

# Modelación y predicción de la volatilidad con innovaciones de colas pesadas distribuidas: evidencia empírica para los petróleos Maya y Mezcla Mexicana de Exportación

RAÚL DE JESÚS GUTIÉRREZ Y LIDIA CARVAJAL GUTIÉRREZ\*

## RESUMEN

El objetivo de este trabajo es evaluar la capacidad predictiva de una familia de modelos GARCH para predecir la volatilidad condicional de los rendimientos del petróleo Maya y Mezcla Mexicana de Exportación para el periodo 2 de enero de 1989 al 30 de diciembre de 2011. Los modelos de volatilidad se estimaron bajo tres distribuciones condicionales para las innovaciones: normal,  $t$ -student y errores generalizada. Los hallazgos empíricos señalan que el modelo EGARCH, con innovaciones  $t$ -student es más eficiente en el proceso de predicción de la volatilidad dentro de la muestra que los modelos basados en las distribuciones de errores generalizada y normal. Sin embargo, los resultados de la prueba de Diebold-Mariano muestran que los modelos CGARCH, con innovaciones de errores generalizados y normales, superan el desempeño predictivo óptimo de los modelos GARCH con innovaciones  $t$ -student cuando se consideran las predicciones de la volatilidad fuera de la muestra.

**Palabras clave:** Petróleo crudo, Predicción de la volatilidad, Distribuciones de colas pesadas, Prueba de Diebold-Mariano.

**Clasificación JEL:** Q40, C32, C52, E30.

---

\* Profesores-investigadores de tiempo completo de la Facultad de Economía de la UAEM. Dirección: Cerro de Coatepec, s/n. Ciudad Universitaria. C. P. 50110, Toluca, Estado de México, México. Correo electrónico: rjg2005mx@yahoo.com.mx y lcarvajal\_2000@yahoo.com, respectivamente. Teléfonos: (722) 214 94 11 y 213 13 74, ext. 160.

## ABSTRACT

### **Volatility modeling and forecasting with independent and identically distributed heavy-tailed innovations: Empirical evidence for Maya and Export Mexican crude oil blends.**

The purpose of this article is to evaluate the predictive ability of a GARCH-class model family to forecast the conditional volatility of Maya and Export Mexican Blend crude oil returns over the period from January 2, 1989 to December 30, 2011. The volatility forecasting models were estimated under three alternative conditional distributions for innovations: normal, student- $t$  and generalized error. The empirical findings suggest that the EGARCH model with student- $t$  innovations is more efficient in the procedure of the in-sample volatility forecast than the competing models based on the generalized error and normal distributions. However, the results of Diebold-Mariano test show that the CGARCH models driven by generalized error and normal distributed innovations outperform the optimal predictive performance of the GARCH models with student- $t$  innovations when the out-of-sample volatility forecasts are considered.

**Keywords:** Crude oil, Volatility forecast, Heavy-tailed distributions, Diebold-Mariano test.

## INTRODUCCIÓN

En las últimas dos décadas los mercados de energía han mantenido un crecimiento continuo, a tal grado de consolidarse en un mercado financiero sofisticado, en parte atribuido al sólido y constante crecimiento económico global y cambio en la estructura de empleo de petróleo de los consumidores industriales, principalmente por las economías emergentes de China y la

India.<sup>1</sup> Asimismo, factores adicionales como la ininterrumpida depreciación del dólar estadounidense en relación con el euro,<sup>2</sup> el papel de la Reserva Federal de los Estados Unidos (FED, por sus siglas en inglés), la presencia de la creciente especulación, la desregulación, las características y mecanismos de mercado no sólo han sido fundamentales para estimular relativamente la volatilidad en los mercados internacionales del petróleo, sino también para generar niveles de fluctuaciones extremas en los precios de los combustibles fósiles en el corto y mediano plazo. En este contexto, existe bastante literatura empírica que ha estudiado los efectos positivos y negativos de las fluctuaciones en los precios del petróleo en las principales variables macroeconómicas de los países importadores y exportadores de crudo y, por ende, sus significativas consecuencias en la economía global y los mercados financieros internacionales (Hamilton, 1983; Mork, 1989; Lee *et al.*, 1995; Ferderer, 1996; Huntington, 1998; Sadorsky, 1999; Chen y Chen, 2007; Cologni y Manera, 2009; Narayan y Nayaran, 2010; Filis *et al.*, 2011; Estrada y Hernández, 2012).

Desde una perspectiva económica-financiera, la compleja dinámica no-lineal de los precios del petróleo y su volatilidad en la economía global son de vital importancia para los productores, consumidores industriales, compañías refinadoras de gasolina y gas, autoridades gubernamentales e inversionistas. Una mejor percepción de la evolución de la volatilidad cambiante en el tiempo permite a los participantes en los mercados de energía generar información crucial que pueden aprovechar para reducir

---

<sup>1</sup> De acuerdo con las estadísticas de energía mundial de British Petroleum (2012), el consumo de petróleo por parte de China e India en 2011 equivale a 9 758 y 3 473 miles de barriles diarios en promedio, aproximadamente, lo cual representa incrementos de 5.48 y 4.23% respecto a 2010. Mientras que el consumo del hidrocarburo en países desarrollados como EE.UU. y Alemania disminuyó en 1.80 y 3.39%, respectivamente.

<sup>2</sup> Con referencia a la relación petróleo-tipo de cambio nominal, Reboredo (2012) señala que un dólar débil incrementa el poder adquisitivo de compra de los países importadores de petróleo, excepto para EE.UU. En tanto que afecta negativamente a los países exportadores de petróleo, al depreciar sus tipos de cambio nominales cuando los precios del producto descienden.

la exposición al riesgo de precio, particularmente en el contexto de movimientos atípicos inesperados durante las recientes décadas. Asimismo, la modelación y predicción de la volatilidad en los rendimientos del petróleo juega un rol clave en el proceso de la toma de decisiones financieras relacionadas con la valuación de productos derivados energéticos, la creación de estrategias de cobertura óptima, la inversión de portafolio, la predicción futura de la tendencia de los precios de contado y la administración de riesgos.

En consecuencia, se pueden encontrar en la literatura sobre el análisis de la modelación y predicción de la volatilidad condicional varios modelos alternativos. Sin embargo, la flexibilidad y popularidad del modelo de heteroscedasticidad condicional autorregresiva generalizado, o modelo GARCH, propuesto en el trabajo seminal de Bollerslev (1986) y sus diferentes variantes, han sido utilizados para estudiar las características de la volatilidad condicional observadas en los mercados internacionales del petróleo crudo, entre ellas la volatilidad de corto plazo o en aglomeraciones, los efectos de apalancamiento o asimétricos, cambios estructurales, la persistencia de la memoria larga en la volatilidad y el efecto de las colas pesadas o anchas. En Morana (2001), por ejemplo, una forma alternativa de predecir en el corto plazo las tendencias futuras de los precios del crudo Brent de Londres del Mar del Norte es a través de las propiedades de los modelos GARCH semiparamétricos. Basado en un modelo general de cambio de régimen construido sobre una especificación GARCH estándar, Fong y See (2002) indagaron el comportamiento temporal de la volatilidad en los futuros sobre el petróleo crudo estadounidense West Texas Intermediate (WTI). Los hallazgos empíricos mostraron la capacidad del modelo para capturar las características complejas exhibidas en la volatilidad condicional, como cambios inesperados en la media, varianza y curtosis condicional, así como un alto desempeño en la predicción de la volatilidad en periodos de corto plazo.

Un estudio interesante que utiliza una variedad de modelos estadísticos, univariados y multivariados, para la predicción de la volatilidad condicional de varios contratos de futuros sobre energía que cotizan en la Bolsa Mercantil de Nueva York, es el de Sadorsky (2006). De acuerdo con los resultados de la prueba estadística de predicción óptima, el modelo  $TGARCH$  presenta un desempeño superior para predecir la volatilidad condicional en los futuros sobre gas natural y aceite de calefacción. Por su parte, el modelo  $GARCH$  estándar tiene capacidad predictiva superior para estimar la volatilidad cambiante en el tiempo en los mercados de futuros sobre petróleo crudo  $WTI$  y gasolina en comparación con el desempeño de los modelos de cambio de régimen,  $VAR$  y  $GARCH$  bivariados. En este contexto, Wang y Wu (2012) también analizan la significancia de la diferencia de los errores de predicción de dos modelos, estimando especificaciones  $GARCH$  univariados y multivariados; sus resultados empíricos sustentan que los modelos  $BEKK$  (completo, diagonal y escalar) presentan un óptimo desempeño para predecir la volatilidad fuera de la muestra en comparación con el modelo  $GARCH(1,1)$  estándar, pero su capacidad predictiva es reducida por los modelos asimétricos de volatilidad univariados. Ajustando un modelo  $EGARCH$ , Nayaran y Nayaran (2007) argumentan que los choques en el precio del petróleo tienen efectos permanentes y asimétricos sobre la volatilidad condicional en la muestra completa. En contraste, los choques positivos y negativos presentan efectos similares, en términos de magnitud, sobre la volatilidad en los periodos submuestrales.

En cuanto al poder predictivo de los modelos  $GARCH$ , para describir las características de la volatilidad condicional basadas en la prueba estadística de Diebold y Mariano (1995), Kang *et al.* (2009) proporcionan evidencia empírica de la capacidad de los modelos  $CGARCH$  y  $FIGARCH$  para capturar la persistencia en la volatilidad de los tres mercados internacionales del petróleo

(WTI, Brent y Dubái)<sup>3</sup> en comparación con los modelos GARCH estándar e integrado. Asimismo, Wei *et al.* (2010) extienden el trabajo de Kang *et al.* (2009), estimando varias clases de modelos GARCH<sup>4</sup> para ilustrar los principales hechos estilizados de la volatilidad dinámica en los mercados de crudo de tipo Brent y WTI. Los resultados de la prueba de capacidad predictiva superior de Hansen (2005) muestran que ningún modelo destaca en la precisión de la predicción de la volatilidad, aunque la familia de modelos GARCH no-lineales son más eficientes para capturar la volatilidad de largo plazo que los lineales. Finalmente, Xu y Ouenniche (2012) proponen el análisis de datos envolventes para evaluar la capacidad predictiva de dos familias de modelos –volatilidad histórica y GARCH– utilizando diversos criterios de evaluación. Sus resultados empíricos indican que el modelo de promedios móviles simple presenta el mejor desempeño en la predicción de la volatilidad del petróleo WTI.

