

## **181 MODELIZANDO HETEROCEDASTICIDAD EN MERCADOS DE CAPITALS EMERGENTES: EL CASO ARGENTINO.**

Auza, Joaquín ; Larre, Tomás Francisco

**Especialidad: Estadística Aplicada**

**Palabras Clave:** Predicción de Volatilidad - E-GARCH – Apalancamiento – Heterocedasticidad Condicionada

### **Resumen**

El propósito de este trabajo es modelizar el patrón de volatilidad presente en la serie histórica de retornos del principal índice del Mercado de Valores de Buenos Aires (MERVAL) entre el primero de enero del 2013 y el sexto de junio de 2016, empleando la familia de modelos híbridos ARIMA - GARCH. Se realiza un estudio de literatura econométrica enfocada a la modelización de índices bursátiles para otras economías emergentes. Se verifican las condiciones para el empleo de esta familia de modelos. El análisis confirma la presencia de asimetría y efecto apalancamiento por lo que se utilizan modelos asimétricos E – GARCH y GJR – GARCH, tanto con distribución Normal como con distribución  $t$  – Student. Se estiman de forma iterativa modelos para distintos órdenes de las especificaciones mencionadas. Para la selección de modelos dentro de la muestra se recurre al Criterio de Información de Schwarz. Se somete los modelos estimados a una secuencia de pruebas de hipótesis a fin de garantizar el cumplimiento de las siguientes propiedades: la captura de todo componente sistemático del proceso, inexistencia de sesgo de signos y magnitud, y estabilidad de los parámetros. Posteriormente se emplean observaciones fuera de la muestra con el fin de evaluar su poder de pronóstico. Finalmente se constata que el E – GARCH  $\sim t(1, 1)$ , con modelos de media ARMA (2,0) y ARMA (2,1), resulta superior dentro de la muestra y su capacidad predictiva no resulta significativamente inferior a la de otros modelos estimados. Estos resultados son consistentes con la literatura econométrica y financiera consultada.

### **1. Introducción**

El estudio de la volatilidad (grado de fluctuación del precio de un activo entre dos momentos en el tiempo) está fuertemente asociado al riesgo de mercado y cobra mayor importancia en el análisis de series cuya estimación puntual (pronóstico) es poco satisfactoria. Una primera aproximación para el pronóstico de los retornos a través del análisis univariado de la serie de tiempo son los procesos ARIMA. Sin embargo, estos no son capaces de capturar y modelizar la variabilidad en la volatilidad. Se recurre, entonces, a modelos de volatilidad variable de la familia ARCH, propuestos por Engle (1982) y ampliados por Bollerslev (1986). Para contemplar la asimetría en la volatilidad (apalancamiento) se consideraron tanto la familia E-GARCH, propuesta por Nelson (1991), como el modelo GJR-GARCH propuesto por Glosten, Jagannathan, y Runkle (1993). En esta investigación se aplican los mencionados métodos estadísticos para modelizar la volatilidad futura del principal índice del Mercado de Valores de Argentina (MERVAL), en búsqueda del modelo que mejor describa y prediga las futuras realizaciones. El trabajo se organiza de la siguiente manera: primeramente, se exhibe una revisión de la literatura referente al análisis estadístico de series financieras. Luego, se desarrolla el marco teórico y metodológico del estudio. Posteriormente se presenta el análisis econométrico de la serie y, por último, se exponen las conclusiones.

### **2. Revisión de la Literatura**

El trabajo de Engle y Bollerslev sobre la familia ARCH se transformó en la base del modelado de volatilidad, con importante implicancia en la industria financiera. La popularidad de estos modelos se basa en su capacidad para

realizar predicciones certeras sobre la volatilidad (Andersen y Bollerslev, 1998) que, a pesar de su simpleza, no son superadas con facilidad por otros modelos más complejos (P. R. Hansen y Lunde, 2005). No obstante, el planteo original si presentaba ciertas limitaciones, en primer lugar, su incapacidad para capturar el efecto apalancamiento que presentan algunos mercados o activos, algo también observado por Hansen y Lunde. Soluciones para este problema fueron propuestas, entre otros, a través de los modelos E-GARCH y GJR-GARCH.

