1933	0,1739	0,0142	0,0428
GJR-N	PPSI	0,0215	0,0000	0,0050	0,0000	0,0739	0,0593	0,0012	0,0000
	PPSc	0,0398	0,0000	0,0050	0,0000	0,0739	0,0593	0,0012	0,0000
	PPSu	0,0398	0,0000	0,0050	0,0000	0,0739	0,0593	0,0012	0,0000
APARCH-N	PPSI	0,0163	0,0066	0,0814	0,0127	0,0494	0,0294	0,1597	0,2785
	PPSc	0,0412	0,0067	0,0866	0,0127	0,1653	0,1435	0,1616	0,2812
	PPSu	0,0412	0,0067	0,0866	0,0127	0,1653	0,1435	0,1616	0,2812
CGARCH-N	PPSI	0,0817	0,0528	0,5153	0,1782	0,1385	0,1058	0,4698	0,0982
	PPSc	0,5112	0,5062	0,5155	0,5032	0,1624	0,1426	0,4699	0,0992
	PPSu	0,5112	0,5083	0,5170	0,5032	0,2079	0,1897	0,4699	0,1221
CGARCH-A1-N	PPSI	0,0441	0,1393	0,0345	0,3242	0,0021	0,0049	0,0012	0,0028
	PPSc	0,0441	0,1425	0,0345	0,3242	0,0021	0,0049	0,0012	0,0028
	PPSu	0,0441	0,1425	0,0345	0,3242	0,0021	0,0049	0,0012	0,0050
CGARCH-A2-N	PPSI	0,0447	0,0739	0,4320	0,1189	0,0012	0,0279	0,4381	0,4988
	PPSc	0,0676	0,0760	0,4481	0,1198	0,1875	0,5327	0,4986	0,5287
	PPSu	0,0676	0,0760	0,4481	0,1202	0,1875	0,5410	0,5052	0,5287
GARCH-L	PPSI	0,0057	0,0017	0,0106	0,0565	0,2091	0,0080	0,0121	0,0051
	PPSc	0,0511	0,0017	0,0143	0,0565	0,2091	0,0135	0,0121	0,0051
	PPSu	0,0511	0,0017	0,0143	0,0565	0,2091	0,0135	0,0121	0,0051
EGARCH-L	PPSI	0,0374	0,0035	0,0900	0,0016	0,4487	0,0038	0,0226	0,0045
	PPSc	0,0401	0,0035	0,1106	0,0016	0,4487	0,0111	0,0226	0,0120
	PPSu	0,0401	0,0035	0,1106	0,0016	0,4487	0,0111	0,0226	0,0120
GJR-L	PPSI	0,0164	0,0000	0,0025	0,0000	0,0615	0,0000	0,0271	0,0000
	PPSc	0,0373	0,0000	0,0025	0,0000	0,1516	0,0000	0,0271	0,0000
	PPSu	0,0373	0,0000	0,0025	0,0000	0,1516	0,0000	0,0271	0,0000
APARCH-L	PPSI	0,0141	0,0643	0,0421	0,2643	0,3791	0,0708	0,1081	0,0343
	PPSc	0,0351	0,0701	0,0540	0,2671	0,4194	0,5106	0,1144	0,5221
	PPSu	0,0351	0,0703	0,0540	0,2671	0,4194	0,5131	0,1144	0,5221
CGARCH-L	PPSI	0,0170	0,0271	0,5091	0,1516	0,2691	0,2056	0,1894	0,1791
	PPSc	0,5224	0,5299	0,5103	0,5002	0,2786	0,2126	0,1894	0,2127
	PPSu	0,5224	0,5299	0,5115	0,5013	0,2952	0,2227	0,1894	0,2127
CGARCH-A1-L	PPSI	0,0192	0,0492	0,0026	0,1705	0,0008	0,0000	0,0007	0,0000
	PPSc	0,0192	0,0492	0,0026	0,1705	0,0013	0,0000	0,0007	0,0000
	PPSu	0,0192	0,0492	0,0026	0,1705	0,0013	0,0000	0,0007	0,0000
CGARCH-A2-L	PPSI	0,0438	0,0739	0,4815	0,1549	0,4115	0,0806	0,1257	0,0234
	PPSc	0,0440	0,0760	0,5079	0,1591	0,5395	0,0806	0,5076	0,0677
	PPSu	0,0440	0,0760	0,5079	0,1591	0,5395	0,1071	0,5076	0,0667

Nota: PPSc, PPSI y PPSu indican los valores-p consistente, límite inferior y límite superior de la prueba de poder predictivo superior de Hansen, respectivamente. Para calcular los valores-p se utilizaron 10,000 replicaciones bootstrap. Los valores en negritas indican la aceptación de la hipótesis nula de que ninguno de los modelos alternativos tiene mejor desempeño predictivo que el modelo base (benchmark).