En el marco de la pertinencia de los cambios estructurales, por ejemplo, Nomikos y Poulialis (2011) señalan que el modelo GARCH con cambio de régimen tiene mayor capacidad para predecir la volatilidad condicional en los mercados de futuros del petróleo crudo WTI, Brent aceite de calefacción y gas negociados en las Bolsas de Futuros de Nueva York (NYMEX, por sus siglas en inglés) e Intercontinental (ICE, por sus siglas en inglés). Aurori *et al.* (2012) analizan el impacto de los cambios estructurales en la predicción de la volatilidad condicional en los precios de contado y futuros, del petróleo y sus derivados refinados. Sus resultados empíricos son opuestos a los de Sadorsky (2006), puesto que el modelo

---

<sup>3</sup> El petróleo Dubái es el principal marcador de referencia para el petróleo pesado de la región del Golfo Pérsico desde la segunda mitad de la década de los ochenta. Pese a ser un petróleo de baja calidad y de alto contenido en azufre respecto al Brent de Londres, su precio influye en la cotización de los principales crudos de Arabia Saudita, Emiratos Árabes Unidos, Irán, Iraq y Kuwait, miembros de la Organización de Países Exportadores de Petróleo (OPEP), y se negocia en las bolsas de materias primas de Singapur (SIMEX) y Nueva York (NYMEX).

<sup>4</sup> Los modelos de volatilidad utilizados en el análisis incluyen a los modelos GARCH, IGARCH, EGARCH, GARCH-GJR, APARCH, FIGARCH, FIAPARCH y HYGARCH.

FIGARCH tiene, ante la presencia de cambios estructurales, el mejor ajuste en todas las series en comparación con el modelo GARCH estándar.

El grueso de la literatura previa se ha centrado en estudiar el poder predictivo óptimo de la volatilidad fuera de la muestra en los mercados de contado y futuros del petróleo a través de modelos GARCH y bajo el supuesto distribucional de innovaciones normales. Es bien sabido, sin embargo, que el patrón de la dinámica de los precios del petróleo crudo es extremadamente volátil en la actualidad. De hecho, está bien documentado que la naturaleza de las fluctuaciones extremas en los precios del petróleo está asociada no sólo al desequilibrio entre la oferta y demanda en los mercados de energía fósil, sino también a diversos eventos exógenos que corresponden a aspectos de tensiones geopolíticas, conflictos militares, crisis financieras, desastres naturales e incluso de carácter especulativo, por lo que ignorar estos eventos extraordinarios puede traer serias implicaciones en la modelación y predicción de la volatilidad. En consecuencia, la literatura ha sugerido la selección de distribuciones más flexibles para describir las características de las innovaciones de los rendimientos del petróleo caracterizadas por la leptocurtosis.

Existen numerosos estudios empíricos que han extendido los modelos GARCH, con diferentes supuestos distribucionales, para mejorar la modelación y predicción de la volatilidad, entre los que se incluyen a Agnolucci (2009), quien al comparar la capacidad predictiva de los modelos GARCH con la del modelo de volatilidad implícita, obtenida al invertir la fórmula de forma cerrada de Black-Scholes, encontró que los modelos GARCH con distribución de errores generalizada proporcionan el mejor desempeño para modelar y predecir la volatilidad de los futuros sobre el petróleo WTI. Analizando la capacidad de predicción óptima de una familia de modelos de volatilidad –GARCH estándar, EGARCH, APARCH y FIGARCH– con innovaciones *t*-student y evaluados bajo tres funciones de pérdidas, Cheong (2009) encontró evidencia, aunque no contundente, de que las

especificaciones en la varianza condicional más simples y parsimoniosas presentan el mejor ajuste fuera de la muestra para el petróleo tipo Brent. Utilizando precios semanales de contado de 11 mercados internacionales de países exportadores e importadores de petróleo, cuatro funciones de pérdidas y pruebas estadísticas, Mohammadi y Su (2010) comparan el desempeño de cuatro clases de modelos GARCH basados en la distribución de innovaciones  $t$ -student sesgada. Los resultados de la evaluación evidencian 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 E INTEGRADO FRACCIONARIAMENTE (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 negociados en la Bolsa Mercantil de Nueva York. Los resultados del análisis fuera de la muestra sustentan que el modelo GARCH basado en la distribución de errores generalizada alcanza una excelente predicción óptima 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 una distribución para describir las innovaciones en los rendimientos del petróleo de tipo WTI y Brent, Hou y Suardi (2012) proponen un modelo GARCH no-paramétrico que mejora notablemente la capacidad predictiva fuera de la muestra 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. Estimando un modelo EGARCH bajo régimen de volatilidad cambiaria y asumiendo que las innovaciones siguen una distribución  $t$ -student, Chang (2012) demostró que el impacto de los cambios de régimen y los efectos de la base asimétrica juegan un papel importante en la predicción de la volatilidad en los rendimientos de los futuros sobre el petróleo WTI.

En cuanto a la literatura sobre la medición del riesgo en los mercados de energía, Giot y Laurent (2003) contrastaron la



capacidad predictiva de los modelos RiskMetrics con innovaciones normales, ARCH y APARCH con innovaciones  $t$ -student sesgada para seis materias primas, entre ellas los tipos de petróleo WTI y Brent. Los hallazgos empíricos indican que el modelo APARCH ofrece el mejor desempeño de predicción en todas las series financieras, aunque cabe destacar que el modelo ARCH proporciona buenos resultados y su estimación es fácil de implementar en la práctica.<sup>5</sup> Ajustando un modelo GARCH con distribución de errores generalizada para las innovaciones en los rendimientos de los precios de contado del petróleo WTI y Brent, Fan *et al.* (2008) señalan que en un nivel de confianza de 99%, la medida Valor en Riesgo (var, por sus siglas en inglés), basada en el modelo GARCH con innovaciones de colas pesadas, proporciona estimaciones más robustas del riesgo de mercado que los modelos paramétricos tradicionales y simulación histórica filtrado ARMA. El trabajo de Huang *et al.* (2008) estudia el proceso de innovaciones de colas pesadas en la estimación del riesgo de los precios de contado de cinco materias primas de energía. Sus resultados empíricos muestran que el modelo GARCH con distribución de colas pesadas es más eficiente en la estimación del var que los modelos GARCH con innovaciones normales y  $t$ -student para cualquier nivel de confianza. Aloui y Mabrouk (2010) incorporan tres distribuciones alternativas para las innovaciones<sup>6</sup> a una familia de modelos de volatilidad que incluyen los modelos FIGARCH, FIAPARCH y HYGARCH, y encuentran evidencia de que bajo una distribución de innovaciones  $t$ -student sesgada, el modelo FIAPARCH es la mejor aproximación para predecir la volatilidad y estimar el var para las posiciones, corta y larga, en los mercados internacionales del petróleo y gasolina. Asimismo, los hallazgos de Cheng y Hung (2011) también sustentan el potencial de la distribución  $t$ -student sesgada para

---

<sup>5</sup> La estimación del modelo ARCH con distribución  $t$ -student sesgada en los residuales no requiere de procedimientos de optimización no-lineal, incluso puede programarse en una hoja de Excel.

<sup>6</sup> La familia de distribuciones utilizadas en el análisis de comparación de los modelos GARCH incluyen a la normal,  $t$ -student y  $t$ -student sesgada.

describir la volatilidad en los mercados de contado y futuros del petróleo WTI, caracterizados por los diferentes niveles de asimetría y leptocurtosis.

Dado que la literatura empírica previa ha confirmado –aunque con evidencia empírica mixta– que las distribuciones de innovaciones no-normales poseen características más flexibles y eficientes para capturar la ocurrencia de fluctuaciones extremas en el marco de la modelación y predicción de la volatilidad en los mercados globales del petróleo de alta calidad. El objetivo de este trabajo es evaluar la capacidad predictiva de una familia de modelos GARCH para describir las características de la volatilidad en los mercados de energía de baja calidad y alto contenido de azufre, entre ellas la heteroscedasticidad condicional, los efectos de apalancamiento o asimétricos, la dinámica de largo plazo en la volatilidad, también conocida como memoria larga, y las innovaciones de colas pesadas. Esta investigación difiere de la literatura existente en al menos tres puntos. En primer lugar, y con el fin de conducir el análisis de las propiedades de la volatilidad condicional durante el periodo del 2 de enero de 1989 al 30 de diciembre de 2011, se utilizan los precios diarios de cierre de los petróleos mexicanos de tipo Maya y Mezcla Mexicana de Exportación. En segundo lugar, se estiman cuatro modelos de volatilidad: GARCH estándar, EGARCH, GARCH-GJR y CGARCH, adoptando tres diferentes distribuciones de innovaciones normal, *t*-student y de errores generalizada. Cabe resaltar que esta familia de modelos de volatilidad nunca ha sido aplicada a tipos de petróleo de baja calidad y alto contenido de azufre.

Finalmente, la evaluación de la capacidad de los modelos para predecir la volatilidad es otra de las contribuciones importantes de la investigación. El periodo de análisis incluye la gran recesión de 2008-2009 originada por la crisis subprime y la crisis de deuda soberana de la zona euro de 2010-2011. Además, la predicción óptima fuera de la muestra se lleva a cabo sobre horizontes de 1, 5 y 20 días de operación bajo tres funciones de pérdidas robustas y la prueba estadística de Diebold y Mariano (1995).

El resto del trabajo está estructurado de la siguiente forma: en la sección 1 se discute la fuente de los datos y su análisis preliminar. En la sección 2 se describen las características de los modelos GARCH y la Prueba de Diebold-Mariano. En la sección 3 se lleva a cabo la aplicación empírica a las series de los rendimientos de los precios del petróleo doméstico. En la sección 4 se discuten las principales conclusiones de los hallazgos empíricos.

