

Universidad de Buenos Aires
Facultad de Ciencias Económicas
Escuela de Estudios de Posgrado

MAESTRÍA EN FINANZAS

TRABAJO FINAL DE MAESTRÍA

La predicción de volatilidad del mercado de valores argentino
en el período 2010 a 2017

AUTOR: PABLO DANIEL CHICHILNITZKY

DIRECTOR: LUIS ALBERTO TRAJTENBERG

MAYO DE 2020

Resumen

La volatilidad es un aspecto transversal en el análisis y administración de riesgo de instrumentos financieros. Hasta el presente se han desarrollado diferentes modelos destinados a predecirla con mejores o peores resultados de acuerdo a las series sobre las que se realiza la estimación. Sin embargo, los cambios en los regímenes de volatilidad obligan a reestimar los parámetros de un determinado modelo que pudo haber tenido buenos resultados.

En este sentido, la literatura da cuenta del impacto de la crisis financiera global del 2008-2009 en dichos regímenes a través de distintos activos y mercados (Ang y Timmermann, 2011; Brownlees, Engle y Kelly, 2012). Por lo tanto, es intención de este trabajo validar los modelos más utilizados en la predicción de la volatilidad y aplicarlos al índice Merval para obtener un estimador actualizado a partir de la serie de datos histórica del período 2010-2017.

Al respecto, se validan los modelos de heterocedasticidad condicional autorregresiva generalizado (GARCH) y GARCH con umbral (TARCH) que forman parte de la familia de modelos de heterocedasticidad condicional autorregresiva (ARCH) y presentan en general los mejores resultados en series financieras (Brownlees, Engle y Kelly, 2012). Los hallazgos del presente trabajo sugieren que el modelo GARCH con distribución t en los errores es superior al resto de los modelos analizados. Por su parte, el modelo TARCH, si bien empleado para captar la asimetría que exhiben los retornos de las series financieras, no necesariamente mejora el poder de la predicción.

Adicionalmente, se propone la utilización de métodos no paramétricos como complemento para sopesar la posición relativa de la volatilidad pronosticada por los modelos paramétricos. Se utiliza a tal efecto el método por percentiles y osciladores de volatilidad histórica.

Palabras clave: G17 Predicción de volatilidad, análisis de riesgo, modelos ARCH, métodos no paramétricos.

Índice

1. Introducción	4
2. Planteamiento del tema/problema.....	5
2.1. Formulación del tema	5
2.2. Objetivos	5
2.3. Hipótesis	6
3. Marco teórico.....	6
3.1. Consideraciones preliminares acerca de la volatilidad	6
3.2. Modelos paramétricos.....	12
3.2.1. Modelos GARCH.....	14
3.2.2. Modelos TARCH.....	16
3.3. Métodos no paramétricos.....	18
3.4. El horizonte temporal de predicción.....	19
3.5. Evaluación de los pronósticos realizados	20
4. Metodología.....	21
5. Aplicación al índice Merval en el período 2010-2017	22
5.1. Análisis descriptivo de la serie de datos utilizada	23
5.2. Estimación del modelo GARCH para la predicción de volatilidad	29
5.3. Estimación del modelo TARCH para la predicción de volatilidad.....	34
5.4. Selección del modelo paramétrico.....	40
5.4.1. Prueba y selección partir de datos dentro de la muestra	41
5.4.2. Prueba y selección partir de datos fuera de la muestra	42
5.5. Métodos no paramétricos.....	47
6. Conclusiones y consideraciones finales.....	51
7. Referencias bibliográficas.....	53

1. Introducción

Ya sea como analistas de los mercados financieros o como inversores es de interés conocer los instrumentos operados. En este sentido, la volatilidad es un aspecto que no puede omitirse al momento de evaluar el posible movimiento que puede tener un activo financiero en el horizonte de análisis y el riesgo asumido. Asimismo, es uno de los principales componentes de la valoración de opciones financieras y de los modelos de probabilidad para la determinación de las posibles trayectorias del precio de los activos.

Es de destacar que desde la generación de los primeros modelos en la década del ochenta, el tema ha sido abordado desde diferentes ámbitos y mercados. En lo que se refiere al mercado de valores argentino, Bahi (2007) ha sometido a prueba distintos modelos econométricos para el período 1997-2007.

En consecuencia, habida cuenta de los cambios en los regímenes de volatilidad con posterioridad a la crisis financiera internacional (Ang y Timmermann, 2011; Brownlees, Engle y Kelly, 2012) este trabajo en particular busca evaluar y validar herramientas para la predicción de volatilidad en el mercado de valores argentino, en lo que respecta a su pertinencia y efectividad para el período 2010 a 2017.

Adicionalmente, complementa el uso de métodos econométricos con métodos no paramétricos, de manera tal de dotar al operador de un conjunto de herramientas actualizadas e intuitivas que le permita discernir con mayor precisión las trayectorias posibles de los activos y los riesgos involucrados.

El trabajo se estructura en los siguientes bloques: en la sección 2 se describe el tema conjuntamente con los objetivos e hipótesis abordados. Por su parte, en el apartado 3 se expone el marco conceptual sobre el que se basa el trabajo empírico desarrollado. A continuación se expone la metodología empleada. La sección 5 desarrolla la aplicación de conceptos sobre la serie de datos del índice Merval. Por último, en el capítulo 6 se exponen las conclusiones y consideraciones finales.

2. Planteamiento del tema/problema

2.1. Formulación del tema

El presente trabajo tiene por objeto estudiar métodos y modelos de predicción de volatilidad para su aplicación al mercado de valores argentino. Para ello se estudiarán los distintos supuestos en los que se basan y su funcionamiento en el período 2010 a 2017 sobre el índice Merval.

La literatura especializada remarca que la crisis financiera global del 2008-2009 dio lugar al inicio de un régimen de volatilidad distinto. Además, en la modelización de predictores de volatilidad se resalta la importancia de amplitud de la base de datos utilizada para estimar los parámetros (Ang y Timmermann, 2011; Brownlees, Engle y Kelly, 2012).

En este sentido, es de interés validar determinados modelos y actualizarlos de acuerdo a la evidencia empírica del período 2010 a 2017. De esta manera, se generará una herramienta útil y actual que sirva de base para las distintas aplicaciones en los que la volatilidad es un dato de entrada.

En resumen, a través de este estudio se pretende abordar los siguientes aspectos:

- ¿Cuál es el contexto o condiciones en los que los modelos y herramientas estudiados funcionan mejor?
- ¿Qué características particulares tiene el mercado de valores argentino que demandarían algún ajuste en los modelos?
- ¿Qué efectividad tienen dichos métodos para la estimación de volatilidad en el mercado y período objetivos?

2.2. Objetivos

Objetivo general

Evaluar, validar y seleccionar herramientas para la predicción de volatilidad en el mercado de valores argentino que permitan analizar con mayor precisión las trayectorias posibles de los

activos y los riesgos involucrados, a partir de la utilización de la serie de datos histórica del índice en el período 2010 a 2017.

Objetivos específicos

Identificar características particulares del mercado de valores argentino que puedan afectar la efectividad de los mencionados indicadores.

Probar la efectividad de los métodos seleccionados en el índice Merval en el período 2010 a 2017

2.3. Hipótesis

La hipótesis a contrastar sostiene que los modelos econométricos a evaluar son válidos para su uso en la predicción de la volatilidad del mercado de valores argentino. Asimismo, pueden complementarse con métodos no paramétricos.

3. Marco teórico

En el presente apartado se exponen los elementos conceptuales sobre los que se basa el estudio realizado. A este fin, se comenzará explicando la volatilidad y el tipo de instrumento sobre los que se aplicará la metodología propuesta. Posteriormente, se hará referencia a los métodos de predicción a evaluar para validar y seleccionar un conjunto de herramientas consistentes.

3.1 Consideraciones preliminares acerca de la volatilidad

La volatilidad de un activo financiero es una medida de riesgo de sus retornos. Mientras el riesgo está representado por la posibilidad de obtener resultados o rendimientos distintos a los esperados en una inversión en un determinado período, la volatilidad mide la magnitud de su variabilidad. Matemáticamente la volatilidad suele ser definida como la desviación estándar, σ , o varianza, σ^2 , de los retornos calculada a partir de una muestra y generalmente se expresa en términos anuales. Su cálculo viene dado por la siguiente fórmula:

$$\hat{\sigma}^2 = \frac{1}{N-1} \sum_{t=1}^N (R_t - \bar{R})^2 \quad (1)$$

donde \bar{R} es la media de los retornos.

Cabe señalar que el estadístico $\hat{\sigma}$ representa el segundo momento de la muestra y está libre de una distribución de probabilidad. Sin embargo, para que tenga sentido como medida del riesgo debe asociarse a una distribución de probabilidad. Por cuestiones de simplicidad generalmente se asume una distribución normal, no obstante lo cual, tal parámetro puede calcularse para cualquier distribución con forma irregular. En esta situación, la función de densidad debe derivarse empíricamente (González Isolio y Tapia, 2017; Hull, 2015; Poon y Granger, 2003).

Por otro lado, al referirse a la volatilidad deberá diferenciarse entre la volatilidad histórica, la volatilidad implícita y la volatilidad futura. La primera de ellas es la que efectivamente ha sucedido en el pasado y puede calcularse a partir de una serie de retornos histórica del instrumento financiero que se desea evaluar. Por su parte, la volatilidad implícita es la que surge de la inversión de un modelo de valoración de opciones financieras al utilizar como datos de entrada los precios de mercado de las primas. Es decir, podría afirmarse que es la opinión del mercado respecto a cuál será la volatilidad del activo subyacente hasta el vencimiento del instrumento derivado. Por el contrario, la volatilidad futura es la que sucederá y por lo tanto se desconoce. Es la que interesa inferir a partir de las distintas herramientas y métodos que se estudiarán (Hull, 2015; Natenberg, 1994).

Sin perjuicio de lo expuesto, debe advertirse que aunque la volatilidad comúnmente se la estime a partir de la Ecuación 1, la volatilidad real es inobservable. Otras maneras de medir la volatilidad de forma directa han sido sugeridas. Es el caso de Ding, Granger y Engle (1993) que sugieren considerar los retornos absolutos. Desde el punto de vista teórico la volatilidad real podría observarse a partir de una muestra de los datos que representan el recorrido del proceso de formación del retorno, pero para ello es necesario contar con datos de alta frecuencia. En este sentido, con la mayor difusión de este tipo de datos se ha acuñado el término volatilidad realizada para referirse a la suma de los cuadrados de los retornos intradiarios correspondientes a compresiones de quince o cinco minutos. En este orden de ideas, se ha probado que este estimador

ha sido preciso para representar el proceso latente que define a la volatilidad. También se ha observado que intervalos de tiempo menores a los mencionados resultan en correlación serial espuria (Andersen y Bollerslev, 1998; Poon y Granger, 2003).

La volatilidad en el marco de las finanzas

En el ámbito de las finanzas la volatilidad es un dato que cobra especial relevancia en distintas aplicaciones. Entre éstas puede mencionarse el proceso decisorio para la realización de una determinada inversión financiera, la valuación de instrumentos, la gestión del riesgo así como también la ejecución de política monetaria.

Respecto al proceso decisorio de inversión, representa un dato de entrada tanto para la decisión de inversión como para la construcción de carteras. En este caso, la volatilidad actúa como medida de incertidumbre y estimación del riesgo de esas inversiones, de manera de sopesarlas con respecto al riesgo que pretenden asumir los inversores o quienes se encuentran a cargo de la gestión de las mismas.

En materia de valuación de instrumentos financieros, la volatilidad es uno de los factores más influyentes en lo que hace a la valoración del precio de derivados y dentro de estos, de las opciones financieras. Así, para poder valorar una opción debe conocerse la volatilidad del activo subyacente que se estima ocurrirá entre el momento de valuación y el vencimiento del contrato derivado. Además, con el desarrollo de los principales mercados han surgido nuevos productos, como por ejemplo, derivados donde el activo subyacente es la volatilidad misma.

Por otro lado, como parte de las actividades de la gestión del riesgo financiero, para algunas instituciones financieras se ha vuelto obligatoria la realización de pronósticos de volatilidad a partir de la reforma al Acuerdo de Basilea producida en 1996. Dichas instituciones deben constituir reservas de capital apropiadas de acuerdo a medidas de Valor a Riesgo, cuyo cálculo depende de tales pronósticos.