Tabla 5. Resultados de la prueba de poder predictivo superior para 5 días.

Modelos	Función	I S T M O				M A Y A			
		MSE	MAE	MME(U)	MME(O)	MSE	MAE	MME(U)	MME(O)
GARCH-N	PPSI	0,0749	0,0011	0,0716	0,0003	0,2158	0,0440	0,0019	0,0215
	PPSc	0,1303	0,0011	0,0843	0,0003	0,2158	0,0478	0,0019	0,0392
	PPSu	0,1303	0,0011	0,0843	0,0003	0,2158	0,0478	0,0019	0,0392
EGARCH-N	PPSI	0,0127	0,0419	0,3104	0,0340	0,1081	0,0249	0,0548	0,1421
	PPSc	0,0671	0,0419	0,3104	0,0368	0,3393	0,1695	0,0803	0,1946
	PPSu	0,0671	0,0419	0,3104	0,0368	0,3393	0,1695	0,0831	0,1946
GJR-N	PPSI	0,0614	0,0006	0,0526	0,0000	0,0138	0,0109	0,0059	0,0013
	PPSc	0,1095	0,0006	0,0568	0,0000	0,0138	0,0109	0,0059	0,0013
	PPSu	0,1095	0,0006	0,0568	0,0000	0,0138	0,0109	0,0059	0,0013
APARCH-N	PPSI	0,0278	0,0888	0,2485	0,0930	0,0645	0,0640	0,0270	0,3964
	PPSc	0,1045	0,1119	0,3054	0,0981	0,2955	0,1853	0,1206	0,4555
	PPSu	0,1045	0,1119	0,3054	0,0981	0,2955	0,1853	0,0459	0,4597
CGARCH-N	PPSI	0,0104	0,0509	0,2884	0,1275	0,3029	0,0402	0,1954	0,1037
	PPSc	0,5433	0,5153	0,5334	0,5033	0,4082	0,1028	0,2278	0,1482
	PPSu	0,5433	0,5153	0,5334	0,5038	0,4141	0,1028	0,2278	0,1611
CGARCH-A1-N	PPSI	0,0264	0,0566	0,0678	0,2334	0,0014	0,0344	0,0171	0,0121
	PPSc	0,0264	0,0613	0,0678	0,2367	0,0073	0,0344	0,0171	0,0121
	PPSu	0,0264	0,0613	0,0678	0,2367	0,0073	0,0344	0,0174	0,0226
CGARCH-A2-N	PPSI	0,0083	0,0467	0,1125	0,1068	0,4091	0,0305	0,1925	0,4213
	PPSc	0,0428	0,0467	0,1396	0,1068	0,5625	0,5562	0,5132	0,5562
	PPSu	0,0428	0,0467	0,1396	0,1068	0,5625	0,5562	0,5132	0,5562
GARCH-L	PPSI	0,0211	0,0201	0,0567	0,0136	0,1311	0,0441	0,1131	0,0508
	PPSc	0,1125	0,0208	0,0849	0,0145	0,2855	0,0849	0,2558	0,0773
	PPSu	0,1125	0,0208	0,0849	0,0151	0,2855	0,0849	0,2558	0,0279
EGARCH-L	PPSI	0,1090	0,0587	0,4394	0,0272	0,2126	0,0222	0,2261	0,0685
	PPSc	0,1246	0,0587	0,4601	0,0272	0,3474	0,0557	0,3744	0,0685
	PPSu	0,1246	0,0587	0,4601	0,0272	0,3474	0,0557	0,3744	0,0685
GJR-L	PPSI	0,0865	0,0011	0,0194	0,0000	0,0271	0,0011	0,0217	0,0013
	PPSc	0,0865	0,0011	0,0375	0,0000	0,0731	0,0011	0,0713	0,0013
	PPSu	0,0865	0,0011	0,0375	0,0000	0,0731	0,0011	0,0713	0,0013
APARCH-L	PPSI	0,0379	0,1141	0,2621	0,2133	0,0841	0,2637	0,3725	0,1216
	PPSc	0,0936	0,1417	0,2858	0,2312	0,2767	0,5252	0,4209	0,5385
	PPSu	0,0936	0,1422	0,3013	0,2312	0,2767	0,5252	0,4209	0,5385
CGARCH-L	PPSI	0,0138	0,0995	0,2223	0,1417	0,3520	0,2796	0,4536	0,1505
	PPSc	0,5434	0,5121	0,3346	0,5139	0,5406	0,3011	0,5456	0,2226
	PPSu	0,5531	0,5143	0,3346	0,5139	0,5426	0,3130	0,5456	0,2226
CGARCH-A1-L	PPSI	0,0313	0,0244	0,0007	0,1032	0,0006	0,0002	0,0011	0,0007
	PPSc	0,0313	0,0244	0,0007	0,1056	0,0006	0,0002	0,0139	0,0007
	PPSu	0,0313	0,0244	0,0007	0,1056	0,0006	0,0002	0,0139	0,0007
CGARCH-A2-L	PPSI	0,0236	0,1030	0,2196	0,1809	0,4056	0,1604	0,3963	0,1530
	PPSc	0,0966	0,1037	0,2255	0,1809	0,4239	0,2717	0,3963	0,2653
	PPSu	0,0966	0,1037	0,2616	0,1809	0,4239	0,2717	0,4096	0,2653