## **1. FUENTE DE LOS DATOS Y ANÁLISIS PRELIMINAR**

### *1.1. Datos*

En años recientes la demanda de petróleo crudo de baja calidad y alto contenido de azufre ha aumentado en el mercado global, en parte alimentado por los cambios en el incremento desmedido de la demanda de energía global, la disminución significativa en el volumen de la oferta de petróleo crudo en las áreas de extracción de América del Norte (WTI), Europa (Brent) y Asia (Dubái), así como regulaciones ambientales laxas. Este trabajo utiliza dos conjuntos de datos para el análisis de la volatilidad condicional en el mercado mexicano del petróleo. Los precios diarios de los crudos de tipo Maya y Mezcla Mexicana de Exportación, que cubren el periodo del 2 de enero de 1989 al 30 de diciembre de 2011, totalizan 5 968 observaciones. Las series de precios se obtuvieron de la base de datos de Datastream.

### *1.2. Análisis preliminar de los datos*

La gráfica 1 muestra la tendencia dinámica de los dos tipos de petróleo mexicano durante el periodo de estudio analizado, en el que alcanzó precios de contado entre 5.80-130.46 dólares por barril para el Maya, y 7.07-132.38 dólares por barril para la Mezcla Mexicana de Exportación. Aunque existen diferencias en los


precios entre ambos tipos de petróleo, su comportamiento es muy similar a través del tiempo.

Al igual que los mercados internacionales de petróleo, la naturaleza de los choques positivos y negativos en los precios de los crudos nacionales también ha sido estimulada por eventos económicos y políticos. Por ejemplo, el estallido del conflicto en el Golfo Pérsico entre Kuwait e Irak, en agosto de 1990, generó incertidumbre en los precios del petróleo, pero la liberalización de Kuwait, aunada a las políticas de uso racional de energía, regresó la estabilidad a los mercados de materias primas de energía en el periodo 1991-1997. Otros eventos significativos que afectaron negativamente la tendencia de la cotización del petróleo Maya y la Mezcla Mexicana de Exportación fueron la tensión en Medio Oriente y la crisis asiática de 1997-1998. Sin embargo, desde el conflicto militar entre Estados Unidos e Irak, en 2003, los precios de contado del petróleo Maya y Mezcla Mexicana de Exportación jamás regresaron a los niveles de 1998, alcanzando en julio de 2008 precios históricos nunca antes registrados, 130.46 y 132.38 dólares por barril, respectivamente. No obstante, este periodo de tendencia alcista en el precio del petróleo se vio interrumpido por el desplome espectacular a fines de diciembre de 2008, 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 2009, otra tendencia alcista de largo plazo en el precio del petróleo se observó en el periodo 2010-2011, atribuido a los disturbios en Libia e inestabilidad política en Egipto.

Dado que los precios diarios del petróleo Maya y Mezcla Mexicana se caracterizan por ser series no estacionarias, para fines del 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,  $r_t = 100 \ln (P_t / P_{t-1})$ . La gráfica 2, que muestra la dinámica de los rendimientos de ambos tipos de petróleo a través del tiempo, indica la existencia de fuerte

evidencia de volatilidad en aglomeraciones o periodos de alta volatilidad, seguido de lapsos de relativa tranquilidad. La intensidad del fenómeno de la heteroscedasticidad condicional es más pronunciada en los periodos de la guerra del Golfo Pérsico de 1991, la crisis asiática de 1997-1998 y la recesión económica de Estados Unidos en 2008-2009, en donde los rendimientos experimentaron una sucesión de movimientos atípicos, positivos y negativos, en cortos intervalos de tiempo.

Gráfica 1  
COMPORTAMIENTO DE LOS PRECIOS DEL PETRÓLEO MAYA Y MEZCLA MEXICANA




Fuente: elaboración propia con información de la base de datos de Datastream.

Las estadísticas básicas de los rendimientos para los dos tipos de petróleo son reportadas en el cuadro 1. Los rendimientos promedios son muy parecidos para ambas series; no obstante, la desviación estándar para los rendimientos del petróleo de tipo Maya es ligeramente más grande a la de la Mezcla Mexicana de Exportación (46.70% contra 42.02% anualizada). Las series de los rendimientos son negativamente sesgadas y exhiben exceso de curtosis, esto es, propiedades de colas más pesadas, o anchas, y largas que la distribución normal, particularmente la cola izquierda. De hecho, el valor negativo del coeficiente sesgo revela que los rendimientos extremos negativos tienen mayor probabilidad de ocurrir que los rendimientos extremos positivos.

Gráfica 2

RENDIMIENTOS DE LOS PRECIOS DEL PETRÓLEO MAYA Y MEZCLA MEXICANA



Fuente: elaboración propia con información de la base de datos de Datastream.

**Cuadro 1**  
RESULTADOS DE LAS ESTADÍSTICAS BÁSICAS DE LOS RENDIMIENTOS DEL PETRÓLEO

Petróleo	Media	Máximo	Mínimo	Desv.Est	Sesgo	Curtosis	JB	LM
Maya	0.0363	24.7612	-60.6993	2.9420	-1.5180	40.0133	342904(0)	295.19(0)
Mezcla	0.0362	23.6887	-53.7265	2.6473	-1.4073	34.5130	317100(0)	295.24(0)

Nota: Las estadísticas básicas son expresadas en porcentajes para el periodo del 2 de enero de 1989 al 30 de diciembre de 2011. *Desv. Est.* representa la desviación estándar de los rendimientos. *JB* es el valor del estadístico Jarque-Bera de la prueba de normalidad y *LM* indica el valor del estadístico de la prueba del Multiplicador de Lagrange con valores-*p* entre paréntesis.

Fuente: Estimaciones propias.

Asimismo, el valor-*p* del estadístico Jarque-Bera indica que la hipótesis nula de normalidad es ampliamente rechazada en un nivel de significancia de 1%. La presencia de fuerte heteroscedasticidad condicional o efectos ARCH en ambas series de rendimientos del petróleo es sustentada por la significancia del estadístico de la prueba del Multiplicador de Lagrange a un nivel de 5% para 12 rezagos.

### *1.3. Variable proxy para la volatilidad actual*

La evaluación del poder predictivo de los modelos de volatilidad está basada en los errores de predicción entre la volatilidad estimada y la volatilidad actual (diaria). Sin embargo, la volatilidad actual es una variable no observable que requiere ser estimada por una *proxy*. En este contexto, la literatura empírica ha utilizado los rendimientos cuadrados de los precios del petróleo como *proxy* de la volatilidad actual o no observable. Pese a que esta variable *proxy* se caracteriza por ser un estimador insesgado, la presencia de ruido o inestabilidad en los rendimientos cuadrados es muy alta para observar el proceso de la volatilidad actual, debido a las características de los rendimientos de los precios del

petróleo (Andersen y Bollerslev, 1998). La representación gráfica de las dos series de los rendimientos cuadrados de los precios del petróleo nacional se muestra en la gráfica 3, en donde se puede observar que su comportamiento tiende a ser muy variable o ruidoso como consecuencia de los movimientos atípicos observados en los rendimientos de los precios del petróleo, particularmente durante la etapa de la gran recesión económica de Estados Unidos en el periodo 2008-2009.

En consecuencia, otras alternativas recomendadas por la literatura es el uso de datos de frecuencia alta y la estimación basada en el rango máximo/mínimo como variable *proxy* para la volatilidad actual. Estos estimadores suelen ser insesgados y más eficientes que los rendimientos cuadrados; sin embargo, su principal desventaja es que no sólo requieren de precios intradía, sino también de precios de apertura, cierre, máximo y mínimo, los cuales no están disponibles para los tipos de petróleos nacionales. Además, Xu y Ouenniche (2012) señalan que el potencial de estas variables *proxy* se reduce cuando la distribución de rendimientos es asimétrica o no-normal.

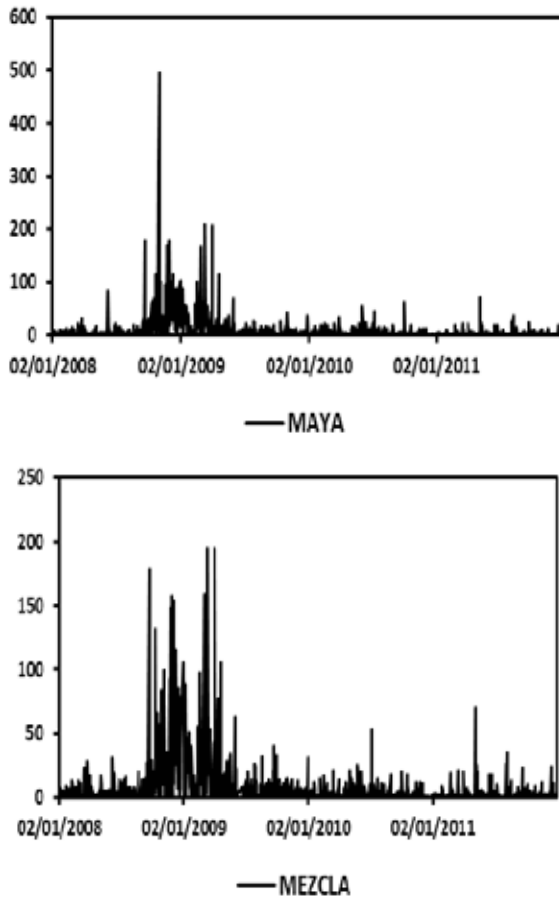
En conclusión, el análisis preliminar de los datos sugiere el uso de procesos GARCH y la incorporación de distribuciones de colas pesadas en la modelación y predicción de la volatilidad condicional en las innovaciones de los rendimientos de los precios del petróleo mexicano.

## **2. MODELOS GARCH CON DISTRIBUCIONES DE COLAS PESADAS ALTERNATIVAS**

En esta sección se describe a una familia de modelos GARCH univariados con innovaciones normales, *t*-student y errores generalizados para modelar y predecir la volatilidad condicional de los rendimientos de los precios del petróleo Maya y Mezcla Mexicana de Exportación.



Gráfica 3  
VOLATILIDAD ACTUAL DE LOS RENDIMIENTOS DEL PETRÓLEO MAYA Y MEZCLA MEXICANA



Fuente: elaboración propia con información de la base de datos de Datastream.