En cuanto a la aplicación del enfoque mencionado para el análisis de series de tiempo de activos financieros en economías emergentes la literatura resulta diversa, tanto por las metodologías aplicadas como por la ubicuidad geográfica. van Dijk (2003), encontró en su análisis comparativo de los modelos de la familia GARCH para los mercados de valores de Argentina, Brasil, Chile, México, Corea, Malasia, Filipinas, Taiwán y Tailandia entre enero de 1998 y diciembre de 2002, incidencia significativa de apalancamiento y demostró la superior capacidad predictiva del modelo E-GARCH. Wiphatthananthakul y Sriboonchitta (2010) calcularon el Índice de Volatilidad de Tailandia (VIX) realizando un análisis comparativo de modelos ARMA-GARCH, E-GARCH, GJR-GARCH y P-GARCH. Sus conclusiones demuestran la persistencia de un efecto asimétrico estadísticamente significativo para todos los modelos, pero sin efecto apalancamiento. A su vez concluyeron que el mejor modelo según el criterio de Akaike sería el ARMA-PGARCH, mientras que el E-GARCH resultó superior siguiendo el criterio bayesiano de Schwartz. Sin embargo, siguiendo los criterios MAPE y RSME hallaron al GJR-GARCH como aquél que mejor se ajustaba. Sinha (2012), por su parte, realizó un análisis de la volatilidad presente en los retornos históricos de los dos principales índices nacionales de India (BSE y NSE). Su aporte demuestra que la utilización de los modelos E-GARCH y GJR-GARCH proporciona un mejor ajuste relativo al modelo GARCH original generalizado por Bollerslev. Además, comprobó la presencia de autocorrelación y asimetría negativa en los retornos diarios, así como la persistencia de los shocks en el tiempo. Ugurlu, Thalassinou, Muratoglu, y cols. (2012) realizaron un análisis de la aplicación de los modelos tipo GARCH para la modelización de la volatilidad de los retornos de los mercados de valores de Bulgaria, República Checa, Polonia, Hungría y Turquía, considerados emergentes en finanzas. Su investigación evidencia la presencia de efecto ARCH en todos los casos exceptuando a Bulgaria. Andersson y Haglund (2015) se propusieron investigar cuál de los modelos usados para la proyección del *Value at Risk* (VaR) - GARCH, GJR-GARCH y E-GARCH - resulta más apropiado y con qué distribución (Normal o *t - Student*) para el *forecast* de siete índices internacionales. Concluyendo que el E-GARCH (1,1) resulta el modelo más apropiado para dicho propósito, si se considera una distribución *t - Student*, sugiriendo que el mejor desempeño ha de atribuirse a la inclusión del efecto del apalancamiento juntamente con la mejor captura del efecto de la curtosis presente en su muestra. Finalmente, Kannadhasan, Thakur, Aramvalathan, y Radhakrishnan (2018), en su estudio de la presencia y el patrón de agrupamiento de la volatilidad y el apalancamiento para el Índice NIFTY50 entre 1996 y 2015 demostraron como la modelización mediante un GARCH (1,1) resultó la estructura más apropiada para predecir la performance futura de dicho índice. A modo de síntesis, el aporte de Engle dio lugar a una ingente variedad de estudios para series financieras que se propusieron detectar y desarrollar metodologías acordes a las particularidades de las mismas.