Nota: PPSc, PPSI y PPSu indican los valores-p consistente, límite inferior y límite superior de la prueba de poder predictivo superior de Hansen, respectivamente. Para calcular los valores-p se utilizaron 10,000 replicaciones bootstrap. Los valores en negritas indican la aceptación de la hipótesis nula de que ninguno de los modelos alternativos tiene mejor desempeño predictivo que el modelo base (benchmark).

Tabla 6. Resultados de la prueba de poder predictivo superior para 20 días.

Modelos	Función	I S T M O				M A Y A			
		MSE	MAE	MME(U)	MME(O)	MSE	MAE	MME(U)	MME(O)
GARCH-N	PPSI	0,1256	0,0199	0,1698	0,0016	0,3434	0,0126	0,0450	0,1010
	PPSc	0,2504	0,0240	0,2151	0,0016	0,3624	0,0202	0,0450	0,0210
	PPSu	0,2541	0,0240	0,2151	0,0016	0,3624	0,0202	0,0450	0,0481
EGARCH-N	PPSI	0,0316	0,2117	0,2446	0,1031	0,0159	0,0205	0,1693	0,0810
	PPSc	0,1068	0,2117	0,2527	0,1061	0,0159	0,0816	0,1693	0,1060
	PPSu	0,1068	0,2117	0,2527	0,1091	0,0159	0,0816	0,1693	0,1450
GJR-N	PPSI	0,0678	0,0034	0,1026	0,0001	0,2548	0,0001	0,0756	0,0001
	PPSc	0,0678	0,0034	0,1026	0,0001	0,3624	0,0001	0,0756	0,0001
	PPSu	0,0678	0,0034	0,1026	0,0001	0,3624	0,0001	0,0756	0,0001
APARCH-N	PPSI	0,1449	0,2742	0,2987	0,3182	0,1038	0,1067	0,0250	0,1779
	PPSc	0,2534	0,3350	0,3836	0,3266	0,1313	0,1152	0,0303	0,5245
	PPSu	0,2636	0,3350	0,3836	0,3327	0,2565	0,1515	0,0303	0,5402
CGARCH-N	PPSI	0,1256	0,5301	0,3408	0,4809	0,3573	0,2994	0,2073	0,1162
	PPSc	0,5498	0,5301	0,5373	0,4900	0,5639	0,3119	0,2807	0,1596
	PPSu	0,5498	0,5301	0,5373	0,4900	0,5639	0,3458	0,2807	0,1720
CGARCH-A1-N	PPSI	0,0590	0,1037	0,0705	0,0705	0,2831	0,0169	0,4882	0,0141
	PPSc	0,0909	0,1037	0,0705	0,0705	0,3624	0,0414	0,5168	0,0141
	PPSu	0,0909	0,1037	0,0705	0,0705	0,3624	0,1015	0,5168	0,0779
CGARCH-A2-N	PPSI	0,0407	0,2263	0,1252	0,4812	0,3044	0,2628	0,2364	0,2145
	PPSc	0,0854	0,2321	0,1541	0,5036	0,3624	0,5099	0,5340	0,2453
	PPSu	0,0854	0,2321	0,1541	0,5036	0,3624	0,5382	0,5340	0,2826
GARCH-L	PPSI	0,1176	0,0728	0,1535	0,0402	0,3431	0,0137	0,3328	0,0215
	PPSc	0,2365	0,0789	0,1803	0,0402	0,3624	0,0368	0,3328	0,0467
	PPSu	0,2406	0,0789	0,1803	0,0402	0,3624	0,0530	0,3328	0,0694
EGARCH-L	PPSI	0,1549	0,2971	0,3763	0,2035	0,3191	0,0426	0,0996	0,0824
	PPSc	0,2195	0,3093	0,3957	0,2035	0,3191	0,0464	0,1051	0,1271
	PPSu	0,2481	0,3093	0,3957	0,2035	0,3191	0,0975	0,1051	0,1271
GJR-L	PPSI	0,0408	0,0239	0,0528	0,0084	0,3056	0,0004	0,0873	0,0003
	PPSc	0,0902	0,0239	0,0830	0,0084	0,3553	0,0004	0,0873	0,0003
	PPSu	0,0902	0,0239	0,0830	0,0084	0,3553	0,0004	0,0873	0,0003
APARCH-L	PPSI	0,1497	0,4053	0,3414	0,4409	0,1040	0,2980	0,2356	0,2356
	PPSc	0,2597	0,4506	0,4008	0,4409	0,1117	0,3619	0,5190	0,5290
	PPSu	0,2597	0,4506	0,4008	0,4409	0,1117	0,3826	0,5199	0,5499
CGARCH-L	PPSI	0,1308	0,4335	0,3477	0,1544	0,3529	0,4047	0,3466	0,2208
	PPSc	0,5630	0,5320	0,5398	0,1544	0,5679	0,5425	0,5412	0,2617
	PPSu	0,5630	0,5320	0,5398	0,1585	0,5679	0,5425	0,5414	0,3402
CGARCH-A1-L	PPSI	0,0179	0,0226	0,0073	0,1061	0,3467	0,0244	0,0379	0,0239
	PPSc	0,0190	0,0226	0,0073	0,1061	0,3624	0,0523	0,0506	0,0239
	PPSu	0,0190	0,0226	0,0073	0,1061	0,3624	0,0523	0,0506	0,0934
CGARCH-A2-L	PPSI	0,0501	0,3351	0,2153	0,4016	0,3328	0,1031	0,1289	0,0970
	PPSc	0,1535	0,3356	0,2291	0,4982	0,3624	0,1432	0,1975	0,1421
	PPSu	0,1535	0,3365	0,2291	0,4982	0,3624	0,1661	0,1975	0,1743