### 2.1. Modelo GARCH estándar

Tradicionalmente, el modelo GARCH (1,1) estándar ha sido utilizado para capturar el efecto de la volatilidad en aglomeraciones en los rendimientos de las series financieras a través de la varianza condicional como una función lineal de la información pasada. El modelo GARCH (1,1) estándar está definido por dos ecuaciones

$$r_t = \mu_t + \varepsilon_t = \mu_t + \sigma_t z_t \quad (1)$$

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (2)$$

donde  $\mu_t$  representa la media condicional;  $\varepsilon_t$  indica las innovaciones en la ecuación de la media;  $\sigma_t^2$  es la varianza condicional que depende de la última innovación de los residuales cuadrados  $\varepsilon_{t-1}^2$ , comúnmente conocido como el efecto ARCH o persistencia de corto plazo, y la varianza condicional previa  $\sigma_{t-1}^2$ ,  $z_t$  es un proceso de ruido blanco que sigue una distribución normal con media cero y varianza uno;  $\omega$  es un término determinístico en la ecuación de la varianza que indica que la volatilidad condicional debe converger a un valor positivo. Para evitar estimaciones negativas en la varianza condicional y la existencia del proceso GARCH, los parámetros  $\omega$ ,  $\alpha$  y  $\beta$  deben ser estrictamente positivos. Además, la suma  $\alpha + \beta < 1$  es una condición suficiente para asegurar que el proceso GARCH (1,1) sea estrictamente estacionario y ergódico.

## 2.2. Modelos GARCH asimétricos

La presencia de diferentes niveles de asimetría en las series de los rendimientos ha dado la pauta para introducir otra clase de modelos de volatilidad. De esta manera, para resolver el problema de los efectos de apalancamiento o asimétricos observados en los rendimientos de los tipos de petróleo crudo nacional, esta investigación usa el modelo GARCH exponencial (EGARCH) propuesto por Nelson (1991).

La especificación de la varianza condicional se puede expresar de la siguiente forma:

$$\log(\sigma_t^2) = \omega + \alpha \frac{|\varepsilon_{t-1}|}{\sigma_{t-1}} + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + \beta \log(\sigma_{t-1}^2) \quad (3)$$

A diferencia del modelo GARCH (1,1) estándar, no hay necesidad de restringir los parámetros estimados  $\omega$ ,  $\alpha$  y  $\beta$  para asegurar que la varianza condicional sea positiva. El parámetro  $\gamma$  captura el comportamiento asimétrico de los choques negativos y positivos en la volatilidad condicional, cuyo efecto de apalancamiento es más bien exponencial que cuadrático. Para  $\gamma < 0$ , las implicaciones económicas son que las innovaciones negativas (noticias malas) tendrán un impacto mayor en la volatilidad condicional futura que las innovaciones positivas (noticias buenas) de la misma magnitud. Finalmente, las condiciones de proceso estacionario y ergódico son alcanzadas por el modelo EGARCH (1,1) cuando  $|\beta| < 1$ . Otra especificación alternativa que permite capturar los efectos de apalancamiento en la volatilidad es el modelo GARCH-GJR (1,1) desarrollado por Glosten, Jagannathan y Runkle (1993).

La ecuación de la varianza condicional del modelo GARCH-GJR (1,1) está definida por

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \gamma I(\varepsilon_{t-1} < 0) \varepsilon_{t-1} + \beta \sigma_{t-1}^2 \quad (4)$$

donde  $I(\bullet)$  es la función indicadora de Heaviside que se activa con valor igual a 1 cuando  $\varepsilon_{t-1} < 0$  y cero en cualquier otro caso, implicando que las noticias catastróficas tienen un impacto de  $\alpha + \gamma$  sobre el coeficiente de  $\varepsilon_{t-1}^2$ , mientras que el impacto de las noticias optimistas depende únicamente del parámetro  $\alpha$ . Por lo que el efecto de apalancamiento es observado si  $\gamma > 0$  a diferencia del modelo EGARCH (1,1), en donde dicho parámetro debe ser negativo. Para garantizar una varianza positiva, todos los parámetros estimados en la especificación de la varianza condicional deben ser estrictamente mayores o iguales a cero como en el caso del modelo GARCH (1,1) estándar.

### 2.3. Modelo GARCH de dos componentes

La dependencia de largo plazo o memoria larga observada en la volatilidad de las series financieras ha sido documentada en una gran cantidad de estudios empíricos. Es bien sabido que la propiedad de memoria larga no puede ser recogida por los modelos GARCH tradicionales, mencionados en las secciones 2.1 y 2.2, por lo que tiene que modelarse con un componente de largo plazo. Una especificación alternativa que captura el fenómeno de la memoria larga en la volatilidad es el modelo de dos componentes o CGARCH propuesto por Engle y Lee (1999).

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

$$\sigma_t^2 = \sigma_{t,1}^2 + \sigma_{t,2}^2 \quad (5)$$

$$\sigma_{t,1}^2 = \omega + \alpha_1 v_{t-1} + \beta_1 \sigma_{t-1,1}^2 \quad (6)$$

$$\sigma_{t,2}^2 = \alpha v_{t-1} + \beta \sigma_{t-1,2}^2 \quad (7)$$

$$v_{t-1} = \varepsilon_{t-1}^2 - \sigma_{t-1}^2 \quad (8)$$

donde el primer componente  $\sigma_{t,1}^2$  captura el impacto de largo plazo en la varianza, los errores de predicción pasados, representados por  $v_{t-1}$ , proporcionan la fuerza principal en los movimientos dependientes en el tiempo de la varianza de largo plazo. El segundo componente  $\sigma_{t,2}^2$  recoge los efectos temporales de corto plazo de los choques en la varianza. El modelo garantiza una varianza positiva si sus parámetros satisfacen las condiciones  $\alpha + \beta < \beta_1 < 1$ ,  $\alpha_1 < \beta$  y la tasa de reversión a la media del segundo componente es menor a la tasa del primer componente; es decir,  $\omega / (1 - \beta_1)$ . De esta manera, la reacción en cada uno de los componentes ante una innovación reciente es diferente y con una tasa de decaimiento distinta, puesto que están asociadas a las innovaciones de las varianzas rezagadas.

Para capturar las características no-normales en las innovaciones de los rendimientos de los precios de los petróleos nacionales, se

asume que las innovaciones siguen también una distribución  $t$ -student y una distribución de errores generalizada.

Las funciones de densidad de probabilidad de la distribución  $t$ -student y la distribución de errores generalizada se pueden expresar como

$$f(\varepsilon_t) = \frac{\Gamma(\frac{1}{2}(v+1))}{\Gamma(\frac{1}{2}v)\sqrt{\pi(v-2)}\sigma_t^2} \left[ 1 + \frac{\varepsilon_t^2}{(v-2)\sigma_t^2} \right]^{-\frac{1}{2}(v+1)} \quad (9)$$

$$f(\varepsilon_t) = \frac{\nu \exp\left(-\frac{1}{2} \left| \frac{\varepsilon_t}{\lambda\sigma_t} \right|^\nu\right)}{\lambda\sigma_t 2^{\frac{\nu+1}{\nu}} \Gamma\left(\frac{1}{\nu}\right)} \quad (10)$$

donde  $\nu$  es el parámetro de forma o grados de libertad y  $\lambda = \left(\frac{2^{-2/\nu} \Gamma(1/\nu)}{\Gamma(3/\nu)}\right)^{1/2}$ .

#### 2.4. Medidas de evaluación predictiva

Existen diferentes criterios para la evaluación predictiva de los modelos de volatilidad, entre las medidas más comunes se encuentran las funciones de pérdidas. Para el análisis de la volatilidad fuera de muestra utilizamos los estadísticos QLIKE, error cuadrado medio (MSE) y error absoluto medio (MAE).<sup>7</sup>

<sup>7</sup> Ante la presencia de ruido en la volatilidad actual, Patton (2011) demostró analíticamente que las funciones de pérdidas más robustas en la minimización del error de predicción son el error cuadrado medio (MSE) y el QLIKE.

Los estadísticos de predicción óptima asociados a la volatilidad condicional se definen como

$$\text{QLIKE} = \frac{\sum_{t=1}^T \left( \ln(\sigma_{\text{estimada},t}^2) + \frac{\sigma_{\text{actual},t}^2}{\sigma_{\text{estimada},t}^2} \right)}{T} \quad (11)$$

$$\text{MSE} = \frac{\sum_{t=1}^T (\sigma_{\text{actual},t}^2 - \sigma_{\text{estimada},t}^2)^2}{T} \quad (12)$$

$$\text{MAE} = \frac{\sum_{t=1}^T |\sigma_{\text{actual},t}^2 - \sigma_{\text{estimada},t}^2|}{T} \quad (13)$$

donde  $T$  es el número de predicciones fuera de la muestra,  $\sigma_{\text{estimada},t}^2$  representa la varianza estimada de cada modelo para el horizonte de tiempo  $t$ , y  $\sigma_{\text{actual},t}^2$  indica la varianza actual sobre el horizonte de tiempo  $t$ .

Las funciones de pérdidas permiten clasificar los modelos de volatilidad con base en la exactitud de la predicción fuera de la muestra. Sin embargo, la capacidad de predicción óptima entre dos modelos de volatilidad no tiene una validación estadística a través de pruebas robustas. Para solucionar este problema, Diebold y Mariano (1995) desarrollaron una prueba estadística que permite comparar dos modelos de volatilidad a través de dos conjuntos de errores de predicción  $e_{1,t}$  y  $e_{2,t}$  para  $t = 1, \dots, n$ . La diferencia entre los errores de predicción de dos modelos de volatilidad puede expresarse como

$$d_t = h(e_{1,t}) - h(e_{2,t}) \quad (14)$$

donde  $h(\cdot)$  es una función asociada a cada una de las funciones de pérdidas.

La media muestral de la diferencia entre los errores de predicción,  $\bar{d}$  se distribuye asintóticamente como  $\sqrt{n}(\bar{d} - \mu) \xrightarrow{d} N(0, \text{Var}(\bar{d}))$ ; es decir,

$$\text{Var}(\bar{d}) \approx \frac{\left( \gamma_0 + 2 \sum_{j=1}^{h-1} \gamma_j \right)}{n} \quad (15)$$

donde  $\gamma_j$  es la  $j$ -ésima covarianza de  $d_t$ , cuya estimación es igual a

$$\hat{\gamma} = \frac{1}{n} \sum_{t=j+1}^n (d_t - \bar{d})(d_{t-j} - \bar{d}) \quad (16)$$

Bajo la hipótesis nula de predicción óptima idéntica o media cero ( $\mu = 0$ ). El estadístico de la prueba de Diebold y Mariano (1995) puede expresarse como

$$\text{DM} = \frac{\bar{d}}{\sqrt{\hat{\text{Var}}(\bar{d})}} \quad (17)$$

donde  $\hat{\text{Var}}(\bar{d})$  es un estimador consistente de la varianza asintótica  $\text{Var}(\bar{d})$  y DM sigue una distribución normal estándar bajo la hipótesis nula, la cual se rechaza cuando el valor del estadístico es negativo y estadísticamente significativo.