### 3. Marco Teórico Modelos

### 3.1 Modelos ARIMA

Sea  $y(\omega, t), t \in T, \omega \in \Omega$  una sucesión de variables aleatorias observadas y ordenadas en el tiempo, si  $T \in \mathbb{N}_0$ , se dice que se trata de un proceso estocástico de tiempo discreto. Un proceso es débilmente estacionario, u estacionario de orden dos, si posee media constante y momento de orden dos finito y constante, y su función de autocovarianzas  $\gamma_k = cov(y_t, y_{t+|k|}) \forall t \forall k$ . Cualquier proceso estocástico débilmente estacionario admite la descomposición de la forma  $Y_t = D_t + X_t$ , donde  $D$  es un proceso puramente determinístico, combinación lineal de las realizaciones pasadas del proceso, y  $X$  es una combinación de shocks aleatorios incorrelacionados (Wold y cols., 1948). Wold introdujo el concepto pero su aplicación práctica se logró recién a través de la metodología derivada por Box y Jenkins (1970). Una representación ARMA  $(p, q)$ , se forma como una combinación lineal de sus  $p$  realizaciones pasadas y sus  $q$  innovaciones pasadas:

$$y_t = \delta + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} \quad (1)$$

El caso más general de estas representaciones contempla la presencia de  $d$  raíces unitarias, las cuales se eliminan diferenciando la serie, obteniéndose una representación ARIMA  $(p, d, q)$ :

$$\nabla^d y_t = \delta + \sum_{i=1}^p \phi_i \nabla^d y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} \quad (2)$$

### 3.2 Modelos ARCH, GARCH, E-GARCH y GJR-GARCH

La especificación de Engle para la modelización de la volatilidad en presencia de heterocedasticidad condicionada parte de:

$$\epsilon_t = \sigma_t \omega_t; \omega_t \sim i. i. d N(0,1) \quad / \quad E(\epsilon_t^2) | \mathcal{F}_{t-1} = \sigma_t^2 \quad (3)$$

donde  $\mathcal{F}_{t-1}$  es el conjunto de información al momento  $t$ . Ergo, la varianza condicional  $[\sigma_t^2 = Var(y_t | \mathcal{F}_{t-1})]$  bajo un modelo ARCH ( $r$ ) es:

$$\sigma_t^2 = \mu + \sum_{i=1}^r \alpha_i \epsilon_{t-i}^2 \quad \forall \mu > 0; \alpha_i \geq 0 \quad (4)$$

Bollerslev presentó una generalización en la cual modeliza  $\sigma_t^2$  incluyendo realizaciones pasadas de  $\epsilon_t$ , quedando así definidas las ecuaciones para un modelo GARCH( $r, s$ ):

$$\sigma_t^2 = \mu + \sum_{i=1}^r \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 \quad \forall \mu > 0; \alpha_i \geq 0; \beta_j \geq 0 \quad (5)$$

Un modelo GARCH exponencial -denotado E-GARCH ( $r, s$ )- busca capturar el efecto asimétrico en la volatilidad. En él,  $g(\omega_t)$  debe ser función del signo y la magnitud de  $\epsilon_t$ , por lo que se la define como una combinación lineal de  $\omega_t$  y  $|\omega_t|$ . Entonces, la varianza condicional se representa:

$$\ln(\sigma^2) = \mu + \sum_{i=1}^r \beta_i \left( \Theta \frac{\epsilon_{t-i}}{\sigma_{t-i}} + \gamma_i \left( \left| \frac{\epsilon_{t-i}}{\sigma_{t-i}} \right| - E \left( \left| \frac{\epsilon_{t-i}}{\sigma_{t-i}} \right| \right) \right) \right) + \sum_{j=1}^s \alpha_j \ln(\sigma_{t-j}^2) \quad (6)$$

donde  $\Theta$  y  $\gamma$  son constantes reales y no ambas cero,  $\alpha$  es una constante que representa el efecto magnitud o de simetría en el modelo,  $\gamma$  representa la asimetría ( $\gamma = 0$  significa un modelo simétrico), tal que un valor  $\gamma > 0$  implica