Nota: PPSc, PPSI y PPSu indican los valores-p consistente, límite inferior y límite superior de la prueba de poder predictivo superior de Hansen, respectivamente. Para calcular los valores-p se utilizaron 10,000 replicaciones bootstrap. Los valores en negritas indican la aceptación de la hipótesis nula de que ninguno de los modelos alternativos tiene mejor desempeño predictivo que el modelo base (benchmark).

En el caso del petróleo Istmo, el modelo CGARCH con innovaciones de Laplace, propuesto como modelo base y bajo las medidas MSE y MME(O), tiene el mejor desempeño para predecir la volatilidad condicional fuera de la muestra para el horizonte de 5 días. Sin embargo, bajo las medidas MAE y MME(U), los valores-*p* *bootstrap* indican que ninguno de los modelos alternativos alcanza superior desempeño predictivo que el modelo CGARCH con innovaciones normales. Para el caso del petróleo Maya, la capacidad predictiva del modelo CGARCH-A2 con innovaciones normales es incuestionable bajo cualquiera de las medidas de error predictivo, excluyendo la medida MME(U) en donde el poder predictivo del modelo CGARCH basado en la distribución de Laplace supera a los modelos alternativos. Al igual que en el horizonte de predicción de 1 día, el modelo CGARCH-A1 muestra el peor desempeño predictivo entre los modelos de volatilidad de dos componentes bajo cualquier medida de error predictivo, incluso por debajo del desempeño de los modelos APARCH y EGARCH bajo cualquier distribución.