### 3. APLICACIÓN A LOS MERCADOS DEL PETRÓLEO DE LA MEZCLA MEXICANA DE EXPORTACIÓN Y MAYA

En esta sección el análisis de la modelación y predicción de la volatilidad condicional para las dos series de rendimientos del petróleo nacional se lleva a cabo en dos etapas: la primera considera el periodo del 2 de enero de 1989 al 31 de diciembre de 2007 para la estimación de los modelos GARCH dentro de la muestra, y la segunda abarca del 2 de enero de 2008 al 30 de diciembre de 2011, usado para la selección del modelo predictivo fuera de la muestra.

### *3.1. Análisis de la volatilidad dentro de la muestra*

Para el ajuste de los modelos de volatilidad se emplea el método de estimación de cuasi-máxima verosimilitud de Bollerslev y Wooldridge (1992), el cual proporciona errores estándar más robustos. Además se utiliza la distribución de errores generalizada y la distribución *t*-student a parte de la normal, dado que las innovaciones en los rendimientos de los precios del petróleo presentan propiedades de colas pesadas o anchas y no siguen una distribución normal.

Los cuadros 2 y 3 presentan las estimaciones de los parámetros de los cuatro modelos GARCH bajo los diferentes supuestos distribucionales para las innovaciones en los rendimientos de los precios del petróleo Maya y Mezcla Mexicana de Exportación, respectivamente, junto con sus pruebas de diagnóstico. Para el caso del petróleo Maya, los parámetros estimados de la especificación de la media condicional son casi todos significativos para los diferentes niveles de significancia, excepto para los modelos GARCH (1,1) y EGARCH (1,1) con innovaciones normales. Asimismo, los 12 modelos GARCH bajo las tres distribuciones alternativas capturan exitosamente los patrones de la volatilidad condicional a través del tiempo, dado que todos los estimadores son estadísticamente significativos en los niveles convencionales.

Por su parte, la volatilidad condicional es muy persistente, como resultado de que los coeficientes de persistencia  $\alpha + \beta$  son menores a uno, excepto para los modelos EGARCH (1,1) bajo los diferentes supuestos distribucionales, aunque los términos GARCH menores a la unidad garantizan aún las condiciones de proceso de volatilidad estacionario y ergódico. En cuanto al coeficiente del impacto asimétrico de las noticias, todos los parámetros estimados  $\gamma$ , con la excepción del modelo GARCH-GJR (1,1) con distribución de errores generalizada, son significativamente diferentes de cero para los diferentes niveles. Este hallazgo indica que la volatilidad condicional responde de diferente manera a los



choques positivos (noticias optimistas) y negativos (noticias pesimistas) de la misma magnitud.

Para los modelos GARCH basados en la distribución  $t$ -student y distribución de errores generalizada, los grados de libertad del parámetro estimado  $\nu$  alcanzan valores más grandes de 4 y 1, respectivamente. Este hecho revela que la distribución de rendimientos de los precios del petróleo de tipo Maya presenta propiedades de colas pesadas. Respecto a los componentes de corto y largo plazo reportados en el cuadro 2, los pequeños valores de los coeficientes de persistencia  $\alpha + \beta$  alcanzados por el modelo CGARCH (1,1), en relación con los de los modelos GARCH (1,1) y GARCH-GJR (1,1), indican la presencia de persistencia más débil en el componente de la volatilidad de corto plazo. Sin embargo, los componentes de largo plazo asociados con el parámetro estimado  $\beta_1$  confirman un alto grado de persistencia en la volatilidad de largo plazo para las innovaciones de los rendimientos del petróleo Maya.

En el proceso de la selección del modelo de volatilidad, los valores pequeños en términos absolutos de los criterios de información de Akaike y Schwarz (AIC y BIC) y Log(L), muestran el potencial del modelo EGARCH (1,1) con innovaciones  $t$ -student para identificar los hechos estilizados de la heteroscedasticidad condicional, la volatilidad en aglomeraciones, la persistencia de los choques e incluso los efectos de apalancamiento, seguido por el modelo CGARCH (1,1). A pesar de que los modelos GARCH (1,1) y GARCH-GJR (1,1) presentan criterios de información de Schwarz más bajos (2.2141 y 2.2146 contra 2.2149). Este hecho se atribuye a que el BIC penaliza a los modelos de volatilidad que estiman parámetros adicionales.

Por su parte, el diagnóstico a través de la prueba de Ljung-Box con 12 rezagos señala que la ecuación de la media condicional en los diferentes modelos GARCH es apropiada para explicar el comportamiento de los rendimientos de los precios del petróleo. Esto obedece a los altos valores- $p$  que rechazan la presencia de correlación serial en los residuales estandarizados simples a un nivel de

Cuadro 2  
ESTIMACIONES PARA EL PETRÓLEO TIPO MAYA

	normal			t-student			dég			
	Garch	Egarch	G/JR	Egarch	G/JR	Cgarch	Garch	Egarch	G/JR	Cgarch
c	0.0432 (0.0282)	0.0304 (0.0286)	0.0511*** (0.0303)	0.0631** (0.0285)	0.0483*** (0.0265)	0.0546** (0.0269)	0.0736* (0.0241)	0.0735* (0.0240)	0.0671* (0.0244)	0.0720* (0.0241)
ω	0.0644* (0.0079)	-0.1027* (0.0036)	0.0862* (0.0081)	0.1025* (0.0206)	-0.0788* (0.0091)	0.1047* (0.0207)	0.0916* (0.0192)	-0.0899* (0.0098)	0.0916* (0.0184)	0.0201 (0.0153)
α	0.0819* (0.0029)	0.1736* (0.0059)	0.0777* (0.0037)	0.0529* (0.0169)	0.1402* (0.0133)	0.0591* (0.0098)	0.0709* (0.0075)	0.1561* (0.0142)	0.0574* (0.0087)	0.0603** (0.0235)
β	0.9115* (0.0034)	0.9877* (0.0011)	0.9099* (0.0035)	0.7397* (0.0080)	0.9876* (0.0027)	0.9178* (0.0080)	0.9180* (0.0080)	0.9688* (0.0029)	0.9201* (0.0078)	0.6790* (0.1820)
α <sub>1</sub>				0.0542* (0.0158)		0.0367* (0.0131)				0.4020* (0.0162)
β <sub>1</sub>				0.9273* (0.0102)		0.9448* (0.0109)				0.9389* (0.0133)
γ		-0.0952* (0.0225)	0.0136** (0.0061)		-0.1617* (0.0610)	0.0248*** (0.0127)		-0.1209** (0.0564)	0.0190 (0.0117)	
α+β	0.9935	1.1613	0.9876	0.7927	1.1278	0.9770	0.9889	1.1429	0.9775	0.7393
ν				4.2059 (0.2577)	4.2746 (0.2572)	4.2143 (0.2578)	1.1033 (0.0219)	1.1012 (0.0214)	1.1176 (0.0217)	1.1073 (0.0218)
				Diagnóstico						
Log(L)	-11387	-11383	-11385	-11384	-11032	-11047	-11065	-11053	-11064	-11062
AIC	2.2782	2.2777	2.2781	2.2780	2.2076	2.2107	2.2141	2.2119	2.2140	2.2139
BIC	2.2808	2.2810	2.2814	2.2819	2.2115	2.2146	2.2173	2.2158	2.2179	2.2184
Q(12)	10.5916 [0.5646]	-10.8631 [0.5409]	10.1731 [0.6007]	10.7121 [0.5542]	10.0809 [0.6092]	9.4425 [0.6649]	10.3381 [0.5924]	10.3661 [0.5841]	9.5130 [0.6586]	10.3954 [0.5819]
Q*(12)	18.5901 [0.9989]	19.2014 [0.0637]	18.5661 [0.9988]	18.1658 [0.1109]	21.3696 [0.0453]	19.0464 [0.0876]	19.3554 [0.0804]	20.6309 [0.0560]	18.7924 [0.0937]	17.6775 [0.1262]

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

significancia de 5%. En el caso de los residuales estandarizados cuadrados, la significancia de los estadísticos de la prueba de Ljung-Box sustenta la capacidad de los modelos GARCH para corregir la correlación serial en la ecuación de la varianza condicional de los rendimientos del petróleo Maya, especialmente la especificación CGARCH (1,1) bajo los diferentes supuestos distribucionales para las innovaciones.

Para los rendimientos de la Mezcla Mexicana de Exportación, los resultados empíricos muestran que todos los parámetros estimados de la especificación de la media y varianza condicional son estadísticamente significativos para los diferentes niveles de significancia. Las únicas excepciones se pueden observar en los modelos GARCH-GJR (1,1) con innovaciones normales y CGARCH (1,1) basadas en la distribución de errores generalizada, en donde el parámetro de la ecuación de la media condicional y el parámetro del término GARCH o componente de persistencia de la ecuación de la varianza condicional no son significativos a un nivel de 1%, respectivamente. Los resultados de los efectos asimétricos sobre la volatilidad condicional son mixtos para la Mezcla Mexicana de Exportación. El coeficiente de respuesta asimétrica de la volatilidad, asociado a las noticias malas y buenas, es negativo y significativo a un nivel de 1% y 10% para el modelo EGARCH (1,1) con innovaciones normales y *t*-student, mientras que para el modelo GARCH-GJR (1,1) con innovaciones normales es positivo y significativo a un nivel del 1%.