que las innovaciones positivas son más desestabilizantes que las negativas y viceversa,  $\beta$  y  $\mu$  son secuencias no estocásticas reales,  $\beta$  representa la persistencia. El modelo presentado por Glosten, Jagannathan y Runkle -GJR- considera la asimetría en el proceso a través de la variable dummy  $S_t^-$ , que toma los valores 1 si  $\epsilon_t < 0$  y 0 si  $\epsilon_t \geq 0$ . Se captura la diferencia en  $\sigma^2$  producto del signo que toman los residuos, y se cuantifica la asimetría a través del parámetro  $\gamma$ . De modo tal que la ecuación para el GJR-GARCH ( $r,s$ ) es:

$$\sigma_t^2 = \mu + \sum_{i=1}^r \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 + \sum_{i=1}^r S_{t-i}^- \gamma_i \epsilon_{t-i}^2 \quad (7)$$

Por último, dado que el peso de las colas de la distribución de las innovaciones del proceso de media puede no ser capturado por una distribución normal, se trabaja también con la distribución  $t$ . De este modo, se tiene:

$$\epsilon \sim t - student; f(\epsilon_t, v, \sigma^2) = \frac{\Gamma(\frac{v+1}{2})}{\sqrt{\pi} \Gamma(\frac{v}{2})} \left( (v-2) \sigma_t^2 \right)^{-\frac{1}{2}} \left( 1 + \frac{\epsilon_t^2}{(v-2) \sigma_t^2} \right)^{-\frac{v+1}{2}}; v > 2 \quad (8)$$

Donde  $v$  son los grados de libertad. El desarrollo de las funciones de verosimilitud, así como los algoritmos para la estimación de los parámetros para los modelos precedentes se puede encontrar detallado por Casas Monsegny y Cepeda Cuervo (2008).

### 3.3 Pruebas de volatilidad asimétrica

La serie de pruebas propuestas por Engle y Ng (1993), conocidas como pruebas de sesgo de signo y magnitud brindan información para determinar la suficiencia de un modelo GARCH simétrico, o la necesidad de utilizar uno asimétrico. En primer lugar, se define  $V_t$  como el cociente entre el residuo estandarizado del modelo de media y la raíz de la varianza estimada. La prueba de *sesgo de signo* se centra en el impacto diferenciado que las innovaciones positivas y negativas tienen en la volatilidad, y que no se haya capturado por el modelo.

La prueba de *sesgo de signo* se centra en el impacto diferenciado que las innovaciones positivas y negativas tienen en la volatilidad y que no se haya capturado por el modelo. Las pruebas de sesgo de magnitud negativo y positivo refieren a los efectos no capturados por el modelo generados por innovaciones pequeñas y grandes, negativas y positivas, respectivamente. Los efectos pueden comprobarse individualmente mediante *tests t* que evalúen la significatividad de los parámetros  $b$  sobre regresiones individuales o de forma conjunta a través de una prueba F, sobre una regresión múltiple definida como:

$$V_t^2 = b_0 + b_1 D_t^- + b_2 D_t^- \epsilon_{t-1} + b_3 (1 - D_t^-) \epsilon_{t-1} + v_t \quad (9)$$

## 4. Análisis Econométrico





Figura 1. Serie de los retornos logarítmicos.

La serie consta de 1557 observaciones obtenidas de *Yahoo Finance*, comprendidas entre el 1° de enero de 2013 y el 6° de junio de 2019. La información de interés es el precio de cierre de cada día. En base a esta serie se obtienen los retornos logarítmicos ( $r_t = \ln(\frac{P_t}{P_{t-1}})$ ) que conforman la serie cuyas características se busca modelizar. Esta fue dividida en un segmento de 779 observaciones para la estimación del modelo (*Training Set*), y unas 778 observaciones restantes (*Validation Set*) para la evaluación del pronóstico.

Se comprobó que la serie de los retornos logarítmicos cumpliera con las dos condiciones iniciales para la modelización de la volatilidad mediante modelos GARCH. La estacionariedad de la serie se verificó mediante una combinación de análisis gráfico y pruebas de hipótesis (todas realizadas considerando un  $\alpha$  del 5 %).