Para el horizonte de predicción de 20 días, las probabilidades *bootstrap* de las pruebas estadísticas PPS se reportan en la Tabla 6. Para los petróleos Istmo y Maya, los valores-*p* de la prueba estadística PPSi indican que los modelos CGARCH bajo cualquier supuesto distribucional son la mejor opción para predecir la volatilidad condicional fuera de la muestra bajo las medidas MSE y MAE, respectivamente. La medida MME(U) apoya el desempeño predictivo de los modelos EGARCH con innovaciones de Laplace y CGARCH-A1 con innovaciones normales. En el caso de los valores-*p* de las pruebas estadísticas PPS_c y PPS_u, el modelo CGARCH con innovaciones de Laplace presenta el mejor desempeño para predecir la volatilidad condicional de los rendimientos del petróleo Istmo y Maya bajo las medidas MSE, MAE y MME(U), mientras que la medida MME(O) confirma el poder predictivo de los modelos CGARCH-A2 con innovaciones normales y APARCH con innovaciones de Laplace, respectivamente. Un hallazgo importante que se tiene que resaltar para el horizonte de predicción de 20 días, es que existen varios modelos con valores-*p* mayor al 5%, entre ellos, por ejemplo, los modelos GARCH y GJR. Este hecho implica que cualquier modelo con probabilidad *bootstrap* alta puede predecir correctamente la volatilidad de los rendimientos del petróleo Istmo y Maya.

En resumen, la evidencia empírica muestra que la calidad del petróleo y el horizonte de tiempo juega un papel fundamental en la selección del modelo con mejor desempeño predictivo, más que el supuesto distribucional y las medidas de errores predictivos. Por ejemplo, el modelo CGARCH simétrico con distribución normal o de Laplace, es la mejor alternativa para mejorar la predicción de la volatilidad de los rendimientos del petróleo Istmo para cualquier horizonte y medida de error de predicción. Para los rendimientos del petróleo Maya, el modelo CGARCH-A2 es preferido por las medidas de error para los horizontes de 1 y 5 días, particularmente para la distribución normal. Sin embargo, el modelo CGARCH con distribución de Laplace proporciona el mejor desempeño predictivo para el horizonte de 20 días, excepto bajo la medida MME(O) que prefiere al modelo APARCH. (Tabla 6)

5. Conclusiones

En este trabajo se estiman modelos CGARCH simétrico y asimétricos bajo dos distribuciones condicionales: Normal y Laplace, para mejorar la predicción de la volatilidad de los rendimientos de los precios de los petróleos Istmo y Maya en el periodo del 2 de enero de 2000 al 31 de diciembre de 2016. El desempeño predictivo de los modelos propuestos es comparado al de los modelos GARCH, EGARCH, GJR, APARCH durante el periodo del 3 de enero de 2011 al 31 de diciembre de 2016. Los hallazgos revelan que los rendimientos del petróleo presentan las características comunes de asimetría y persistencia en la volatilidad en el corto y largo plazos. Asimismo, los resultados fuera de la muestra de la prueba estadística de Hansen (2005) sustentan que los modelos CGARCH y CGARCH-A2 proporcionan excelentes predicciones de la volatilidad. A pesar de que el modelo CGARCH tiene un alcance limitado para capturar la asimetría en el corto y largo plazos, en particular para los rendimientos del petróleo Istmo. Además, la distribución de Laplace captura apropiadamente los movimientos en las fluctuaciones de los rendimientos del petróleo mexicano bajo las 4 medidas de errores y 3 horizontes de predicción. Los hallazgos empíricos son de gran relevancia, ya que proporcionan información más completa de la dinámica de la volatilidad en los mercados del petróleo mexicano. En este sentido, el gobierno federal contará con mejores herramientas para transferir su exposición al riesgo, a través del diseño de estrategias de cobertura óptima ante cambios inesperados en los mercados internacionales que afecten la tendencia positiva en los mercados del petróleo mexicano y, por consecuencia, las finanzas públicas del país. En términos de políticas públicas y diseño de estrategias óptimas, se recomienda la utilización de los modelos implementados en el presente trabajo para, por medio de la predicción, administrar operaciones en el mercado y aminorar el efecto de eventos extremos. La previsión de cambios abruptos e inestabilidad en los precios de los hidrocarburos es esencial para el manejo adecuado de la política monetaria, sobre todo, en aquellos países productores de los mismos.