Asimismo, la evidencia del fenómeno de las colas pesadas o anchas y la alta persistencia observadas en las innovaciones de los rendimientos de la Mezcla Mexicana de Exportación son sustentadas por los valores del parámetro de forma de las dos distribuciones de colas pesadas y los componentes de la volatilidad de largo plazo. Basado en los valores de la función de verosimilitud y los criterios AIC y BIC, el modelo EGARCH (1,1), con innovaciones *t*-student, continúa siendo la aproximación más eficiente en la descripción de las características de la volatilidad condicional. La hipótesis nula de la confirmación de correlación

Cuadro 3  
ESTIMACIONES PARA EL PETRÓLEO TIPO MEZCLA MEXICANA DE EXPORTACIÓN

	normal			t-student			deg			
	Garch	Egarch	GJ/R	Garch	Egarch	GJ/R	Garch	Egarch	GJ/R	Ggarch
<b>c</b>	0.0452*** (0.0260)	0.0509*** (0.0255)	0.0402 (0.0279)	0.0678* (0.0259)	0.0584** (0.0253)	0.0638** (0.0255)	0.0671* (0.0254)	0.0778* (0.0229)	0.0741* (0.0232)	0.0801* (0.0229)
<b>ω</b>	0.0838* (0.0080)	-0.1039* (0.0039)	0.0890* (0.0088)	0.1402* (0.0136)	-0.0755* (0.0091)	0.1068* (0.0212)	0.0279*** (0.0166)	0.0886* (0.0186)	0.0921* (0.0187)	0.0464*** (0.0242)
<b>α</b>	0.0864* (0.0033)	0.1930* (0.0068)	0.0724* (0.0042)	0.0686* (0.0081)	0.1363* (0.0131)	0.0622* (0.0104)	0.0700* (0.0217)	0.1628* (0.0151)	0.0608* (0.0093)	0.0764* (0.0253)
<b>β</b>	0.9062* (0.0037)	0.9781* (0.0017)	0.9060* (0.0039)	0.7619* (0.0358)	0.9854* (0.0032)	0.9142* (0.0087)	0.5811* (0.1863)	0.9163* (0.0084)	0.9159* (0.0084)	0.3417 (0.2663)
<b>α<sub>1</sub></b>				0.0781* (0.0039)			0.0381* (0.0108)			0.0483* (0.0103)
<b>β<sub>1</sub></b>				0.9114* (0.0040)			0.9428* (0.0101)			0.9330* (0.0102)
<b>γ</b>		-0.0796* (0.0218)	0.0262* (0.0058)			0.0178 (0.0129)		-0.0876 (0.0555)	0.0151 (0.0116)	
<b>α+β</b>	0.9926	1.1712	0.9784	0.8305	0.9864	1.1217	0.6512	0.9866	0.9767	0.4181
<b>v</b>					4.3201 (0.2676)	4.4462 (0.2658)	4.3261 (0.2685)	1.1168 (0.0220)	1.1299 (0.0218)	1.1148 (0.0219)
<b>Diagnóstico</b>										
<b>Log(L)</b>	-10999	-11003	-10998	-10976	-10676	-10675	-10671	-10693	-10692	-10689
<b>AIC</b>	2.2007	2.2017	2.2007	2.1965	2.1362	2.1362	2.1357	2.1397	2.1372	2.1393
<b>BIC</b>	2.2033	2.2050	2.2040	2.2004	2.1394	2.1401	2.1403	2.1429	2.1411	2.1439
<b>Q(12)</b>	7.7660	6.9291	7.4230	7.8092	7.0751	6.8622	7.0475	7.1950	6.5493	7.6025
	[0.8031]	[0.8623]	[0.8285]	[0.7998]	[0.8526]	[0.8666]	[0.8545]	[0.8445]	[0.8859]	[0.8621]
<b>Q*(12)</b>	22.4615	23.5104	22.3321	15.6801	23.1831	22.0240	20.1351	22.3432	22.2809	20.6612
	[0.0326]	[0.0237]	[0.0399]	[0.2063]	[0.0262]	[0.0373]	[0.0646]	[0.0338]	[0.0345]	[0.0556]

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(12) y Q\*(12) indican los estadísticos de la prueba de Ljung-Box para los residuales simples y cuadrados con 12 rezagos y valores-p entre corchetes cuadrados. Los términos \*, \*\*, y \*\*\* indican significancia para los niveles de 1%, 5% y 10%, respectivamente. Los errores estándar se reportan entre paréntesis  
Fuente: estimaciones propias.

serial en los residuales estandarizados simples es imposible aceptarla debido a que los valores- $p$  de la prueba de Ljung-Box son notablemente mayores a cualquier nivel de significancia convencional. Sin embargo, la evidencia de correlación serial en los residuales estandarizados cuadrados puede ser aún encontrada en las especificaciones de la varianza dinámica a un nivel de significancia de 5%, excepto para el modelo CGARCH (1,1) con innovaciones normales.

### *3.2. Evaluación de la predicción óptima fuera de la muestra: metodología y resultados*

Con el fin de evaluar la precisión y eficiencia de los modelos GARCH fuera de la muestra, se utiliza en este estudio el periodo del 2 de enero de 2008 al 30 de diciembre de 2011 para reestimar la varianza condicional a través de una ventana móvil, removiendo la observación más remota y agregando la observación más reciente a la muestra, cuya predicción se compara con la varianza actual para determinar el error de predicción. El proceso es repetido hasta obtener la predicción de la varianza condicional del 30 de diciembre de 2011 para cada horizonte de tiempo. 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.

El cuadro 4 resume los resultados de los estadísticos de los errores de predicción QLIKE, MSE y MAE para los horizontes de 1, 5 y 20 días. Para los rendimientos del petróleo Maya, el modelo CGARCH (1,1) con distribución de errores generalizada (CGARCH-deg) obtiene la clasificación más alta para el horizonte de un día bajo los tres estadísticos de predicción óptima. De hecho, este hallazgo indica claramente la capacidad de los modelos de volatilidad para capturar la leptocurtosis de la distribución empírica de los rendimientos de los precios del petróleo Maya. Sin embargo, la evidencia es mixta para el horizonte de 5 días. El modelo

EGARCH-DEG es favorecido dentro de la clasificación por el estadístico QLIKE, mientras que los modelos EGARCH (1,1) y CGARCH (1,1) con innovaciones normales son preferidos por el MSE y MAE, respectivamente. Para el horizonte de predicción de 20 días, los modelos EGARCH (1,1) con distribución normal proporcionan los mejores resultados bajo los criterios QLIKE y MSE. En tanto que el estadístico MAE prefiere el modelo EGARCH-DEG.

Para el caso de la Mezcla Mexicana de Exportación y el horizonte de un día, los criterios QLIKE y MSE prefieren al modelo CGARCH-N y el modelo CGARCH-DEG es preferido por la función de pérdidas MAE. Por su parte, el modelo CGARCH-N presenta el menor error de predicción para el horizonte de cinco días bajo los tres criterios. Finalmente, el modelo CGARCH-T es seleccionado como *benchmark* por los criterios QLIKE y MSE para un horizonte de predicción de 20 días, mientras que el modelo CGARCH-DEG es mejor clasificado por el criterio MAE.

El cuadro 5 reporta los valores estimados del estadístico de Diebold-Mariano para evaluar el desempeño de los modelos GARCH, usando las diferencias de los errores de predicción de dos modelos de volatilidad bajo las tres funciones de pérdidas. Para el crudo Maya, el modelo CGARCH-DEG, propuesto como *benchmark* y bajo los criterios QLIKE y MAE, tiene el mejor desempeño para predecir la volatilidad condicional fuera de la muestra para el horizonte de un día en comparación con los 11 modelos GARCH, excepto en relación con el modelo CGARCH-N bajo el estadístico QLIKE, aunque es importante resaltar que este modelo sobreestima la volatilidad de las innovaciones del petróleo Maya. No obstante, los valores cercanos a cero del estadístico de Diebold-Mariano señalan que la hipótesis nula de predicción óptima idéntica es fuertemente aceptada bajo el criterio MSE. De hecho, la capacidad predictiva del modelo *benchmark* sólo es superior a dos modelos de volatilidad (GARCH-T y GARCH-DEG). Para el horizonte de predicción de cinco días y bajo el criterio QLIKE, el error de predicción es menor bajo el *benchmark* representado por el modelo EGARCH-DEG en comparación con los modelos alternativos, aunque la predicción óptima idéntica se mantiene respecto al modelo CGARCH-N.