Se efectuó la prueba de Dickey-Fuller aumentada (Said y Dickey, 1984) y se rechazó la hipótesis nula de existencia de raíz unitaria ( $\tau = -28.38, vc_{\alpha=5\%} = 0.146$ ). El resultado de la prueba ADF se complementó con la prueba de KPSS (Kwiatkowski, Phillips, Schmidt, y Shin, 1992) empleando una hipótesis nula de estacionariedad en tendencia y en media. Para ninguna de las dos alternativas se pudo rechazar  $H_0$  ( $\tau = 0.023, vc_{\alpha=5\%} = 0.146$  y  $\mu = 0.1452, vc_{\alpha=5\%} = 0.463$ ). En base a estos resultados empíricos se concluye que no hay evidencia de no estacionariedad. En segundo término se procedió a verificar que existiera agrupamiento de la volatilidad en el proceso. A este fin, se realizó el *test* de Multiplicadores de Lagrange descrito por Engle, con una hipótesis nula de inexistencia de efecto ARCH, la cual se rechaza ( $\chi^2 = 146.71, p\text{-valor} = 0$ ). Hay indicios gráficos y empíricos de correlación tanto en el valor absoluto como en el cuadrado de las observaciones. De este modo, quedan verificadas las condiciones necesarias para modelizar utilizando la familia de modelos de heterocedasticidad condicionada.



**Figura 2.** Correlogramas para los retornos absolutos y cuadráticos.

## 5. Selección de modelos

Se especificaron dentro de la muestra las combinaciones posibles de modelos híbridos ARMA-GARCH, ARMA-E-GARCH y ARMA-GJR-GARCH de orden  $p, q, r$  y  $s$  desde  $(0, 0, 1, 0)$  hasta  $(2, 2, 4, 4)$  asumiendo innovaciones con distribución normal y con distribución  $t$  - *Student*, contabilizando 720 modelos. Los modelos dentro de la muestra fueron seleccionados y jerarquizados mediante a su bondad de ajuste utilizando el criterio SIC. Se verificó que los modelos de varianza estimados logaran capturar todo componente sistemático, para lo cual se realizó un *test* Q de Ljung-Box sobre sus residuos a fin de establecer la incorrelación de los mismos, y la inexistencia de efecto ARCH. También se constató que los parámetros cumplan con la restricción de no negatividad (para las especificaciones GARCH y GJR-GARCH) y que su suma no supere la unidad. Por último, se practicaron las pruebas de sesgo de signo y magnitud que revelaron la necesidad de optar por modelos asimétricos. Entre estos, el análisis mostró que los modelos E-GARCH logran capturar

la asimetría de manera más efectiva que los GJR-GARCH, y que la distribución  $t$  – *Student*, ajusta mejor a los datos dentro de la muestra. Para la totalidad de modelos se realizó un *rolling-forecast* a 1 período y se obtuvo el MSE.

(p,q)-(r,s)	Especificación	SIC	MSE
(2,0)-(1,1)	E-GARCH-t	-4.726569064	5,28543667873296e-7
(2,1)-(1,1)	E-GARCH-t	-4.724281102	5.27114690769544 e-7

**Tabla 1.** Mejores modelos por Scharz: Especificación del modelo, distribución de los residuos, SIC, MSE y MAE para el modelo de varianza.

(p,q)-(r,s)	Especificación	SIC	MSE
(1,2)-(3,3)	E-GARCH-N	-4.664631918	5,23417056818824e-7
(2,1)-(2,1)	E-GARCH-N	-4.686264295	5,23728180256075e-7

**Tabla 2.** Mejores Modelos por MSE: Especificación del modelo, distribución de los residuos, SIC, MSE y MAE para el modelo de varianza.