Por último, es de hacer notar que existe evidencia del vínculo entre la incertidumbre en los mercados financieros y la confianza del público. Esta relación a su turno, puede provocar serios efectos en la economía de un país. A partir de ello, los hacedores de política monetaria suelen considerar los pronósticos de volatilidad como indicador de las vulnerabilidades de los mercados financieros y la economía (Poon y Granger, 2003).

Regímenes de volatilidad

Los regímenes de volatilidad se refieren a comportamientos persistentes a través de largos períodos. Al respecto, podrían ocurrir períodos de baja o alta volatilidad que representarían el contexto en el cual la volatilidad de menor plazo oscilaría.

El paso de un régimen a otro generalmente se corresponde con cambios en las regulaciones, políticas, entre otros. Ejemplo de ello ha sido el período posterior a la crisis financiera global del 2008-2009. También se ha observado que los diferentes regímenes suelen corresponderse con ciclos alcistas y bajistas. Por su parte, los cambios de un régimen observados a través de un portafolio de mercado pueden también verificarse en los activos que lo componen (Ang y Timmermann, 2011; Pagan y Sossounov, 2003).

Activo financiero a analizar

De acuerdo al tipo de renta que puede obtenerse de un instrumento financiero, pueden clasificarse en instrumentos de renta fija, renta variable, renta contingente y de renta híbrida (González Isolio y Tapia, 2017). Este trabajo se centrará en los segundos, que se caracterizan por otorgar un rendimiento que depende de la capacidad de generar flujos de fondos positivos del activo real que representa.

En particular, se analizará el mercado de valores argentino a través del índice Merval. Un índice de mercado mide la evolución del valor de una canasta de activos financieros públicos de acuerdo a un método empleado.

El índice Merval se calcula en función a la participación en el volumen y cantidad de operaciones de los últimos seis meses que tienen las acciones de compañías cotizantes en la Argentina. La composición del índice cambia cada tres meses de acuerdo a esos parámetros (IAMC, 2017).

Hechos estilizados de las series financieras

La volatilidad de los retornos financieros tiene características propias que deben ser consideradas por los modelos con los que se intenta representarla. Engle y Patton (2001) dan cuenta de algunas de ellas y que corresponde mencionar en lo que respecta al presente estudio.

Persistencia en la volatilidad

Al analizar series de retornos financieros puede observarse que la volatilidad varía a través del tiempo y da lugar a la formación de *clusters* o agrupamientos. Éstos vienen dados por períodos donde la misma permanece en un nivel más alto o bajo en términos relativos a los niveles que normalmente exhibe. En otros términos, esto significa que un shock que se produzca hoy tendrá efecto sobre la expectativa que se tenga en cuanto a los períodos futuros. Además, el pronóstico de la volatilidad dependerá de la información con que se cuenta en el período actual, la cual viene dada por el retorno de ese día. La persistencia tiene lugar cuando el retorno diario actual tiene un efecto importante sobre la varianza pronosticada muchos períodos hacia adelante.

Por su parte, Nelson (1991) sostiene que a medida que aumenta la frecuencia de la muestra de datos obtenida, la persistencia de la volatilidad encontrada debería ser mayor. En esa línea de ideas, Glosten, Jagannathan y Runkle (1993) hallan que la persistencia en muestras de retornos mensuales es menor comparada con la de compresiones menores.

Reversión a la media

Esta característica es consecuencia de la descrita precedentemente. La volatilidad oscila entre períodos de alta o baja volatilidad alrededor de un nivel que generalmente es interpretado como normal o de largo plazo. Es decir, que luego de verificarse un extremo es de esperarse que retorne a este último valor. Tal es así que un pronóstico de muy largo plazo debiera arribar a ese nivel sin importar el momento en que sea realizado. Al contrario de lo mencionado en cuanto a la persistencia, la reversión a la media significa que la información actual no tiene efectos sobre la proyección de largo plazo.

Efectos asimétricos de las innovaciones

Los shocks negativos exhiben mayores efectos que los positivos sobre la volatilidad de los retornos del mercado de acciones. Esta asimetría se la ha atribuido al *leverage effect* o efecto apalancamiento (Black, 1976) y en ciertos casos al efecto por prima de riesgo (French, Schwert y

Stambaugh, 1987). El efecto apalancamiento se refiere al incremento del riesgo que supone para una empresa la baja en el valor de la compañía con respecto a la deuda financiera. Esto se traduce en un ratio deuda/capital mayor y mayor riesgo para el accionista, los cuales producen una mayor volatilidad en el retorno de sus acciones. Por su parte, el efecto por prima de riesgo se observa gracias a una mayor aversión al riesgo generada por un evento negativo no esperado. Como consecuencia, la baja en el valor de las acciones refuerza el proceso e incrementa la volatilidad.

Otros estudios que han encontrado evidencia a favor de esta relación negativa entre la volatilidad y los retornos de las acciones comprenden los realizados por Nelson (1991) y Engle y Ng (1993) para muestras de retornos diarios y Glosten et al. (1993) para retornos mensuales. En el caso de los hallazgos de Glosten et al. (1993) los retornos positivos no esperados devienen en una revisión a la baja de la volatilidad y los negativos en una revisión al alza. Por el contrario, Nelson (1991) y Engle y Ng (1993) encuentran que tanto los shocks positivos como negativos incrementan la volatilidad, pero estos últimos provocan revisiones al alza de la volatilidad mayores.

En el caso de Glosten et al. (1993) para argumentar este efecto consideran la relación entre las variaciones de los flujos de fondos esperados, su riesgo y los cambios en los precios de las acciones y retornos. Así, si se asume por un momento tasas de interés de descuento constantes y sin efecto sobre la volatilidad futura y que las variaciones del precio de las acciones se derivan de cambios en los flujos de fondos esperados, un cambio no proporcional en el riesgo de los flujos de fondos con respecto al de las expectativas revisadas de los inversores generará que las variaciones no esperadas del precio de las acciones y sus retornos estén relacionados negativamente con los cambios en la volatilidad futura.

Influencia de variables exógenas

Además de la propia serie histórica de datos analizada otras variables exógenas podrían contener información relevante que afecte la volatilidad, ya sean de otros mercados o eventos específicos como anuncios de resultados, datos macroeconómicos, entre otros. Por ejemplo, Engle, Ng y Rothschild (1990) desarrollan un modelo multivariado a través del cual se asocian las volatilidades del mercado de acciones, bonos y prima de riesgo. También se ha encontrado evidencia que demuestra una mayor correlación entre volatilidades de distintos activos que entre los mismos retornos. Además, ambas correlaciones tienden a incrementarse durante mercados bajistas y crisis financieras (Poon y Granger, 2003).

Distribución de probabilidad con colas pesadas

La distribución de probabilidad de los retornos de activos financieros exhibe colas pesadas con coeficientes de curtosis que típicamente varían en un rango de 4 a 50 y confirman la ausencia de normalidad.

Modelos y herramientas de predicción

En esta sección se abordarán los métodos a evaluar, distinguiendo entre los modelos paramétricos o econométricos y métodos no paramétricos. A tal efecto, de los primeros se han seleccionado los métodos más utilizados y que han demostrado buenos resultados a través de diferentes tipos de activos y regímenes de volatilidad (Brownlees, Engle y Kelly, 2012; Fabris, 2015). De los segundos, se ha elegido un método de uso común (Fabris, 2015) y otro complementario.

Entre los econométricos se probarán los modelos de heterocedasticidad condicional autorregresiva generalizado (GARCH) y GARCH con umbral (TGARCH). En cuanto a los no paramétricos, se evaluarán el método histórico por percentiles y el uso de osciladores.

Es pertinente recordar que los modelos paramétricos se basan en supuestos acerca de la volatilidad esperada, la cual es capturada por diferentes formas funcionales y la naturaleza de las variables contenidas en la información de la serie de datos. En contraposición, los métodos no paramétricos intentan medir directamente la volatilidad sobre dicha serie y hacen caso omiso a la utilización de supuestos acerca de las formas funcionales que gobiernan el proceso analizado (Andersen, Bollerslev y Diebold, 2002).

3.2. Modelos paramétricos

En el apartado precedente se mencionaba que la volatilidad de los retornos financieros varía en el tiempo y tiende a formar agrupamientos en diferentes niveles. En el contexto de análisis de regresión esta característica es conocida como heterocedasticidad y se presenta cuando la varianza de los errores es distinta a través de la serie de datos. El inconveniente que surge al realizar la estimación mediante el método de mínimos cuadrados ordinarios (MCO) es que los errores estándar y los intervalos de confianza quedan subestimados. Para resolver esta cuestión los

modelos de la familia ARCH tratan la heterocedasticidad como una varianza a ser modelada y particularmente ésta es la que resulta de interés como predictor de la volatilidad de los retornos financieros.

Previo al modelo ARCH (Engle, 1982) la mejor herramienta disponible era la volatilidad histórica, definida como la desviación estándar de una cantidad determinada de observaciones. De esta manera, se consideraba que cada una de esas observaciones tenían idéntica ponderación en el pronóstico de la volatilidad del siguiente período. La novedad del modelo ARCH fue permitir la estimación de las ponderaciones de cada una de esas observaciones que mejor represente a la varianza (Engle, 2001).

En cuanto a los datos a considerar para la estimación de los parámetros de los diferentes modelos es preferible utilizar series de la mayor amplitud posible. Sin embargo, a los fines de evitar desalineamiento en los mismos es útil actualizarlos de manera periódica (Brownlees, Engle y Kelly, 2012).

Modelos ARCH

La propuesta de Engle (1982) consiste en estimar simultáneamente la media y la varianza condicional de una serie, es decir, considerando la información hasta el momento en que se realiza el pronóstico. En caso contrario, si se considerasen los valores incondicionales la proyección correspondería al valor de largo plazo.

Para clarificar el concepto, a continuación se asume la estimación de un modelo autorregresivo de media móvil (ARMA) $y_t = a_0 + a_1 y_{t-1} + \varepsilon_t$. La media condicional de y_{t+1} estará dada por

$$E_t y_{t+1} = a_0 + a_1 y_t$$

y la varianza condicional por

$$var(y_{t+1}|y_t) = E_t[(y_{t+1} - a_0 - a_1 y_t)^2] = E_t(\varepsilon_{t+1})^2$$

Si se modela la varianza condicional como un proceso autorregresivo (AR(p)) utilizando los cuadrados de los residuos se tiene

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \alpha_2 \hat{\varepsilon}_{t-2}^2 + \dots + \alpha_p \hat{\varepsilon}_{t-p}^2 + v_t$$

En ese sentido, el modelo más simple de este tipo es

$$\varepsilon_t = v_t \sqrt{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2}$$

donde v_t es un proceso de ruido blanco con $\sigma_v^2 = 1$ y $E v_t = 0$, σ_v^2 y ε_{t-1} son independientes y α_0 y α_1 son constantes con $\alpha_0 > 0$ y $0 \leq \alpha_1 \leq 1$. Para garantizar que la varianza no sea negativa se imponen estas restricciones de no negatividad para α_0 y α_1 y por otro lado se impone que α_1 sea menor o igual a 1 para que el proceso sea estable. En cuanto a los efectos del proceso puede notarse que si el valor de ε_{t-1}^2 es grande, la varianza condicional en t también lo será. Si ocurre un shock inusualmente grande en v_t afectará a ε_t y tenderá a persistir de acuerdo a la magnitud de α_1 (Enders, 2015).

La utilidad de este tipo de modelos se fundamenta en el hecho de que la precisión de un pronóstico tiende a cambiar con el tiempo y la magnitud de los errores suele agruparse formando *clusters*. En el contexto de la teoría de las finanzas en donde un portafolio de inversión en activos financieros es mantenido de acuerdo al retorno esperado y su varianza como medida de riesgo, un cambio en la demanda de esos activos estaría asociado a la variación del retorno esperado y su varianza. Por lo tanto, en los procesos donde la varianza es cambiante y puede predecirse a partir de los errores pasados cobra sentido la utilización de estos modelos (Engle, 1982).

3.2.1. Modelos GARCH

GARCH es una generalización del modelo ARCH de Engle (1982) propuesta por Bollerslev (1986) a través de la cual se modela la varianza condicional como un proceso ARMA. La ecuación de un modelo GARCH (p, q) queda determinada de la siguiente manera:

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i}$$

donde $p \geq 0$, $q > 0$, $\alpha_0 > 0$, $\alpha_i \geq 0$ $i=1, \dots, q$, $\beta_i \geq 0$ $i=1, \dots, p$ y $\sum_{i=1}^q \alpha_i + \sum_{i=1}^p \beta_i < 1$.