Referencias

- Agnolucci, P., 2009. Volatility in Crude Oil Futures: A Comparison of the Predictive Ability of GARCH and Implied Volatility Models, *Energy Economics*. 31(2), 316-321.
- Baker, H.K., Rahman, A., Saadi, S., 2008. The Day-of-the-Week and Conditional Volatility: Sensitivity of the Distributional Assumptions, *Review of Financial Economics*. 17(4), 280-297.
- Bibby, B.M., Sorensen, M., 2003. Hyperbolic Processes in Finance, in Rachev, S.T. (editor), *Handbook of Heavy Tailed Distributions in Finance*. Elsevier Science, Amsterdam.
- Black, F., 1976. Studies of Stock Market Volatility Changes, *Proceedings of the American Statistical Association, Business and Economic Statistics Section*, 177-181.
- Brailsford T.J., Faff, R.W., 1996. An Evaluation of Volatility Forecasting Techniques, *Journal of Banking and Finance*, 20(3), 419-438.
- Cheong, C.W., 2009. Modeling and Forecasting Crude Oil Markets Using ARCH-Type Models, *Energy Policy*. 36(6), 2346-2355.
- Christoffersen, P., Jacobs, K., Wang, Y., 2006. Option Valuation with Long-Run and Short-Run Volatility Components. Unpublished Working Paper. McGill University.
- Diebold, F.X., Mariano, R.S., 1995. Comparing Predictive Accuracy, *Journal of Business & Economic Statistics*. 13(3), 253-263.
- Engle, R.F., Lee, G.G., 1999. A Permanent and Transitory Component Model of Stock Return Volatility, in Engle, R. F., White, H. (eds.), *Cointegration, Casuality and Forecasting: A Festschrift in Honor of Clive W. J. Granger*. Oxford University Press, Oxford, 475-497.
- Granger, C.W., Ding, Z., 1995. Some Properties of Absolute Return, an Alternative Measure of Risk, *Annales D'économie et the Statistique*. 40(Oct-Dec), 67-91.
- Glosten, L., Jaganathan, R., Runkle, D., 1993. On the Relation Between the Expected Value and the Volatility of the Nominal Excess Returns on Stocks, *Journal of Finance*. 48(5), 1779-1801.
- Hansen, P.R., 2005. A Test for Superior Predictive Ability, *Journal of Business and Economics Statistics*. 23(4), 365-380.
- Hassan, S.A., Zaman, K., 2012. Effect of Oil Prices on Trade Balance: New Insights into the Cointegration Relationship from Pakistan. *Economic Modelling*. 29(6), 2125-2143.
- Hou, A., Suardi, S., 2012. A Nonparametric GARCH Model of Crude Oil Price Return Volatility, *Energy Economics*. 34(2), 616-626.
- Kang, S.H., Kang, S.M., Yoon, S.M., 2009. Forecasting Volatility of Crude Oil Markets, *Energy Economics*. 31(1), 119-125.
- Kroner, K.F., Kneafsey, K.P., Claessens, S., 1995. Forecasting Volatility in Commodity Markets, *Journal of Forecasting*. 14(2), 77-95.
- Marzo, M., Zagaglia, P., 2010. Volatility Forecasting for Crude Oil Futures, *Applied Economics Letters*. 17(16), 1587-1599.
- Mittnik, S., Paoletta, M.S., Rachev, S.T., 1998. Unconditional and Conditional Distributional Models for Nikkei Index, *Asia-Pacific Financial Markets*. 5(2), 99-128.
- Mohammadi, H., Su, L., 2010. International Evidence on Crude Oil Price Dynamics: Application of ARIMA-GARCH Models, *Energy Economics*. 32(5), 1001-1008.
- Narayan, P.K., Narayan, S., 2007. Modelling Oil Price Volatility, *Energy Policy*. 35(12), 6549-6553.
- Nelson, D., 1991. Conditional Heteroskedasticity in Asset Returns: A New Approach, *Econometrica*. 59(2), 347-370.
- Patton, A.J., 2011. Volatility Forecast Comparison Using Imperfect Volatility Proxies, *Journal of Econometrics*. 160(1), 246-256.
- Politis, D.N., Romano, J.P., 1994. The Stationary Bootstrap, *Journal of the American Statistical Association*. 89(428), 1303-1313.
- Sadorsky, P., 2006. Modeling and Forecasting Petroleum Futures Volatility, *Energy Economics* 28(4), 467-488.
- Wei, Y., Wang, Y., Huang, D., 2010. Forecasting Crude Oil Market Volatility: Further Evidence Using GARCH-Class Models, *Energy Economics*. 32(6), 1477-1484.
- White, H., 2000. A Reality Check for Data Snooping, *Econometrica*. 68(5), 1097-1126.
- Xu, B., Ouenniche, J., 2012. A Data Envelopment Analysis-Based Framework for the Relative Performance Evaluation of Competing Crude Oil Price Volatility Forecasting Models, *Energy Economics*. 34(2), 576-583.