## 6. Análisis de los modelos

Parámetro	(2,1) - (1,1)	(2,0) - (1,1)	(2,1) - (2,1)	(1,2) - (3,3)
$\phi_1$	-0.84101	0.069078	-0.843341	-0.955180
$\phi_2$	0.10047	0.049332	0.11589	0
$\theta_1$	0.91377	0	0.911857	1.036703
$\theta_2$	0	0	0	0.120434
$\mu$	-1.56762	-1.532244	-1.599649	-2.248711
$\alpha_1$	-0.18351	-0.176673	-0.178615	-0.148956
$\alpha_2$	0	0	0.019068	-0.142281
$\alpha_3$	0	0	0	0.108786
$\beta_1$	0.79134	0.795822	0.786439	0.231797
$\beta_2$	0	0	0	0.785212
$\beta_3$	0	0	0	-0.316044
$\gamma_1$	0.27190	0.265488	0.199232	0.215436
$\gamma_2$	0	0	0.092401	0.180826
$\gamma_3$	0	0	0	0.032581

**Tabla 3:** Parámetros estimados para los mejores modelos dentro y fuera de la muestra.

El ARMA (2,0)-E-GARCH-t (1,1) posee un parámetro no significativo ( $\phi_2$ ). La estabilidad de estos se evalúa a través de la prueba de Nyblom-Hansen (B. E. Hansen, 1992; Nyblom, 1989), la cual no da indicios de inestabilidad ni de forma individual ni conjunta. Rechaza la hipótesis nula de la prueba de bondad de ajuste de Pearson con respecto a la distribución elegida y logra capturar la totalidad del componente sistemático de modo que no hay evidencia de correlación en sus residuos ni residuos cuadráticos. Por último, el modelo logra superar las pruebas de sesgo de signos. El ARMA(2,1)-E-GARCH-t(1,1) posee parámetros significativos. No hay indicios de inestabilidad. Tampoco presenta

problemas de ajuste a la distribución elegida de acuerdo a la prueba  $\chi^2$  de Pearson. No hay asimetría no capturada por el modelo. El ARMA(1,2)-E-GARCH-N (3,3) posee dos parámetros no significativos ( $\beta_1$  y  $\gamma_3$ ), ningún parámetro inestable y logra capturar la asimetría de acuerdo a la prueba de sesgo de signos, así como no existe evidencia de correlación en sus residuos ni residuos cuadráticos. El ARMA(2,1)-E-GARCH-N(2,1), posee un parámetro no significativo ( $\varphi_2$ ), aunque no presenta inestabilidad de acuerdo a la prueba de Nyblom y Hansen. Está correctamente especificado en términos de capturar la asimetría y de incorrelación de sus residuos.

A continuación se evalúa la diferencia en la capacidad predictiva del ARMA(2,1)-E-GARCH-t(1,1) y aquella de los mejores modelos en cuanto a predicción fuera de la muestra. Se utiliza la siguiente forma funcional para la diferencia relativa:

$$DR = \frac{MSEa - MSEb}{MSEa} \quad (10)$$

Donde  $MSEa$  es la métrica para el mejor modelo de acuerdo al criterio SIC, y  $MESb$  es la métrica para el modelo con mejor capacidad predictiva. Al comparar la capacidad predictiva del ARMA(2,0)-E-GARCH-t(1,1) y el EI ARMA(1,2)-E-GARCH-N(3,3) se obtiene un valor de DF 0.009699503, y al comparar con el ARMA(2,1)-E-GARCH-N(2,1) se obtiene un valor de 0.00911086. Al comparar el EI ARMA(2,1)-E-GARCH-t(1,1) con el EI ARMA(1,2)-E-GARCH-N(3,3), el valor es de 0.007014857, y de 0.006424618 al compararlo con el ARMA(2,1)-E-GARCH-N(2,1). Los resultados obtenidos no son significativos, es decir que la capacidad predictiva de los modelos elegidos por criterio SIC no es significativamente inferior a la de los modelos que mejor predicen de acuerdo al criterio MSE.




Figura 3. Volatilidad pronosticada (rojo) para el ARMA(2,1)-E-GARCH-t(1,1) contra retornos cuadráticos (azul) .