Puede notarse que para un orden $p=0$ el proceso resulta en un modelo ARCH(q) visto anteriormente. Nuevamente se establecen condiciones para lograr la no negatividad y la estabilidad del proceso. A diferencia del modelo anterior, el modelo GARCH transforma el proceso en un mecanismo de aprendizaje adaptativo al incorporar los rezagos de la propia varianza condicional

que se modela. La ventaja de esta incorporación es la posibilidad de generar representaciones más parsimoniosas que las que se lograrían con modelos ARCH de órdenes superiores.

Puesto en otros términos, la estimación de la volatilidad se realiza a partir de la media de largo plazo de la varianza, los cuadrados de los retornos representados por los residuos de la regresión de la media condicional, y los desvíos más recientes. La especificación más usual es la de orden (1,1), en particular en series financieras.

Por su parte, los parámetros a estimar son los ponderadores de cada una de las variables mencionadas. La estimación se realiza con el método de máxima verosimilitud que consiste en la elección de los valores que maximicen la probabilidad de ocurrencia de los datos (Bollerslev, 1986; Hull, 2015).

Propiedades de los modelos GARCH (1, 1)

Como sucedía en el caso de los modelos ARCH, en los modelos GARCH también se estiman dos ecuaciones interrelacionadas. Por un lado, se tiene la ecuación de la media condicional

$$y_t = a_0 + \beta x_t + \varepsilon_t$$

donde x_t puede contener variables exógenas o un proceso ARMA.

Por otro lado, ε_t se modela a partir de un proceso GARCH que representa la varianza condicional de la ecuación de la media

$$\varepsilon = v_t (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1})^{0.5}$$

La media incondicional de ε es 0 y la varianza incondicional es $E\varepsilon_t^2 = \alpha_0 / (1 - \alpha_1 - \beta_1)$. No obstante, la varianza condicional del proceso es $h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}$, de manera que la misma no es constante y puede modelarse y pronosticarse dado un proceso y_t .

Las características principales de este tipo de modelos son el reconocimiento de la reversión a la media, la simetría del impacto de los cambios en los retornos, la agrupación de niveles de volatilidad y persistencia, así como también la generación de procesos con distribución leptocúrtica.

En cuanto a la persistencia, puede señalarse que si bien los errores del proceso GARCH no están correlacionados, los cuadrados de los residuos sí lo están y su grado de decaimiento vendrá dado por la sumatoria de los coeficientes $\alpha_1 + \beta_1$. Cuanto mayor sea ésta, más grado de persistencia mostrará el modelo. Sin embargo, la magnitud de cada uno de esos parámetros genera diferentes respuestas. Mientras α_1 captura la sensibilidad a nueva información, β_1 lo hace con respecto al grado de persistencia autorregresiva.

Otro aspecto a considerar es el pronóstico de la varianza condicional más allá de un período. Al respecto, debe tenerse en cuenta que si bien el mismo es posible de calcular de manera recursiva, a medida que se incrementan los períodos a considerar el resultado tenderá hacia el valor de largo plazo, es decir, la varianza incondicional (Bollerslev, 1986; Enders, 2015; Hull, 2015).

3.2.2 Modelos TARARCH

A los efectos de captar el efecto *leverage* mencionado anteriormente, Glosten et al. (1993) desarrollaron el modelo TARARCH. A diferencia de los modelos GARCH precedentes, reconoce la asimetría del efecto de los retornos negativos con respecto a los positivos sobre la volatilidad. Es decir, remarca el incremento de volatilidad ante choques idiosincráticos negativos por encima de los positivos. En este caso, la ecuación de la varianza condicional es

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \lambda_1 d_{t-1} \varepsilon_{t-1}^2 + \beta_1 h_{t-1}$$

donde d_{t-1} es una variable binaria con valor uno si $\varepsilon_{t-1} < 0$ y es cero si $\varepsilon_{t-1} \geq 0$.

De esta manera, cuando $\lambda_1 > 0$ la varianza condicional será afectada en mayor medida cuando los retornos sean negativos. La magnitud del efecto será equivalente a $(\alpha_1 + \lambda_1) \varepsilon_{t-1}^2$ comparado con el efecto $\alpha_1 \varepsilon_{t-1}^2$ que tendría si los rendimientos son positivos.

Pruebas del efecto leverage

Para probar la existencia del efecto asimétrico de los retornos negativos, y por ende, la viabilidad de utilizar un modelo TARARCH, Enders (2015) sintetiza los siguientes métodos. Una manera directa de hacerlo es a través de la estimación del modelo TARARCH y llevar adelante un test t para la hipótesis nula $\hat{\lambda}_1 = 0$. Sin embargo, para un análisis específico pueden formarse los

residuos estandarizados de la estimación de un modelo GARCH de manera que $s_t = \hat{\varepsilon}_t / \hat{h}_t^{1/2}$. A partir de ellos, se estima una regresión del siguiente tipo

$$s_t^2 = a_0 + a_1 s_{t-1} + a_2 s_{t-2} + \dots$$

Habr  efecto apalancamiento si el valor muestral F para la hip tesis nula $a_1 = a_2 = \dots$ supera el valor cr tico F correspondiente. En caso contrario, los cuadrados de los errores no deber an estar correlacionados con los t rminos de los errores.

Otra alternativa es el m todo del test de signo del sesgo desarrollado por Engle y Ng (1993). Este consiste en regresar los cuadrados de los residuos estandarizados sobre una constante y la variable binaria d_{t-1} , es decir, con la siguiente forma

$$s_t^2 = a_0 + a_1 d_{t-1} + \varepsilon_{1t}$$

Donde d_{t-1} es una variable binaria cuyo valor es 1 si s_{t-1} es negativo, y ε_{1t} es el residuo de la regresi n.

El estad stico del test es el estad stico t para el coeficiente a_1 . Si por medio de la prueba se concluye que  ste es estad sticamente significativo distinto de cero, entonces el signo de los retornos es  til para predecir la volatilidad y tiene sentido estimar un modelo TARCh.

3.3. M todos no param tricos

M todo de percentiles

El m todo hist rico por percentiles se basa en la utilizaci n de datos hist ricos y el c lculo del percentil en un momento dado. De esta manera, puede observarse si la volatilidad en un determinado momento es m s alta o m s baja comparativamente con los valores observados en per odos anteriores (Hull, 2015).

Volatilidad hist rica y construcci n de osciladores

Por su parte, el m todo de la volatilidad hist rica se caracteriza por su simplicidad al considerar la muestra de la volatilidad de un per odo determinado como pron stico de la

volatilidad futura. Es decir, se asume que la volatilidad es constante en el período objeto de estimación. Su cálculo está dado por la desviación estándar de los retornos continuos compuestos de ese período y otorga la misma ponderación a cada observación de la muestra. Cabe destacar que la desviación estándar resulta óptima como estimador de la variabilidad para muestras normales, pero pierde eficiencia en la estimación de datos con colas pesadas como los que presentan las series de retornos financieros (Randal, Lally y Thomson, 2004; Walsh y Tsou, 1998).

Un aspecto a resolver en este método es la cantidad de observaciones para calcular la volatilidad histórica. Un enfoque posible es utilizar la cantidad de días equivalentes a la que se pretende aplicar hacia adelante. Sin embargo, debe tenerse en cuenta que el método arrojará mejores resultados cuando se utiliza como muestra períodos más cortos (Hull, 2015; Walsh y Tsou, 1998).

A su vez, el método de oscilador aplicado a la volatilidad consiste en la construcción de dos medias móviles de volatilidades históricas, una de corto plazo y una de mayor plazo. El cruce de la primera hacia arriba de la segunda indica un incremento en la variabilidad en los períodos más recientes mientras que el cruce hacia abajo representa una disminución del nivel de volatilidad.

Las características del comportamiento de la volatilidad muestran que en ciertas ocasiones ésta exhibe valores crecientes y decrecientes. Por su parte, luego de alcanzar valores extremos tiende a regresar a su media de largo plazo.

El oscilador permite advertir el posible inicio de esos cambios. Al respecto, puede construirse en forma gráfica de histograma por el diferencial entre ambas volatilidades. De esta manera pueden detectarse picos de actividad y niveles de estabilización (Natenberg, 1994).

La desventaja de estos métodos es que no arrojan una predicción en sí misma sino que sólo representan un indicio con respecto a los datos pasados. No obstante, teniendo en cuenta la característica de reversión a la media que tiene la volatilidad, en conjunción con otras herramientas pueden ser de utilidad (Randal, Lally y Thomson, 2004).

3.4 El horizonte temporal de predicción

Como consecuencia de las propiedades de las series financieras vistas anteriormente, el grado de precisión de los pronósticos tenderá a variar según el nivel de volatilidad de cada momento, la estructura de volatilidad y el horizonte de predicción (Diebold, Hickman, Inoue y Schuermann, 1998). En el estudio realizado por Brownlees et al. (2012) los autores concluyen que para arribar a mejores resultados es importante considerar una base de datos lo suficientemente amplia y actualizar los parámetros al menos una vez por semana.

Por su parte, se puede afirmar que a nivel general la precisión del pronóstico aumentará cuanto mayor sea la frecuencia de la compresión de tiempo de los datos en relación al horizonte de los pronósticos. Empero, los pronósticos realizados a partir de modelos tienden a perder eficacia cuando los horizontes temporales de predicción son mayores a seis meses. En estos casos, los métodos históricos de baja frecuencia funcionan mejor (Figlewski, 1997; Poon y Granger, 2003).

3.5 Evaluación de los pronósticos realizados

Uno de los aspectos centrales en la construcción de modelos de predicción es la evaluación de los pronósticos realizados, en particular con datos fuera de la muestra utilizada para generar los parámetros del modelo. Esta evaluación permitirá también comparar modelos y descartar aquellos que arrojen resultados inferiores en términos de precisión.

En ese sentido, pueden mencionarse algunas medidas estadísticas usuales utilizadas en la literatura existente para evaluar pronósticos. Entre estas encontramos al error medio (ME), el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). En definitiva, la medida de precisión de la predicción viene determinada por la pérdida promedio alcanzada por cada modelo. Cuanto menor sea esa pérdida, la predicción será mejor.

Además, en la evaluación de pronósticos de volatilidad no debe olvidarse que el valor verdadero de la volatilidad contra el que se compara es inobservable. Por ello, como se mencionaba anteriormente, la comparación se realiza contra un proxy *ex post* de la volatilidad. Para subsanar

esta cuestión, resulta necesario encontrar una función de pérdida que genere el mismo ranking de modelos sin importar qué proxy se utiliza, ya sea los cuadrados de los retornos o la volatilidad realizada. Al respecto, Patton (2011) ha identificado dos funciones de pérdida robustas, entre aquellas utilizadas comúnmente en este tipo de trabajos, que consisten en el MSE y en la cuasi-verosimilitud (QL).

Dichas funciones se definen como sigue:

$$QL: L(\hat{\sigma}_t^2, h_{t|t-k}) = \frac{\hat{\sigma}_t^2}{h_{t|t-k}} - \log \frac{\hat{\sigma}_t^2}{h_{t|t-k}} - 1$$

$$MSE: L(\hat{\sigma}_t^2, h_{t|t-k}) = (\hat{\sigma}_t^2 - h_{t|t-k})^2$$

donde $\hat{\sigma}_t^2$ es un proxy insesgado *ex post* de la varianza condicional, tal como la volatilidad realizada o los retornos cuadrados, y $h_{t|t-k}$ es la volatilidad pronosticada de acuerdo a la información disponible hasta t-k con $k > 0$.

En el caso de la función de pérdida MSE la única dependencia es con respecto al error aditivo mientras que en la función QL la dependencia es con el error multiplicativo. La diferencia entre ambos radica en que el primero presenta niveles altos de dependencia serial respecto a una correcta especificación del modelo de predicción. Además, el sesgo que exhibe MSE resultará proporcional al cuadrado de la varianza real, es decir, que MSE puede exhibir niveles altos de pérdida debido a un incremento brusco en la volatilidad, sin que ello signifique una pérdida en la precisión del modelo. QL, por su parte, permite la comparación independientemente de los regímenes de volatilidad observados (Brownlees et al., 2012; Poon y Granger, 2003).