**Cuadro 4**  
**RESULTADOS DE LOS ESTADÍSTICOS DE PREDICCIÓN ÓPTIMA FUERA DE LA MUESTRA**

	1 día			5 días			20 días		
	QLIKE	MSE	MAE	QLIKE	MSE	MAE	QLIKE	MSE	MAE
<b>Panel A: Maya</b>									
Garch-N	2.6384(10)	24.5737(7)	8.7887(8)	2.6589(7)	15.0987(6)	7.6982(9)	2.7423(5)	20.4479(5)	8.8761(7)
Egarch-N	2.6429(11)	24.4835(5)	8.8489(11)	2.6550(5)	<b>14.6702(1)</b>	7.5519(3)	<b>2.7050(1)</b>	<b>20.1981(1)</b>	8.7450(4)
GJR-N	2.6334(8)	24.4262(4)	8.7416(5)	2.6475(4)	15.0521(4)	7.6343(6)	2.7621(10)	20.6087(7)	9.1990(11)
Cgarch-N	2.5980(3)	24.3494(3)	8.5909(3)	2.6246(2)	14.8438(2)	<b>7.5185(1)</b>	2.7348(4)	20.4040(4)	8.7876(5)
Garch-t	2.6283(7)	24.6045(10)	8.8404(10)	2.6760(12)	15.4035(11)	7.8394(12)	2.7601(9)	20.7845(10)	8.9848(9)
Egarch-t	2.6493(12)	24.6056(11)	8.9033(12)	2.6339(3)	15.2159(8)	7.6248(5)	2.7104(3)	20.3389(3)	8.7088(2)
GJR-t	2.6220(6)	24.4956(6)	8.7597(7)	2.6750(11)	15.0854(5)	7.7253(10)	2.7826(12)	20.8474(11)	9.2094(12)
Cgarch-t	2.5775(2)	24.2924(2)	8.5537(2)	2.6641(9)	15.2205(9)	7.6949(8)	2.7494(7)	20.5550(6)	8.7888(6)
Garch-deg	2.6187(5)	24.6190(12)	8.7431(6)	2.6670(10)	15.4333(12)	7.7606(11)	2.7547(8)	20.7752(9)	8.8826(8)
Egarch-deg	2.6363(9)	24.6023(9)	8.7998(9)	<b>2.6243(1)</b>	15.1481(7)	7.5504(2)	2.7054(2)	20.3381(2)	<b>8.6736(1)</b>
GJR-deg	2.6148(4)	24.5839(8)	8.6810(4)	2.6626(8)	14.9326(3)	7.5914(4)	2.7753(11)	20.8806(12)	9.0983(10)
Cgarch-deg	<b>2.5659(1)</b>	<b>24.2789(1)</b>	<b>8.4890(1)</b>	2.6578(6)	15.3686(10)	7.6588(7)	2.7471(6)	20.7019(8)	8.7207(3)
<b>Panel B: Mezcla Mexicana</b>									
Garch-N	2.5410(4)	16.0655(4)	7.5346(7)	2.6520(4)	14.0742(2)	7.4556(5)	2.8332(9)	19.4228(3)	10.0004(4)
Egarch-N	2.5591(7)	16.2224(6)	7.4860(4)	2.6746(6)	14.2715(4)	7.4395(3)	2.8357(10)	19.9884(10)	10.1802(10)
GJR-N	2.5438(5)	16.0992(5)	7.5210(6)	2.6611(5)	14.1962(3)	7.4515(4)	2.8182(5)	19.5455(5)	10.0460(6)
Cgarch-N	<b>2.4866(1)</b>	<b>15.2330(1)</b>	7.2268(2)	<b>2.6132(1)</b>	<b>13.5391(1)</b>	<b>7.2106(1)</b>	2.8417(12)	19.4269(4)	9.9704(3)
Garch-t	2.5746(10)	16.5019(10)	7.6599(10)	2.6919(10)	14.8703(9)	7.7863(11)	2.8210(6)	19.7276(6)	10.1507(9)
Egarch-t	2.6133(11)	16.9719(11)	7.9019(11)	2.7131(11)	14.9310(11)	7.7520(10)	2.8157(3)	20.0048(11)	10.3136(11)
GJR-t	2.5683(9)	16.4520(8)	7.5736(9)	2.6854(9)	14.8236(8)	7.6511(8)	2.8125(2)	19.7877(7)	10.1319(7)
Cgarch-t	2.5132(3)	15.8946(3)	7.3379(3)	2.6307(3)	14.4029(6)	7.5163(6)	<b>2.8123(1)</b>	<b>19.3145(1)</b>	9.9576(2)
Garch-deg	2.5636(8)	16.4705(9)	7.5691(8)	2.6843(8)	14.8720(10)	7.7083(9)	2.8277(8)	19.8306(9)	10.1439(8)
Egarch-deg	2.6250(12)	16.9869(12)	7.9209(12)	2.7908(12)	15.6002(12)	8.0661(12)	2.8371(11)	20.3870(12)	10.4537(12)
GJR-deg	2.5588(6)	16.4259(7)	7.4882(5)	2.6818(7)	14.8230(7)	7.5797(7)	2.8173(4)	19.7980(8)	10.0120(5)
Cgarch-deg	2.4954(2)	15.7621(2)	<b>7.1839(1)</b>	2.6254(2)	14.2747(5)	7.3847(2)	2.8216(7)	19.3892(2)	<b>9.8928(1)</b>

Nota: los valores en negritas indican los modelos con clasificación más alta bajo los estadísticos de predicción óptima QLIKE, MSE y MAE.

Fuente: estimaciones propias.

Cuando los modelos EGARCH-N Y CGARCH-N SON los *benchmark*, la predicción óptima superior sólo es alcanzada en tres casos bajo el criterio MAE. Finalmente, para el horizonte de predicción de 20 días, los modelos alternativos comparados son superados por la capacidad de los modelos EGARCH-N Y EGARCH-DEG para predecir la volatilidad fuera de la muestra en cinco casos bajo los criterios QLIKE Y MAE.

Respecto a la Mezcla Mexicana de Exportación, la superioridad en la predicción óptima de la volatilidad fuera de la muestra por parte de los modelos CGARCH, bajo las tres funciones de pérdidas y los supuestos distribucionales de innovaciones normales y errores generalizados es notable para el horizonte de predicción de un día a través del estadístico de Diebold-Mariano, puesto que la hipótesis nula de predicción óptima idéntica entre los modelos *benchmark* y alternativos es solamente aceptada en un caso, bajo el criterio MAE (CGARCH-DEG contra CGARCH-N). Para el horizonte de 5 días, el modelo CGARCH-N parece ser la especificación más apropiada para predecir la volatilidad fuera de la muestra bajo el criterio QLIKE, porque sólo en dos casos el *benchmark* presenta el mismo poder predictivo respecto a los modelos alternativos comparados (CGARCH-T y CGARCH-DEG), en tanto que bajo el criterio MSE el modelo *benchmark* no es superior a ningún modelo de volatilidad. En términos del criterio MAE, el poder predictivo del modelo CGARCH-N sobre la familia de modelos es alcanzado en seis casos, esto es, respecto a los modelos GARCH-N, GARCH-T, EGARCH-T, GJR-T, GARCH-DEG Y EGARCH-DEG.

Para el horizonte de predicción largo, los *benchmark* identificados por los modelos CGARCH-T y CGARCH-DEG evidencian claramente la capacidad de predicción óptima idéntica a todos los modelos alternativos comparados bajo las tres funciones de pérdidas. Otro hallazgo relevante que cabe resaltar es que la distribución de errores generalizada juega un papel importante en la predicción óptima de la volatilidad condicional, seguido por la distribución normal. Este hecho se atribuye a que en 48 de 77



CUADRO 5  
RESULTADOS DE LA PRUEBA DE DIEBOLD-MARIANO DE PREDICCIÓN ÓPTIMA IDENTICA

	Mezcla Mexicana															
	Maya				20 días				1 día				5 días			
	QLIKE	MSE	MAE	QLIKE	MSE	MAE	QLIKE	MSE	MAE	QLIKE	MSE	MAE	QLIKE	MSE	MAE	
Garch-N	-2.31**	-1.61	-6.38*	-4.75*	-1.64	-3.51*	-3.18*	-1.76	-1.77	-11.35*	-3.80*	-6.38*	-2.29**	-1.44	-2.23**	
Egarch-N	-2.94*	-0.71	-3.51*	-2.15**	-	-0.31	-	-	-0.67	-7.59*	-3.10*	-3.51*	-2.38**	-1.12	-1.19	
GJR-N	-2.33**	-0.63	-5.31*	-2.43**	-1.32	-1.20	-1.60	-1.75	-2.44**	-8.60*	-3.47*	-4.63*	-2.48**	-1.29	-1.58	
Ggarch-N	-1.01	-0.45	-2.70*	-0.07	-0.78	-	-1.49	-1.19	-0.78	-	-	-1.71	-	-	-0.85	
Garch-t	-9.04*	-2.76*	-10.00*	-9.63*	-1.82	-3.61*	-4.25*	-1.28	-3.92*	-10.22*	-3.75*	-10.01*	-3.84*	-1.83	-2.89*	
Egarch-t	-5.48*	-1.31	-6.09*	-10.52*	-1.27	-1.01	-0.90	-0.68	-0.86	-9.73*	-3.96*	-6.09*	-3.63*	-1.61	-2.36**	
GJR-t	-6.13*	-1.25	-6.67*	-10.55*	-1.91	-1.78	-2.42**	-1.62	-3.07*	-9.43*	-3.55*	-6.67*	-3.48*	1.64	-2.05**	
Ggarch-t	-6.08*	-0.46	-4.70*	-11.57*	-1.49	-1.63	-2.24**	-1.07	-0.82	-6.97*	-3.02*	-4.69*	-1.10	-1.49	-1.42	
Garch-deg	-7.60*	-2.81*	-7.49*	-5.88*	-1.72	-2.20**	-3.04*	-1.17	-3.05*	-9.45*	-3.56*	-7.49*	-3.54*	-1.74	-2.31**	
Egarch-deg	-4.97*	-1.42	-4.56*	-	-1.19	-0.30	-0.04	-0.64	-	-10.42*	-3.95*	-4.56*	-4.24*	-1.86	-3.08*	
GJR-deg	-5.66*	-1.84	-4.57*	-2.56**	-1.55	-0.67	-1.78	-1.41	-2.59*	-8.57*	-3.34*	-4.58*	-3.16*	-1.57	-1.52	
Ggarch-deg	-	-	-	-3.55*	-1.54	-1.11	-1.81	-1.00	-0.35	-2.81*	-2.59*	-	-1.61	-1.31	-0.79	

Nota: resultados de la prueba de Diebold-Mariano para validar la hipótesis nula de que la predicción óptima del modelo benchmark es idéntica a los modelos alternativos. \* y \*\* indican el rechazo de la hipótesis nula a un nivel de significancia de 1% y 5%.  
Fuente: estimaciones propias.

casos los *benchmark* basados en la distribución de errores generalizada presentaron el mejor desempeño en la predicción fuera de la muestra respecto a los modelos alternativos, mientras que en 45 de 88 casos los modelos *benchmark* con innovaciones normales alcanzaron el mejor desempeño predictivo de la volatilidad.

Aunque los resultados de la evaluación del poder predictivo y pruebas de comparación entre dos modelos son robustos bajo las tres funciones de pérdidas, en la mayoría de los casos en este estudio, desafortunadamente, algunos criterios de errores de predicción proporcionan inferencias incorrectas y la selección de modelos inferiores o superiores que subestiman o sobrestiman las predicciones de la volatilidad condicional como consecuencia de la sensibilidad de algunas observaciones extremas en los rendimientos cuadrados de los precios del petróleo y el uso inapropiado de medidas *proxy* para la varianza actual. Este fenómeno es más notable bajo la distribución normal y *t*-student para las innovaciones de los rendimientos del petróleo Maya, como se puede observar en el cuadro 5.

Estas distorsiones, en términos de la forma funcional de las funciones de pérdidas para la clasificación apropiada de los modelos predictivos de volatilidad, tienen importantes implicaciones económicas en la toma de decisiones financieras. En el contexto de la administración de riesgos, la sobreestimación de la volatilidad condicional incrementa el valor en riesgo (VAR) en los mercados de energía, que al mismo tiempo se traduce en un mayor nivel de requerimientos de capital para hacer frente a las posiciones financieras largas ante cambios inesperados en los precios del crudo y viceversa. Asimismo, la correlación positiva entre la volatilidad del precio del petróleo como activo subyacente y las primas de las opciones financieras es otra de las preocupaciones de gran interés para los participantes que compran opciones *call* y *put* en el mercado de productos derivados de energía, porque la volatilidad sobreestimada encarece el costo de las coberturas petroleras a los consumidores industriales y productores de crudo, como en el caso de México, mientras

que la volatilidad subestimada reduce el valor de las coberturas afectando a los vendedores de opciones sobre petróleo.