## 7. Conclusiones

Este trabajo modelizó la volatilidad de los retornos para la serie del Merval entre el primero de enero de 2013 y el sexto de junio del 2019, utilizando modelos ARMA-GARCH, E-GARCH y GJR-GARCH.

Los resultados de la investigación constatan la existencia de heterocedasticidad condicionada y asimetría en la volatilidad lo cual justifica la necesidad del empleo de modelos asimétricos. La superior performance de los modelos E-GARCH  $\sim t(1,1)$  dentro de la muestra queda constatada, juntamente con el hallazgo de que su poder predictivo fuera de la muestra no es significativamente inferior al de otros modelos evaluados. Estas observaciones se condicen con los resultados de estudios similares para otros índices bursátiles obtenidos por Sinha, van Dijk y Wiphatthananthakul y Sriboonchitta.

La investigación se limitó a un conjunto y familia de modelos con distribuciones normales y *t-Student*. A futuro, resulta pertinente expandir el estudio de la volatilidad a otras distribuciones de error, emplear modelos multivariados o recurrir a modelos de volatilidad estocástica.

## Referencias

- Andersen, T. G., y Bollerslev, T. (1998). Answering the skeptics: Yes, standard volatility models do provide accurate forecasts. *International economic review*, 885–905.
- Andersson, O., y Haglund, E. (2015). Financial econometrics: A comparison of garch type model performances when forecasting var.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31 (31), 307-327.
- Box, G., y Jenkins, G. (1970). *Time series analysis-forecasting and control*. san francisco: Holden day. 553 p.
- Casas Monsegny, M., y Cepeda Cuervo, E. (2008). Modelos arch, garch y egarch: aplicaciones a series financieras. *Cuadernos de economía*, 27(48), 287–319.
- Engle, R. F., y Ng, V. K. (1993). Measuring and testing the impact of news on volatility. *The journal of finance*, 48(5), 1749–1778.
- Glosten, L. R., Jagannathan, R., y Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, 48(5), 1779–1801.
- Hansen, B. E. (1992). Testing for parameter instability in linear models. *Journal of policy Modeling*, 14 (4), 517–533.
- Hansen, P. R., y Lunde, A. (2005). A forecast comparison of volatility models: does anything beat a garch (1, 1)? *Journal of applied econometrics*, 20(7), 873–889.
- Kannadhasan, M., Thakur, B. P. S., Aramvalathan, S., y Radhakrishnan, A. (2018). Modelling volatility in emerging capital market: The case of indian capital market. *Academy of Accounting and Financial Studies Journal*, 22(1), 1–11.
- Kwiatkowski, D., Phillips, P. C., Schmidt, P., y Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of econometrics*, 54 (1-3), 159–178.
- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, 59(2), 347–370.
- Nyblom, J. (1989). Testing for the constancy of parameters over time. *Journal of the American Statistical Association*, 84(405), 223–230.
- Said, S. E., y Dickey, D. A. (1984). Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika*, 71 (3), 599–607.
- Sinha, B. (2012). Determining historical volatility in emerging markets using advanced garch models. Available at SSRN 2140647.
- Ugurlu, E., Thalassinos, E., Muratoglu, Y., y cols. (2012). Modeling volatility in the stock markets using garch models: European emerging economies and turkey. En *Annual international meeting for international conference on applied business and economics*, nicosia, cyprus.



van Dijk, D. (2003). Forecasting emerging equity market volatility using nonlinear garch models. IFAC Proceedings Volumes, 36(16), 221–226.

Wiphatthanananthakul, C., y Sriboonchitta, S. (2010). The comparison among arma-garch,-egarch,-gjr, and-pgarch models on thailand volatility index. The Thailand Econometrics Society, 2(2), 140–148.

Wold, H. O., y cols. (1948). On prediction in stationary time series. The Annals of Mathematical Statistics, 19(4), 558–567.