4. Metodología

En primer término, cabe advertir que este trabajo tiene un enfoque cuantitativo dado que se vale principalmente de la validación de modelos econométricos y métodos no paramétricos basados en la utilización de datos numéricos. Es decir, se hace uso de datos numéricos y análisis estadístico para probar la hipótesis planteada (Sampieri, Fernández Collado y Baptista Lucio, 2010).

Asimismo, tiene un diseño de tipo correlacional. Al respecto, además de validar el funcionamiento de un determinado modelo, se estiman los parámetros que determinan el modelo seleccionado y que posteriormente servirán para realizar predicciones de la volatilidad del mercado de valores local.

Por la naturaleza del objeto de estudio, los modelos dan cuenta de una relación que depende del comportamiento de la misma variable estudiada, dando lugar a la utilización de procesos autorregresivos para dar con los parámetros mencionados.

El presente estudio es de tipo transversal, es decir, con los datos disponibles hasta la fecha pero con implicancias prospectivas. Sin perjuicio de ello, es pertinente señalar que las herramientas que finalmente resultan seleccionadas deben actualizarse con cierta periodicidad para asegurarse de no perder fiabilidad en el nivel de predicción (Fassio y Pascual, 2016).

La principal unidad de análisis es la volatilidad de los retornos diarios de la serie de datos del índice Merval para el período 2010-2017. A tal efecto, se han obtenido los datos oficiales de mercado de los valores del índice Merval a través del sitio web <https://www.bolsar.com> y se han descargado en formato MS Excel.

Para los métodos no paramétricos se han trabajado los datos y se han realizado los cálculos y gráficos en MS Excel. Los modelos econométricos se han trabajado con el software estadístico Eviews y se aplica el enfoque metodológico propuesto por Box y Jenkins (1976). Este método consiste en la ejecución de tres etapas, a saber, la identificación, la estimación y el diagnóstico del modelo. En la primera etapa se observan las gráficas de la serie de datos, las funciones de autocorrelación y autocorrelación parcial y la estacionariedad de la serie como paso previo para tener indicios del modelo adecuado. En la fase de estimación se computan los parámetros, se los examina y se selecciona aquel que tenga mejor grado de ajuste. Por último, en la etapa de diagnóstico se verifica que los residuos del modelo resultante se asemejen a los de un proceso de ruido blanco (Enders, 2015).

Por su parte, las variables analizadas son el retorno y la volatilidad de los mismos. Respecto al primero, se trabaja con retornos compuestos continuos los cuales se definen por la siguiente fórmula: $R_t = \ln \left(\frac{P_t}{P_{t-1}} \right)$, donde R_t es el retorno compuesto continuo del período t , P_t el precio del activo en el período t y P_{t-1} el precio del activo en el período inmediato anterior a t . Cabe recordar

que a diferencia de los retornos discretos, los continuos resultan simétricos, pueden adicionarse entre distintos períodos y permiten analizar con mayor precisión las series y sus propiedades estadísticas. En cuanto a la volatilidad, si bien la misma es inobservable directamente de la serie, es representada por la desviación estándar de los retornos diarios del activo en cuestión (González Isolio y Tapia, 2017; Tsay, 2010).

5. Aplicación al índice Merval en el período 2010-2017

En esta sección se analiza la serie de datos del índice Merval en el período 2010 a 2017 (MVL) con el objetivo de verificar la pertinencia de la aplicación de los modelos econométricos GARCH y TARCH para estimar la volatilidad futura de los retornos diarios del índice y seleccionar el más eficiente. Adicionalmente, se aplican métodos no paramétricos para complementar los pronósticos obtenidos.

En tal sentido, se comienza con el análisis descriptivo de la serie de datos bajo examen para identificar características particulares que indiquen la posibilidad de modelar la volatilidad con los mencionados modelos econométricos.

5.1. Análisis descriptivo de la serie de datos utilizada

Consideraciones preliminares sobre el período bajo examen

En primer lugar, cabe destacar que la serie de datos analizada cuenta con 1948 observaciones. Las mismas corresponden a cotizaciones diarias entre el 04/01/2010 y el 29/12/2017. En la parte superior de la figura 1 puede observarse su representación gráfica en escala semilogarítmica. Si bien este período se caracteriza por un marcado ciclo alcista posterior a la crisis financiera internacional del año 2008, su trayectoria no ha estado exenta de correcciones y períodos de consolidación con diferentes niveles de volatilidad.

En ese orden de ideas, la sección inferior de la figura 1 muestra la volatilidad histórica de 20 ruedas o aproximadamente 1 mes calendario, y la volatilidad anualizada de la muestra que asciende a 30,8075%. Se observa que la primera ha oscilado alrededor de esta última y sus picos en general se corresponden con períodos de corrección.




Figura 1. Cotizaciones diarias del índice Merval período 04/01/2010 a 29/12/2017 en escala semilogarítmica y volatilidad histórica de 20 ruedas anualizada.

Fuente: elaboración propia en base a datos de la Bolsa de Comercio de Buenos Aires y plataforma gráfica TradingView.com.

Por otro lado, a partir de los datos de cotizaciones se calculan los retornos logarítmicos diarios, de manera tal que se obtienen 1947 observaciones que son representadas gráficamente en la figura 2. En el mismo se destaca la alternancia de períodos de tranquilidad relativa y otros de mayor volatilidad que tienden a agruparse, dando lugar a la formación de *clusters* o agrupamientos de volatilidad. Al respecto, el tercer trimestre de 2011, el segundo semestre de 2014 y finales de 2015 son ejemplos de períodos de mayor volatilidad que han denotado cierta persistencia.




Figura 2. Retornos diarios del índice Merval período 04/01/2010 a 29/12/2017, expresados en porcentaje.

Fuente: elaboración propia en base a datos de mercado obtenidos de <https://www.bolsar.com>.

Análisis de la distribución estadística de los retornos diarios

En la figura 3 se exhibe el histograma correspondiente a MVL con sus principales estadísticos. En este gráfico se observa con mayor claridad que la mayor parte de los valores se concentran alrededor del cero con una media de 0,13%. También se aprecia la presencia de colas pesadas a través de su forma leptocúrtica que es confirmada por un valor de curtosis de 5,76, superior al valor de 3 de una distribución normal. De esta forma, es de esperar una mayor probabilidad de ocurrencia de valores extremos comparado con esta última.

Además, presenta una medida de *skewness* o asimetría negativa de -0,40, lo que indica que la cola izquierda es mayor a la que presentaría una distribución normal. Es decir, que no sólo se observarán mayor cantidad de valores extremos sino que entre éstos los negativos tienen mayor probabilidad que los positivos.

Para confirmar la ausencia de normalidad en la distribución de los retornos se ha realizado el contraste de hipótesis mediante el test Jarque-Bera. El estadístico de prueba arroja un valor alto de 672,31 que permite rechazar la hipótesis nula de normalidad a un nivel de significancia del 1%.




Figura 3. Histograma y estadísticos de la serie de retornos diarios del índice Merval período 04/01/2010 a 29/12/2017.

Fuente: elaboración propia en base a datos de mercado obtenidos de <https://www.bolsar.com>.

Presencia de estacionariedad

Otro de los aspectos que pueden inferirse a partir de la figura 2 es la presencia de estacionariedad en la serie. Los valores se concentran alrededor del cero y no se observan tendencias o puntos de ruptura. Para confirmarlo formalmente se ha llevado a cabo el contraste de Dickey-Fuller aumentado (ADF) con intercepto, cuyos resultados se exponen en la tabla 1.

Cabe destacar, que bajo el criterio de información Akaike se ha estimado la regresión sin retardos. Tanto el coeficiente como la constante son estadísticamente significativos y el estadístico Durbin-Watson con un valor aproximado de 2 confirma la ausencia de correlación serial en los errores y por lo tanto la validez del test.

Al respecto, el estadístico ADF supera en términos absolutos al punto crítico correspondiente al 1% de significancia, lo que permite rechazar la hipótesis nula de presencia de raíz unitaria con un nivel de confianza del 99%. Es decir, la prueba permite concluir que la serie es estacionaria.

Tabla 1

Resultados del test de Dickey-Fuller aumentado para la serie de retornos diarios de MVL con intercepto

Descripción	Coeficiente/Valor	Std. Error	Estadístico t	Prob.
LRet(-1)	-0,935124	0,022632	-41,31834	0,0000
C	0,121427	0,044021	2,758407	0,0059
Estadístico ADF			-41,31834	0,0000
Valor crítico ADF 1%			-3,433510	
Valor crítico ADF 5%			-2,862822	
Estadístico Durbin-Watson	2,000773			

Elaboración propia en base a datos de salida de Eviews para el test ADF

Comprobación de existencia de heterocedasticidad condicional autorregresiva

Como se mencionaba anteriormente, en la figura 2 se pueden observar agrupamientos de volatilidad que también son conocidos como heterocedasticidad condicional. A los efectos de validarlo formalmente se ha realizado el test ARCH-LM sobre la regresión auxiliar de los retornos y una constante. La ecuación de esta última estimada por mínimos cuadrados ordinarios (MCO) se resume a $LRet_t = 0,130169 + u_t$.

Sin perjuicio de lo mencionado anteriormente, en la figura 4 se presentan los correlogramas de los residuos (*correlogram of residuals*) y del cuadrado de los residuos (*correlogram of residuals squared*) de la regresión. El primero muestra que sólo existiría correlación con el primer rezago si se considera un nivel de significancia del 1% mientras que el segundo demuestra autocorrelación y autocorrelación parcial de 0,203 para el primer rezago para luego disminuir gradualmente. En la siguiente sección se ahondará en este aspecto al modelar la ecuación de la media de los modelos ARCH. Por su parte, los cuadrados de los residuos al estar correlacionados arrojan un indicio más de existencia de heterocedasticidad en la varianza y cierta persistencia en la misma.

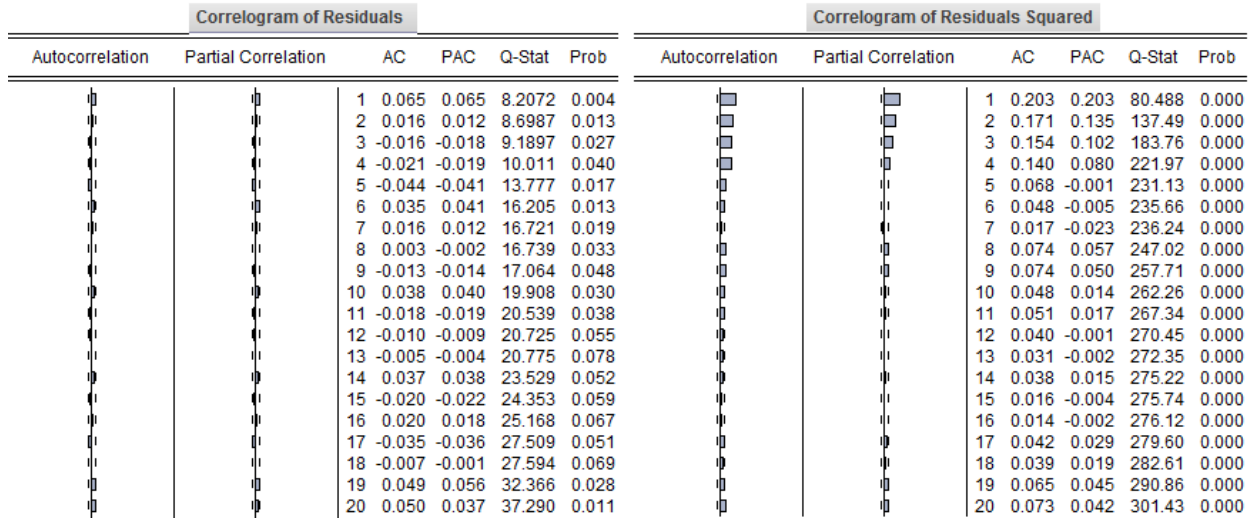


Figura 4. Correlogramas de los residuos y del cuadrado de los residuos de la regresión de retornos y una constante.

Fuente: elaboración propia en base a datos de salida de EViews.

Por su parte, en la tabla 2 se exponen los resultados de la regresión de los residuos cuadrados u_t^2 de la anterior ecuación sobre el rezago de los mismos, a partir del cual se ha efectuado el mencionado test con una hipótesis nula de ausencia de efectos ARCH de primer orden.