## CONCLUSIONES

La selección correcta de la distribución condicional para el proceso de las innovaciones, caracterizadas por el fenómeno de la leptocurtosis y las colas pesadas o anchas, juega un rol importante en la descripción de la volatilidad condicional de los rendimientos de los precios del petróleo. De hecho, la literatura ha documentado que la omisión de las propiedades distribucionales en la modelación y predicción de la volatilidad puede traer serias implicaciones en las áreas relacionadas con la política monetaria y energética, la medición del riesgo de mercado, la valuación de opciones sobre materias primas de energía, la administración del portafolio y la creación de estrategias óptimas de cobertura para reducir la exposición al riesgo de precio.

En consecuencia, esta investigación adopta tres distribuciones condicionales (normal, *t*-student y de errores generalizada) en la comparación de la superioridad del poder predictivo de la volatilidad fuera de la muestra de cuatro modelos GARCH, bajo tres funciones de pérdidas y diferentes horizontes de predicción. En el análisis dentro de la muestra, el comportamiento de los rendimientos de los precios del petróleo nacional presenta las características típicas de las series financieras, elevados niveles de exceso de curtosis, existencia de volatilidad en aglomeraciones, efectos asimétricos aunque mixtos y un alto grado de persistencia de memoria larga en la volatilidad, particularmente durante la crisis financiera global.

En términos de la evaluación fuera de la muestra, los resultados empíricos de la prueba de Diebold-Mariano señalan que la volatilidad condicional es sensible a la selección de la distribución para las innovaciones y criterios estadísticos de evaluación. En este sentido, la distribución de errores generalizada y

la distribución normal proporcionan el mejor desempeño de la predicción óptima de la volatilidad fuera de la muestra a través de los modelos *benchmark*, en particular, para el horizonte de predicción de un día y bajo los criterios QLIKE Y MAE para el petróleo Maya, y tres criterios estadísticos y horizontes de uno y 20 días para la Mezcla Mexicana de Exportación. Asimismo, la evidencia empírica muestra la capacidad del modelo CGARCH (1,1) para capturar apropiadamente las características de la memoria larga en la volatilidad de los rendimientos del petróleo bajo cualquier supuesto distribucional. Este hecho es atribuido, en parte, a que 13 de los 18 modelos *benchmark* están determinados por los modelos CGARCH (1,1). Sin embargo, aunque no existe un modelo de volatilidad capaz de superar notablemente a los demás modelos alternativos, la información generada por los hallazgos empíricos puede ser aprovechada por los gobiernos para mantener la estabilidad económica en los países consumidores y productores de petróleo crudo, especialmente México. De esta manera, los diseñadores de la política monetaria no sólo tendrán información más completa de la volatilidad, sino también herramientas para proteger los precios futuros del petróleo mexicano a través de eficientes estrategias de cobertura ante cambios inesperados en los mercados internacionales que afecten la tendencia positiva del petróleo crudo y, por consecuencia, la Ley de Ingresos de la Federación.

## BIBLIOGRAFÍA

- Agnolucci, P. (2009), "Volatility in crude oil futures: A comparison of the predictive ability of GARCH and implied volatility models", en *Energy Economics*, 31, pp. 316-321.
- Aloui, C. y S. Mabrouk (2010), "Value-at-risk estimations of energy commodities via long-memory, asymmetry and fat-tailed GARCH models", en *Energy Policy*, 38, pp. 2326-2339.
- Andersen, T. y T. Bollerslev (1998), "Answering the skeptics: yes, standard volatility models do provide accurate forecasts", en *International Economic Review*, 39, pp. 885-905.

- Arouri, M., A. Lahiani, A. Lévy y D. K. Nguyen (2012), "Forecasting the conditional volatility of oil spot and futures prices with structural breaks and long memory models", en *Energy Economics*, 34, pp. 283-293.
- Bollerslev, T. (1986), "Generalised autoregressive conditional heteroskedasticity", en *Journal of Econometrics*, 31, pp. 307-327.
- Bollerslev, T. y J. Wooldridge (1992), "Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances", en *Econometric Review*, 11, pp. 143-172.
- Chang, K. L. (2012), "Volatility regimes, asymmetric basis effects and forecasting performance: An empirical investigation of the WTI crude oil futures market", en *Energy Economics*, 34, pp. 294-306.
- Chen, S. S. y H. C. Chen (2007), "Oil prices and real exchange rates", en *Energy Economics*, 29, pp. 390-404.
- Cheng, W. H. y J. C. Hung (2011), "Skewness and leptokurtosis in GARCH-typed VAR estimation of petroleum and metal asset returns", en *Journal of Empirical Finance*, 18, pp. 160-173.
- Cheong, C. W. (2009), "Modeling and forecasting crude oil markets using ARCH-type models", en *Energy Policy*, 36, pp. 2346-2355.
- Cogni A. y M. Manera (2009), "The asymmetric effects of oil shocks on output growth: a Markov-switching analysis for the G-7 countries", en *Economic Modelling*, 26, pp. 1-29.
- Diebold, F. X. y R. S. Mariano (1995), "Comparing predictive accuracy", en *Journal of Business & Economic Statistics*, 13, pp. 253-263.
- Engle, R. F. y G. G. Lee (1999), "A permanent and transitory component model of stock return volatility", en R. F. Engle y H. White (eds.), *Cointegration, causality and forecasting: A Festschrift in Honor of Clive W. J. Granger*, Oxford University Press, Oxford, pp. 475-497.
- Estrada, A. y P. Hernández (2012), "Oil prices and their effects on potential output", en *Applied Economics Letters*, 19, pp. 207-214.
- Fan, Y., Y. J. Zhang, H. T. Tsai y Y. M. Wei (2008), "Estimating "Value at Risk" of crude oil price and its spillover effect using the GED-GARCH approach", en *Energy Economics*, 30, pp. 3156-3171.
- Ferderer, J. P. (1996), "Oil price volatility and the macroeconomy", en *Journal of Macroeconomics*, 18, pp. 1-26.
- Filis, G., S. Degiannakis y C. Floros (2011), "Dynamic correlation between stock market and oil prices: The case of oil-importing and exporting countries", en *International Review of Financial Analysis*, 20, pp. 152-164.

- Fong, W. M. y K. M. See (2002), "A Markov switching model of the conditional volatility of crude oil futures prices", en *Energy Economics*, 24, pp. 71-95.
- Giot, P. y S. Laurent (2003), "Market risk in commodity markets: a var Approach", en *Energy Economics*, 25, pp. 435-457.
- Glosten, L., R. Jaganathan y D. Runkle (1993), "On the relation between the expected value and the volatility of the nominal excess returns on stocks", en *Journal of Finance*, 48, pp. 1779-1801.
- Hamilton, J. D. (1983), "Oil and the macroeconomic since World War II", en *Journal of Political Economy*, 91, pp. 228-248.
- Hansen, P. R. (2005), "A test for superior predictive ability", en *Journal of Business & Economic Statistics*, 23, pp. 365-380.
- Hou, A. y S. Suardi (2012), "A nonparametric GARCH model of crude oil price return volatility", en *Energy Economics*, 34, pp. 616-626.
- Huang J. C., M. C. Lee y H. C. Liu (2008), "Estimation of value-at risk for energy commodities via fat-tailed GARCH models", en *Energy Economics*, 30, pp. 1173-1191.
- Huntington, H. G. (1998), "Crude oil prices and US economic performance: where does the asymmetry reside?", en *Energy Journal*, 19, pp. 107-132.
- Kang, S. H., S. M. Kang y S. M. Yoon (2009), "Forecasting volatility of crude oil markets", en *Energy Economics*, 31, pp. 119-125.
- Lee, K., S. Ni y R. A. Ratti (1995), "Oil shocks and the macroeconomy: the role of Price variability", en *Energy Journal*, 16, pp. 39-56.
- Marzo, M. y P. Zagaglia (2010), "Volatility forecasting for crude oil futures", en *Applied Economics Letters*, 17, pp. 1587-1599.
- Mohammadi, H. y L. Su (2010), "International evidence on crude oil price dynamics: Application of ARIMA-GARCH models", en *Energy Economics*, 32, pp. 1001-1008.
- Morana, C. (2001), "A semiparametric approach to short-term oil price forecasting", en *Energy Economics*, 23, pp. 325-338.
- Mork, K. A. (1989), "Oil and the macroeconomic when prices go up and down: An extension of Hamilton's results", en *Journal of Political Economics*, 97, pp. 740-744.
- Narayan, P. K. y S. Nayaran (2010), "Modelling the impact of oil prices on Vietnam's stock prices", en *Applied Energy*, 87, pp. 356-361.
- Narayan, P. K. y S. Nayaran (2007), "Modelling oil Price volatility", en *Energy Policy*, 35, pp. 6549-6553.

- Nelson, D. (1991), "Conditional heteroskedasticity in asset returns: A new approach", en *Econometrica*, 59, pp. 347-370.
- Nomikos, N. K. y P. K. Pouliasis (2011), "Forecasting petroleum futures markets volatility: A role of regimes and market conditions", en *Energy Economics*, 33, pp. 321-337.
- Patton, A. J. (2011), "Volatility forecast comparison using imperfect volatility proxies", en *Journal of Econometrics*, 160, pp. 246-256.
- Reboredo, J. C. (2012), "Modelling oil price and exchange rate co-movements", en *Journal of Policy Modeling*, 34, pp. 419-440.
- Sadorsky, P. (2006), "Modeling and forecasting petroleum futures volatility", en *Energy Economics*, 28, pp. 467-488.
- Sadorsky, P. (1999), "Oil price shocks and stock markets activity", en *Energy Economics*, 21, pp. 449-469.
- Wang, Y. y C. Wu (2012), "Forecasting energy market volatility using GARCH models: Can multivariate models beat univariate models?", en *Energy Economics*, 34, pp. 2167-2181.
- We, Y., Y. Wang y D. Huang (2010), "Forecasting crude oil market volatility: Further evidence using GARCH-class models", en *Energy Economics*, 32, pp. 1477-1484.
- Xu, B. y J. Ouenniche (2012), "A data envelopment analysis-based framework for the relative performance evaluation of competing crude oil price volatility forecasting models", en *Energy Economics*, 34, pp. 576-583.