También se observan los estadísticos F y el multiplicador de Lagrange (LM) computado como número de observaciones por el coeficiente de determinación. Ambos permiten rechazar la hipótesis nula con un nivel de confianza del 99%, por lo que puede afirmarse que existen efectos ARCH o heterocedasticidad condicional autorregresiva.

Tabla 2

Resultados del test de heterocedasticidad condicional ARCH-LM

Descripción	Coefficiente/ Valor	Std. Error	Estadístico t	Prob.
C	3,000847	0,200775	14,94633	0,0000
u_{t-1}^2	0,203186	0,022208	9,149420	0,0000

Estadístico F (P(1, 1944))	83,71189	0,0000
Estadístico Obs*R ² (P (1))	80,33850	0,0000

Elaboración propia en base a datos de salida de Eviews para el test ARCH-LM.

Síntesis sobre el análisis descriptivo

A través del presente apartado se han analizado las características que presenta la serie de retornos diarios de MVL con el objeto de identificar aspectos que permitan validar la pertinencia de la utilización de modelos econométricos de la familia ARCH en la modelación de la volatilidad.

Al respecto, se han encontrado características típicas de las series financieras que admiten la utilización de dichos modelos. En primer lugar, se destaca la ausencia de normalidad en la distribución de los retornos diarios justificada por la presencia de leptocurtosis y colas pesadas. Los valores se concentran alrededor del cero y se verifica estacionariedad. También se observa asimetría negativa que demuestra que los efectos de shocks negativos son mayores que los positivos.

Por otro lado, se verifica la existencia de heterocedasticidad condicional autorregresiva o efectos ARCH, lo cual se evidencia gráficamente a través de la formación de agrupamientos o *clusters* de volatilidad. En el mismo sentido, se ha observado autocorrelación en el cuadrado de los retornos con una disminución gradual y tendencia a cero a medida que aumentan los rezagos, lo que implicaría cierta persistencia en la volatilidad.

En función de lo expuesto, en las secciones siguientes se evalúan dos modelos de predicción de volatilidad de la familia ARCH, modelos GARCH y TARARCH, de manera tal de comprobar su eficiencia y seleccionar el que mejor se ajuste a las características de la serie MVL.

5.2. Estimación del modelo GARCH para la predicción de volatilidad

En esta sección, se realiza la estimación de los parámetros de un modelo GARCH para la predicción de volatilidad del mercado de valores argentino a partir de los datos de la serie analizada.

Estimación de la ecuación correspondiente a la media condicional del modelo

A esos fines se ha estimado en primer lugar la ecuación de la media condicional. En la sección anterior se había evaluado la ecuación $LRet_t = 0,130169 + u_t$ y el correlograma de los residuos daba indicios de existencia de autocorrelación para el primer rezago. Por lo tanto, se ha incluido como variable un proceso autorregresivo de orden 1 AR(1).

Tabla 3

Resultados de la regresión de los retornos diarios con la inclusión de un proceso AR(1)

Descripción	Coefficiente/Valor	Std. Error	Estadístico t	Prob.
C	0,130197	0,048032	2,710643	0,0068
AR(1)	0,064845	0,015997	4,053520	0,0001

Elaboración propia en base a datos de salida de Eviews.

En la tabla 3 se exponen los resultado de la regresión de los retornos diarios con la inclusión del proceso mencionado anteriormente. Tanto el intercepto como el proceso AR(1) resultan significativos a un nivel de significancia del 1%. Adicionalmente, se ha verificado el correlograma de los residuos y se ha constatado con un nivel de significancia del 5% la eliminación de la correlación serial que se presentaba con la ecuación estimada inicialmente. Nuevamente el correlograma del cuadrado de los residuos evidencia heterocedasticidad que es confirmada por el test ARCH-LM de un rezago con un estadístico F de 94,17548 y Probabilidad F (1, 1944) de 0,0000.

En función de estos resultados, en adelante se estimará la ecuación de la varianza condicional utilizando esta especificación para la media.

Estimación de la ecuación correspondiente a la varianza condicional del modelo

En la tablas 4 y 5 se exponen los parámetros de los modelos GARCH (1,1) estimados bajo los supuestos de distribución normal y distribución t Student en los errores respectivamente. Todos los coeficientes resultaron estadísticamente significativos a los niveles de confianza

convencionales. Por su parte, la suma de los coeficientes ARCH y GARCH arroja en ambas estimaciones un valor inferior a uno (0,942992 para el primero y 0,963912 para el segundo), lo cual implica el cumplimiento de la condición de estabilidad en el proceso. Adicionalmente, esos altos valores indican una elevada persistencia en la volatilidad ante un determinado shock.

En otro orden de ideas, corresponde seleccionar el modelo que mejor se ajuste a la serie analizada. Para ello, se exponen como criterios de selección los valores de la suma del cuadrado de los residuos estandarizados (SSR), criterio de información Akaike (AIC) y del criterio de información de Schwarz o criterio de información bayesiano (BIC). Bajo los tres criterios se selecciona el modelo estimado bajo el supuesto de una distribución t en los errores con 5,916601 grados de libertad. Dicha selección es consistente con el análisis de la distribución estadística de los retornos efectuada en el apartado anterior que indicaba ausencia de normalidad y posible necesidad de acudir a otra distribución para realizar la estimación.

Tabla 4

Estimación de parámetros para un modelo GARCH (1,1) con distribución normal en los errores.

Descripción	Coeficiente/Valor	Std. Error	Estadístico z	Prob.
C	0,231707	0,041980	5,519445	0,0000
ARCH(1)	0,143172	0,015201	9,418670	0,0000
GARCH(1)	0,799820	0,020972	38,13728	0,0000
SSR	7308,618			
AIC	4,026367			
BIC	4,040687			

Elaboración propia en base a datos de salida de Eviews.

Tabla 5

Estimación de parámetros para un modelo GARCH (1,1) con distribución t Student en los errores.

Descripción	Coeficiente/Valor	Std. Error	Estadístico z	Prob.
C	0,154481	0,044798	3,448362	0,0000
ARCH(1)	0,113694	0,019380	5,866463	0,0000
GARCH(1)	0,850218	0,024506	34,69388	0,0000
g.l. distribución t	5,916601	0,856474	6,908091	0,0000
SSR	7302,495			
AIC	3,980431			
BIC	3,997616			

Elaboración propia en base a datos de salida de Eviews.

Pruebas del grado de adecuación del modelo

A partir de la selección del modelo GARCH (1, 1) con distribución t en los errores se han realizado las pruebas de adecuación del modelo para confirmar su validez. Al respecto, en la figura 5 se exponen los correlogramas de los residuos y del cuadrado de los residuos de la regresión. En el primero se puede observar que los coeficientes de autocorrelación son bajos y no son estadísticamente significativos a los niveles convencionales de significancia. Es decir, los residuos estandarizados no estarían serialmente correlacionados y el modelo estaría captando la información relevante.

Correlogram of Standardized Residuals						Correlogram of Standardized Residuals Squared							
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*		
		1	0.031	0.031	1.9319			1	0.011	0.011	0.2183	0.640	
		2	0.041	0.041	5.2884	0.021			2	0.077	0.076	11.637	0.003
		3	-0.030	-0.033	7.0820	0.029			3	-0.007	-0.008	11.726	0.008
		4	-0.011	-0.010	7.3046	0.063			4	0.016	0.011	12.242	0.016
		5	-0.033	-0.030	9.4425	0.051			5	0.012	0.013	12.505	0.028
		6	0.033	0.035	11.564	0.041			6	-0.019	-0.022	13.217	0.040
		7	0.028	0.028	13.091	0.042			7	-0.016	-0.017	13.697	0.057
		8	0.021	0.015	13.988	0.051			8	0.001	0.005	13.701	0.090
		9	-0.021	-0.024	14.885	0.061			9	-0.019	-0.017	14.394	0.109
		10	0.030	0.031	16.623	0.055			10	-0.034	-0.035	16.720	0.081
		11	-0.011	-0.008	16.872	0.077			11	-0.024	-0.020	17.847	0.085
		12	0.000	-0.002	16.872	0.112			12	-0.039	-0.034	20.819	0.053
		13	-0.009	-0.008	17.026	0.149			13	-0.025	-0.022	22.009	0.055
		14	0.029	0.027	18.708	0.132			14	-0.027	-0.021	23.463	0.053
		15	-0.020	-0.019	19.474	0.148			15	-0.020	-0.016	24.220	0.061
		16	0.016	0.013	19.955	0.174			16	-0.015	-0.013	24.682	0.076
		17	-0.022	-0.020	20.880	0.183			17	0.005	0.007	24.722	0.101
		18	0.002	-0.000	20.884	0.232			18	-0.003	-0.002	24.736	0.132
		19	0.043	0.050	24.521	0.139			19	0.011	0.008	24.974	0.161
		20	0.030	0.022	26.271	0.123			20	0.032	0.030	27.009	0.135

Figura 5. Correlogramas de los residuos y del cuadrado de los residuos del modelo GARCH (1, 1) con distribución t en los errores.

Fuente: elaboración propia en base a datos de salida de EViews.

En la sección derecha de la figura 5 se visualiza el correlograma del cuadrado de los residuos para detectar la remanencia de efectos ARCH. A excepción del segundo y tercer rezago, los coeficientes de autocorrelación no son estadísticamente significativos a niveles convencionales de confianza. Por su parte, la realización del test ARCH-LM con un rezago arroja que no es posible rechazar la hipótesis nula de ausencia de efectos ARCH con una probabilidad F (1, 1943) de 0,6409 y un estadístico F de 0,217655. Adicionalmente, se ha realizado el mismo test con 7 rezagos con iguales conclusiones a un nivel de significancia del 5%. En este último caso, con probabilidad F (7, 1931) de 0,0569 no existe evidencia suficiente para rechazar la hipótesis nula y se observa que los coeficientes de los retardos de la regresión no son estadísticamente significativos a niveles convencionales con la excepción del segundo. Por lo tanto, se concluye que el modelo captaría adecuadamente los efectos ARCH.

Por último, para verificar que los residuos del modelo se aproximan a la distribución t Student se han comparado sus respectivos cuantiles. En la figura 6 se observa la representación gráfica de los cuantiles de los residuos estandarizados de la regresión con aquellos que corresponderían al tipo de distribución mencionada. A excepción de valores extremos, la mayoría de los puntos caen sobre la recta que indica aquellos puntos en donde ambos cuantiles coinciden. Por lo tanto, puede considerarse que los errores efectivamente siguen una distribución t Student.




Figura 6. Comparación de los cuantiles de una distribución t con los cuantiles de los residuos estandarizados del modelo GARCH (1, 1) estimado.

Fuente: elaboración propia en base a datos de salida de EViews.

Síntesis sobre la estimación del modelo GARCH para la predicción de volatilidad

En la presente sección se ha realizado la estimación de parámetros de un modelo GARCH (1, 1) para su aplicación al mercado de valores argentino. A tal efecto, se ha definido en primer lugar la ecuación que describe la media condicional del proceso. Para ello, ha sido necesario eliminar la autocorrelación serial que había exhibido la regresión realizada en el apartado anterior. Dicha cuestión fue resuelta mediante la inclusión de un proceso AR(1).

Posteriormente, se han estimado los parámetros de la varianza condicional que es la que resulta de interés a los fines de la predicción de la volatilidad de los retornos financieros. En este sentido, es importante mencionar que los parámetros resultaron estadísticamente significativos a niveles convencionales de significancia y el proceso cumple con la condición de estabilidad. Adicionalmente, refleja la persistencia que caracteriza a la volatilidad ante un determinado shock. Por otro lado, bajo los criterios de selección SSR, AIC y BIC la estimación realizada con el supuesto de una distribución t en los errores ha mejorado los resultados del modelo en comparación con la del supuesto de una distribución normal.

Por último, se han realizado pruebas sobre la adecuación del modelo GARCH (1, 1) con distribución t en los errores. De esta manera, se ha verificado que los residuos estandarizados del modelo no se encontrasen correlacionados serialmente y siguieran una distribución t Student, así como también que no quedasen efectos ARCH remanentes sin considerar.

A raíz de lo analizado, se ha podido concluir que el modelo resulta viable para explicar la volatilidad del mercado de valores argentino. No obstante ello, en la sección siguiente se estimarán los parámetros de un modelo TARCH para verificar su viabilidad y si mejora los resultados alcanzados hasta el momento.

5.3. Estimación del modelo TARCH para la predicción de volatilidad

En esta sección, se realiza la estimación de los parámetros de un modelo TARCH para la predicción de volatilidad del mercado de valores argentino a partir de los datos de la serie bajo examen.

Test de efectos *leverage*

Como paso previo a la estimación mencionada, es necesario validar la pertinencia del modelo. A este fin, se han realizado dos test de diagnóstico de la presencia de efectos *leverage* en los residuos de la estimación del modelo GARCH analizado en la sección anterior. En caso de encontrar estos efectos, a priori, resulta adecuado realizar la estimación de un modelo TARCH.

En primer término, se ha estimado la regresión del cuadrado de los residuos estandarizados del modelo GARCH en función a los rezagos de sus residuos estandarizados. Es decir, la regresión toma la siguiente forma: $s_t^2 = a_0 + a_1s_{t-1} + a_2s_{t-2}$

Tabla 6

Estimación de parámetros de la regresión para un test de *leverage effect*.

Descripción	Coefficiente/Valor	Std. Error	Estadístico t	Prob.
C	0,979059	0,043966	22,26869	0,0000
a1	-0,111685	0,044234	-2,524899	0,0117
a2	-0,162801	0,044262	-3,678170	0,0002
Estadístico F	10.2550			
Prob (Estadístico F)	0,000037			

Elaboración propia en base a datos de salida de Eviews.

En la tabla 6 se observan los coeficientes de cada uno de los rezagos, los cuales resultan significativos, y el estadístico F con un valor de 10,255. De esta manera, a niveles convencionales de confianza se rechaza la hipótesis nula que indica que los coeficientes equivalen conjuntamente a cero. Teniendo en cuenta que el signo de ambos coeficientes es negativo, puede concluirse que los retornos negativos se asocian a valores mayores en la varianza condicional.

Por otra parte, para confirmar dichas conclusiones se ha realizado el test de signo propuesto por Engle y Ng (1993). La regresión a estimar se representa en la ecuación $s_t^2 = a_0 + a_1d_{t-1} + \varepsilon_{1t}$.

Tabla 7

Estimación de parámetros de la regresión para un test de signo de Engle y Ng.

Descripción	Coefficiente/Valor	Std. Error	Estadístico t	Prob.
C	0,854141	0,062923	13,57432	0,0000
a1	0,261057	0,088064	2,964412	0,0031

En la tabla 7 se aprecian los resultados de la regresión aludida. El coeficiente α_1 es estadísticamente significativo a valores convencionales de significancia, de tal manera que permite rechazar la hipótesis nula de que afirma que dicho coeficiente es cero. En consecuencia, valores negativos de s_{t-1} se asocian con valores mayores de s_t^2 , o en otros términos, el signo del shock es útil para predecir el nivel de la varianza condicional.

En función de lo expuesto, puede concluirse que la serie de datos analizada presenta efectos *leverage* y resulta pertinente realizar la estimación de un modelo TARCh. Tal conclusión se ve confirmada en el apartado siguiente al realizar la estimación del modelo y en particular la del parámetro $\hat{\lambda}_1$ que apunta a captar tal característica.

Estimación de la ecuación correspondiente a la varianza condicional del modelo

En este apartado, se presentan los resultados de la estimación de los modelos TARCh (1,1), los cuales han sido computados bajo los supuestos de distribución normal (tabla 8) y distribución t Student en los errores (tabla 9). Todos los coeficientes son positivos y resultaron estadísticamente significativos a los niveles de confianza convencionales, entre ellos el correspondiente al parámetro $\hat{\lambda}_1$. Tal como se adelantara en el apartado anterior, se confirma de esta manera la presencia de efectos *leverage* y la pertinencia de la estimación del modelo. Por su parte, la suma de los coeficientes ARCH, TARCh y GARCH arroja en ambas estimaciones un valor inferior a uno (0,979024 para el primero y 0,994808 para el segundo), lo cual implica el cumplimiento de la condición de estabilidad en el proceso. Nuevamente, esos altos valores indican una elevada persistencia en la volatilidad ante un determinado shock.

Respecto a la selección entre ambos modelos TARCh, la utilización de los criterios SSR, AIC y BIC prioriza el aquel que se ha estimado bajo el supuesto de una distribución t en los errores con 6,041839 grados de libertad. Nuevamente, se observa la consistencia con el análisis de la distribución estadística de los retornos efectuada en el análisis descriptivo que indicaba ausencia de normalidad y posible necesidad de acudir a otra distribución para realizar la estimación.

Tabla 8

Estimación de parámetros para un modelo TAR(1,1) con distribución normal en los errores.

Descripción	Coficiente/Valor	Std. Error	Estadístico z	Prob.
C	0,270895	0,045992	5,890007	0,0000
ARCH(1)	0,098421	0,017403	5,655556	0,0000
TARCH(1)	0,095764	0,021264	4,503548	0,0000
GARCH(1)	0,784839	0,022850	34,34737	0,0000
SSR	7311,594			
AIC	4,021353			
BIC	4,038537			

Elaboración propia en base a datos de salida de Eviews.

Tabla 9

Estimación de parámetros para un modelo TAR(1,1) con distribución t Student en los errores.

Descripción	Coficiente/Valor	Std. Error	Estadístico z	Prob.
C	0,282930	0,065357	4,329026	0,0000
ARCH(1)	0,086247	0,025637	3,364129	0,0008
TARCH(1)	0,128813	0,037689	3,417780	0,0006
GARCH(1)	0,779748	0,031923	24,42570	0,0000
g.l. distribución t	6,041839	0,873856	6,913997	0,0000
SSR	7301,124			
AIC	3,975286			
BIC	3,995335			

Elaboración propia en base a datos de salida de Eviews.

Pruebas del grado de adecuación del modelo

A partir de la selección del modelo TAR(1, 1) con distribución t en los errores se han realizado las pruebas de adecuación del modelo para confirmar su validez. Al respecto, en la figura 7 se exponen los correlogramas de los residuos y del cuadrado de los residuos de la regresión. En el primero se puede observar que los coeficientes de autocorrelación son bajos y no son estadísticamente significativos a los niveles convencionales de significancia. Es decir, los residuos

estandarizados no estarían serialmente correlacionados y el modelo estaría captando la información relevante.

Correlogram of Standardized Residuals						Correlogram of Standardized Residuals Squared						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	
		1	0.025	0.025	1.2583			1	-0.011	-0.011	0.2349	0.628
		2	0.046	0.045	5.2954	0.021		2	0.032	0.031	2.1720	0.338
		3	-0.033	-0.035	7.3962	0.025		3	-0.011	-0.011	2.4242	0.489
		4	0.000	-0.000	7.3962	0.060		4	0.014	0.013	2.8230	0.588
		5	-0.031	-0.028	9.2421	0.055		5	0.025	0.026	4.0328	0.545
		6	0.037	0.037	11.865	0.037		6	-0.016	-0.016	4.5136	0.608
		7	0.024	0.025	12.968	0.044		7	0.001	-0.000	4.5180	0.719
		8	0.019	0.012	13.642	0.058		8	0.003	0.004	4.5319	0.806
		9	-0.023	-0.024	14.693	0.065		9	-0.013	-0.014	4.8812	0.845
		10	0.033	0.034	16.850	0.051		10	-0.025	-0.026	6.1360	0.804
		11	-0.015	-0.012	17.307	0.068		11	-0.003	-0.002	6.1594	0.863
		12	-0.001	-0.005	17.309	0.099		12	-0.020	-0.019	6.9242	0.863
		13	-0.007	-0.004	17.394	0.135		13	-0.015	-0.015	7.3410	0.884
		14	0.036	0.033	19.895	0.098		14	-0.011	-0.009	7.5758	0.910
		15	-0.024	-0.023	21.064	0.100		15	-0.010	-0.008	7.7534	0.933
		16	0.014	0.010	21.475	0.122		16	0.007	0.007	7.8387	0.954
		17	-0.022	-0.019	22.453	0.129		17	0.016	0.018	8.3169	0.959
		18	0.003	0.001	22.472	0.167		18	0.005	0.005	8.3660	0.973
		19	0.044	0.052	26.340	0.092		19	0.029	0.028	9.9668	0.954
		20	0.030	0.021	28.091	0.082		20	0.038	0.039	12.870	0.883

Figura 7. Correlogramas de los residuos y del cuadrado de los residuos del modelo TAR(1, 1) con distribución t en los errores.

Fuente: elaboración propia en base a datos de salida de EViews.

En la sección derecha de la figura 7 se visualiza el correlograma del cuadrado de los residuos para detectar la remanencia de efectos ARCH. En este sentido, se confirma que los coeficientes de autocorrelación no son estadísticamente significativos a niveles convencionales de confianza. A su vez, la realización del test ARCH-LM con un rezago arroja que no es posible rechazar la hipótesis nula de ausencia de efectos ARCH con una probabilidad $F(1, 1943)$ de 0,6284 y un estadístico F de 0,234262. A iguales conclusiones se arriba al realizar el mismo test con 7 rezagos, considerando niveles convencionales de significancia. En este último caso, con probabilidad $F(7, 1931)$ de 0,7202 no existe evidencia suficiente para rechazar la hipótesis nula y se observa que los coeficientes de los retardos de la regresión no son estadísticamente significativos. Por lo tanto, se concluye que el modelo captaría adecuadamente los efectos ARCH.

Finalmente, para verificar que los residuos del modelo se aproximan a la distribución t Student se han comparado sus respectivos cuantiles. En la figura 8 se observa la representación gráfica de los cuantiles de los residuos estandarizados de la regresión con aquellos que corresponderían al tipo de distribución mencionada. A excepción de valores extremos, la mayoría

de los puntos caen sobre la recta que indica aquellos puntos en donde ambos cuantiles coinciden. Se observa además, una mayor coincidencia respecto a la comparación de cuantiles efectuada respecto al modelo GARCH. En resumen, puede considerarse que los errores efectivamente siguen una distribución t Student.

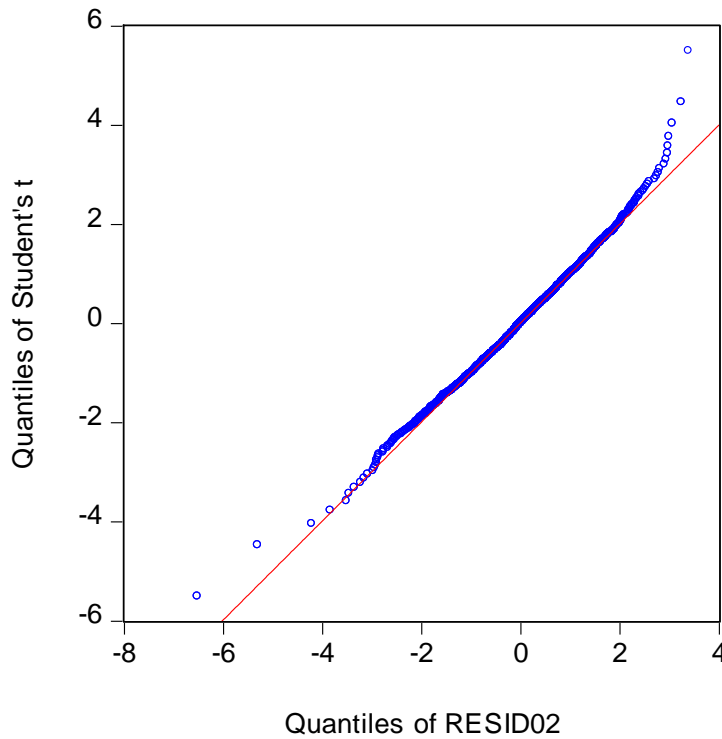


Figura 8. Comparación de los cuantiles de una distribución t con los cuantiles de los residuos estandarizados del modelo TAR(1, 1) estimado.

Fuente: elaboración propia en base a datos de salida de EViews.

Síntesis sobre la estimación del modelo TAR(1, 1) para la predicción de volatilidad

En la presente sección se ha realizado la estimación de parámetros de un modelo TAR(1, 1) para su aplicación al mercado de valores argentino. Como paso preliminar, se ha validado la pertinencia de la estimación de este tipo de modelos a través de la verificación de la presencia de efectos *leverage*, que son los que este modelo intenta capturar.

Posteriormente, se han estimado los parámetros de la varianza condicional, los cuales resultaron estadísticamente significativos a niveles convencionales de significancia. Al igual que en la estimación del modelo GARCH, bajo los criterios de selección SSR, AIC y BIC la estimación realizada con el supuesto de una distribución t en los errores ha mejorado los resultados en comparación con la del supuesto de una distribución normal.

Además, se han realizado pruebas sobre la adecuación del modelo TARARCH (1, 1) con distribución t en los errores. Al respecto, se ha verificado que los residuos estandarizados del modelo no se encontrasen correlacionados serialmente y siguieran una distribución t Student, así como también que no quedasen efectos ARCH remanentes sin considerar.

En función del análisis realizado, se ha podido concluir que este modelo también resulta viable para explicar la volatilidad del mercado de valores argentino, así como también captar los efectos asimétricos que presentan las series de retornos financieros.

Sin perjuicio de lo expuesto, en el siguiente apartado se compararán los resultados de los modelos GARCH (1,1) y TARARCH (1,1) con distribución t en los errores, de manera de seleccionar aquel que presente mejores resultados a los fines de la predicción de la volatilidad de los retornos financieros del mercado de valores argentino.

5.4. Selección del modelo paramétrico

En este apartado, se efectúa la comparación de los modelos paramétricos analizados, de manera tal de seleccionar aquel que exhibe el mejor rendimiento. A este efecto, además de recurrir a los criterios de selección utilizados hasta el momento, se emplean las medidas de pérdida robustas QL y MSE, propuestas por Patton (2011).

A diferencia de las pruebas realizadas anteriormente, en este apartado tal rendimiento es medido frente a la volatilidad realizada, considerando como un proxy de ésta al cuadrado de los retornos.

5.4.1. Prueba y selección partir de datos dentro de la muestra

En primer término se realiza la prueba del rendimiento con datos dentro de la muestra. Es decir, se ha utilizado la estimación de parámetros a partir de la totalidad de datos de la serie MVL

de acuerdo a lo expuesto en los apartados anterior. En el mismo sentido, se contrastado la volatilidad realizada de la totalidad de dicha serie con la predicción arrojada por cada modelo.

Tabla 10

Comparación del rendimiento de la predicción de volatilidad de los modelos paramétricos analizados

Modelo	AIC	BIC	MSE	QL
GARCH (1,1) distribución n	22.832,23	22.848,95	64,25	0,7192
GARCH (1,1) distribución t	22.828,12	22.844,84	64,12	0,7089
TARCH (1,1) distribución n	22.828,81	22.851,10	64,07	0,7220
TARCH (1,1) distribución t	22.834,83	22.857,12	64,27	0,7183

Elaboración propia en base a datos de salida de Eviews.

En la tabla 10 se exponen los valores que arrojan cada uno de los criterios de selección aplicados sobre los resultados de los modelos analizados, esto es, los modelos GARCH y TARCH con distribución normal y distribución t en los errores. Se resaltan en negrita aquellos que indican la superioridad del modelo en cuestión.

Como se puede apreciar, el modelo GARCH (1,1) con distribución t en los errores resulta superior al resto bajo los criterios AIC, BIC y la utilización de la función de pérdida QL.

Es de destacar que en el modelo GARCH, la suposición de distribución t en los errores ha mejorado los resultados bajo todos los criterios con respecto al supuesto de distribución normal. No obstante ello, en los modelos TARCH no se observa tal mejora, a excepción del caso de la función robusta de pérdida QL.

De acuerdo a estos resultados, se infiere que la utilización de un modelo TARCH, si bien empleado para captar la asimetría que exhiben los retornos, no necesariamente mejora el poder de predicción para el índice MVL en el período analizado. Por su parte, la suposición de distribución t en los errores presenta mejoras en los resultados en el caso del modelo GARCH y no resulta concluyente respecto al modelo TARCH.

5.4.2. Prueba y selección partir de datos fuera de la muestra

En esta sección, se realiza la prueba de eficacia de los modelos para datos fuera de la muestra. Esta es la de mayor interés, puesto que dichos modelos son efectuados para su aplicación prospectiva.

Al respecto, se computan en primer lugar los parámetros de cada modelo a partir de la muestra de la serie MVL correspondiente a los períodos 2010 hasta 2016. Posteriormente, se realiza la evaluación de cada modelo sobre la predicción de volatilidad para el período 2017, es decir, datos fuera de la muestra utilizada para computar los parámetros.

En la tabla 11 se exponen los parámetros de cada modelo analizado, computados a partir de la muestra de datos correspondientes a los períodos 2010 a 2016 inclusive. Las pruebas de adecuación de los modelos para esta muestra arrojan iguales conclusiones a las del período completo antes analizado. Por lo tanto, a los fines de evitar la reiteración se han omitido sus resultados.

Tabla 11

Estimación de parámetros para los modelos GARCH (1,1) y TARCH (1,1) con distribución normal y t Student en los errores, a partir de datos de la muestra de los períodos 2010 a 2016

Modelo	Parámetro	Coficiente/Valor	Std. Error	Estadístico z	Prob.
GARCH (1,1) con distribución	C	0,297853	0,057603	5,170811	0,0000
	ARCH(1)	0,140292	0,016505	8,500221	0,0000
	GARCH(1)	0,790778	0,024497	32,28028	0,0000

normal en los errores					
GARCH (1,1)	C	0,209038	0,063585	3,287565	0,0010
con distribución t	ARCH(1)	0,118033	0,021901	5,389485	0,0000
en los errores	GARCH(1)	0,836232	0,029594	28,25646	0,0000
TARCH (1,1)	C	0,355059	0,063205	5,617541	0,0000
con distribución	ARCH(1)	0,091990	0,019162	4,800648	0,0000
normal en los	TARCH(1)	0,098670	0,023611	4,178967	0,0000
errores	GARCH(1)	0,773794	0,026493	29,20727	0,0000
TARCH (1,1)	C	0,352030	0,086960	4,048200	0,0001
con distribución t	ARCH(1)	0,081365	0,027527	2,955805	0,0031
en los errores	TARCH(1)	0,124520	0,039978	3,114679	0,0018
	GARCH(1)	0,774826	0,036567	2,118896	0,0000

Elaboración propia en base a datos de salida de Eviews.

Por su parte, en la tabla 12 se observan los valores que arrojan cada uno de los criterios de selección aplicados sobre los resultados de los modelos analizados. Se resaltan en negrita aquellos que indican la superioridad del modelo en cuestión.

Nuevamente el modelo GARCH (1,1) con distribución t en los errores resulta ser el modelo de mejor rendimiento, a excepción de su medición bajo la función de pérdida QL.

En esta ocasión, la suposición de distribución t en los errores para el modelo GARCH ha mejorado los resultados, salvo en el caso de su medición bajo la función QL. Lo contrario sucede con los modelos TARCH, de manera similar a la que sucedió en las pruebas con datos dentro de la muestra.

En función de la evidencia analizada, se infiere que la utilización de un modelo TARCH no necesariamente mejora el poder de predicción para el índice MVL en el período analizado con respecto a los modelos GARCH. De los cuatro criterios de selección utilizados, sólo la función QL abogaría la preferencia de los modelos TARCH. Adicionalmente, la suposición de distribución t en los errores presenta mejoras en los resultados en el caso del modelo GARCH y no resulta

concluyente respecto al modelo TARARCH, a excepción del caso en que se miden bajo la función QL.

Tabla 12

Comparación del rendimiento de la predicción de volatilidad de los modelos paramétricos analizados sobre datos fuera de la muestra

Modelo	AIC	BIC	MSE	QL
GARCH (1,1) distribución n	1.897,71	1.908,21	9,21	0,4612
GARCH (1,1) distribución t	1.894,35	1.904,85	9,08	0,4717
TARARCH (1,1) distribución n	1.897,67	1.911,68	9,13	0,4432
TARARCH (1,1) distribución t	1.897,95	1.911,96	9,14	0,4388

Elaboración propia en base a datos de salida de Eviews.

En la figura 9 se grafican las trayectorias de la volatilidad realizada y la volatilidad pronosticada en el período correspondiente al año 2017. En el primer caso, se ha utilizado como proxy el cuadrado de los retornos, mientras que el último constituye el pronóstico para datos fuera de la muestra efectuado con la utilización del modelo GARCH (1,1) con distribución t en los errores.

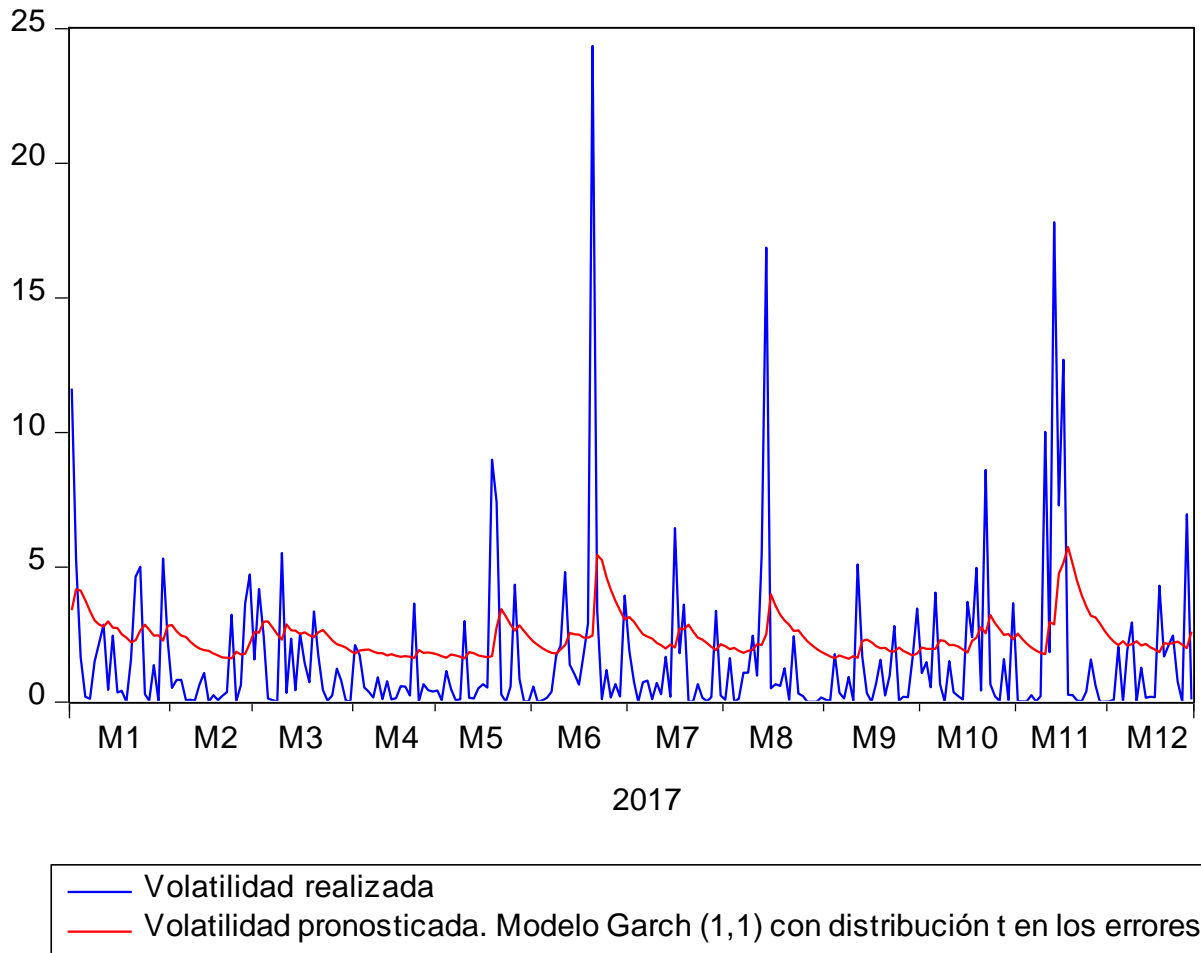


Figura 9. Comparación gráfica de la volatilidad realizada y la volatilidad pronosticada por el modelo GARCH (1,1) con distribución normal en los errores.

Fuente: elaboración propia en base a datos de salida de EViews.

De la apreciación gráfica, se observa que el modelo capta las características de la volatilidad de las series financieras. Así, por ejemplo, se observa la corrección de la predicción ante grandes shocks, que elevan su nivel. También se distingue la persistencia de un determinado shock y su posterior decaimiento hacia un valor medio de largo plazo.

Síntesis sobre la selección del modelo paramétrico

Este apartado ha sido dedicado a la prueba de los modelos paramétricos analizados y selección de aquel que ha exhibido el mejor rendimiento para la predicción de la volatilidad en el mercado de valores argentino.

A tal efecto, se han realizado pruebas tanto con datos dentro de la muestra como con datos fuera de ésta, teniendo en cuenta que estas últimas son las de principal importancia dado su carácter prospectivo. Para su ejecución, se han estimado los parámetros de los modelos utilizando como datos de entrada los del período comprendido entre 2010 a 2016 inclusive. Posteriormente, se ha medido su rendimiento sobre los datos del año 2017 que no forman parte de la muestra considerada para la estimación de los mencionados parámetros.

Es de destacar que se han utilizado como criterios de selección el AIC, BIC, MSE y la función de pérdida QL. De las pruebas efectuadas, puede concluirse que el modelo GARCH (1,1) con distribución t en los errores resulta superior al resto tanto considerando datos dentro de la muestra como con datos fuera de ella y en tres de los cuatro criterios empleados.

Por su parte, se infiere que la utilización de un modelo TARARCH, si bien empleado para captar la asimetría que exhiben los retornos de las series financieras, no necesariamente mejora el poder de predicción para el índice MVL en el período analizado. La excepción se encuentra dada por la utilización de la función de pérdida QL, en contraste con los demás criterios.

Además, la suposición de distribución t en los errores presenta mejoras en los resultados en el caso del modelo GARCH y no resulta concluyente respecto al modelo TARARCH, a excepción del caso en que se miden bajo la función QL.

Por último, la gráfica de la volatilidad realizada y la pronosticada por el modelo seleccionado, denota las capacidades del modelo para captar las características de la volatilidad y su seguimiento. Así, se observa la corrección de la predicción ante grandes shocks así como también la persistencia en los niveles de volatilidad luego de ocurrido los mismos. También se aprecia el decaimiento hacia el valor medio de largo plazo.

En la sección siguiente, se evalúan métodos no paramétricos que podrían ser de utilidad para complementar el análisis llevado a cabo con los modelos estudiados hasta aquí. En este

sentido, se utilizará como método principal la construcción de la volatilidad histórica como predictor de la volatilidad futura. También osciladores para generar indicios de cambios en los niveles de volatilidad.

5.5. Métodos no paramétricos

A continuación, se desarrollan los resultados obtenidos a partir de la utilización de método no paramétricos para la predicción de volatilidad. En este sentido, se computa en primer término la volatilidad histórica y su rendimiento como predictor de la volatilidad realizada para todo el período analizado. Posteriormente, se construye un oscilador como indicador de potenciales cambios en los niveles exhibidos.

Volatilidad histórica

A partir de los datos de la serie MVL para el año 2017, se ha computado las volatilidades históricas de 10 (VH10), 20 (VH20) y 40 (VH40) días. En la tabla 13 se observan las pruebas de rendimiento de la volatilidad histórica como predictor de la volatilidad realizada.

Tabla 13

Comparación del rendimiento de la predicción utilizando la volatilidad histórica para el período 2017

Modelo	AIC	BIC	MSE	QL
Volatilidad histórica 10 días	1.898,20	1.912,21	9,15	1,0436
Volatilidad histórica 20 días	1.876,33	1.890,34	8,37	0,7555
Volatilidad histórica 40 días	1.874,36	1.888,37	8,30	0,6839

Elaboración propia en base a datos de mercado obtenidos de <https://www.bolsar.com>.

Se observa que la VH40 presente los mejores resultados bajo todos los criterios de selección. Al comparar contra los resultados de los modelos paramétricos de la tabla 12 se observa que la VH20 y VH40 arrojan mejores resultados bajo los criterios AIC, BIC y MSE. Sin embargo, los resultados bajo la función de pérdida QL exhiben valores superiores con un considerable margen, a diferencia de lo que sucedía entre los distintos modelos paramétricos, en los que la

diferencia era escasa. De esta manera, se obtiene una señal de advertencia para concluir acerca de su superioridad.

Por su parte, en la figura 10 se contrastan las trayectorias de la volatilidad realizada y cada una de las volatilidades históricas analizadas. De la gráfica, se verifica que al computar mayor plazo para su construcción, peor es la capacidad del método para captar la información de los shocks que elevan la volatilidad a niveles extremos. Por el contrario, las de menores plazos se adecúan mejor pero aun así, lo hacen con el rezago proveniente de la cantidad de períodos elegidos para su construcción.

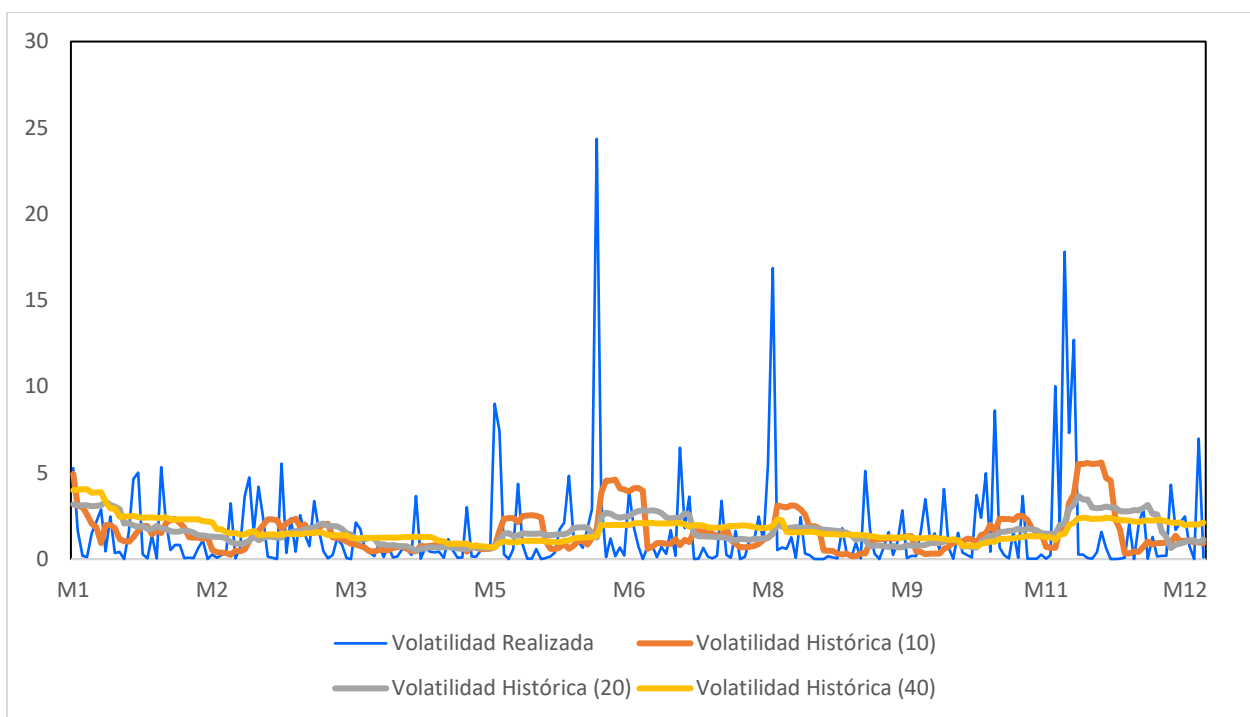


Figura 10. Comparación gráfica de la volatilidad realizada y la volatilidad pronosticada por los métodos no paramétricos

Fuente: elaboración propia en base a datos de mercado obtenidos de <https://www.bolsar.com>.

Osciladores de volatilidad histórica

Del análisis realizado anteriormente, puede concluirse que la volatilidad histórica puede ser de utilidad como predictor de la volatilidad. No obstante, en este trabajo se propone su uso de

manera complementaria a partir del cálculo de un oscilador que otorgue información adicional a la del modelo elegido.

Al respecto, se ha computado un oscilador calculado a partir de la diferencia entre las VH10 y la VH20 que son las que presentan respuesta más rápida ante los distintos cambios.

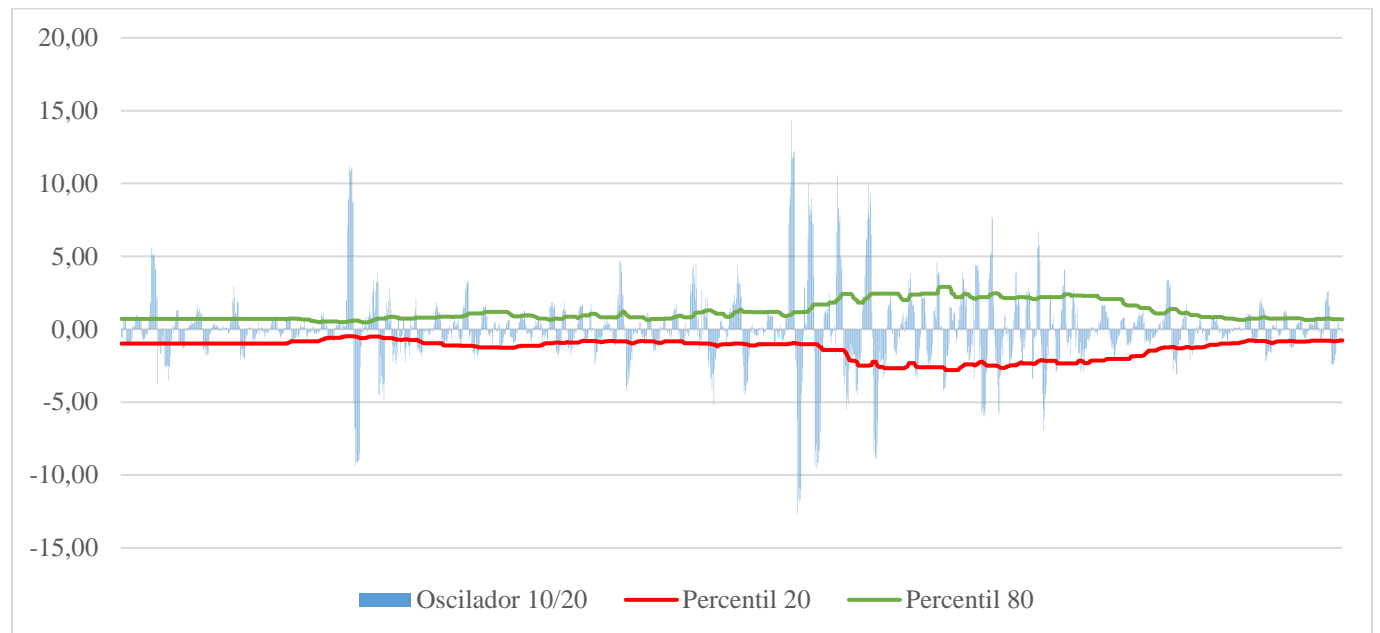


Figura 11. Oscilador de volatilidades históricas de 10 y 20 días para el período 2010-2017

Fuente: elaboración propia en base a datos de mercado obtenidos de <https://www.bolsar.com>.

En la figura 11 se grafica el oscilador como histograma para el período 2010 a 2017, en el cual un valor positivo indica que la volatilidad de corto plazo, representada por la VH10, se está incrementando con respecto a la volatilidad de mayor plazo, en este caso la de 20 ruedas.

Asimismo, se han graficado los percentiles 20 y 80 del valor del oscilador, para el cual se ha considerado un período móvil de 252 ruedas, o aproximadamente 1 año. Al respecto, debe recordarse que una de las características de la volatilidad en series financieras es la reversión a la media. Por lo tanto, un cruce del oscilador hacia valores extremos otorga indicios de una posible reversión.

En ese sentido, para el período analizado el oscilador ha permanecido en valores extremos un 45% del tiempo, para lo cual ha cruzado 77 veces el umbral superior y 91 veces el inferior. Los

cruces por debajo del percentil 20 han durado un promedio de 5,36 días, con una mediana de 4 días, un máximo de 15 días y un mínimo de 1 día. Por su parte, la superación del umbral superior se ha mantenido 5,02 días en promedio, con una mediana de 3, un máximo de 24 y un mínimo de 1 día.

Esta información resulta valiosa si se la considera como complemento de un predictor de volatilidad. No sólo se obtendrá un valor concreto, sino que también se tendrá referencia del punto de partida para coadyuvar al proceso de toma de decisiones.

Síntesis sobre el análisis de métodos no paramétricos

En esta sección se han analizado métodos no paramétricos para su aplicación en el análisis de la predicción de la volatilidad. Así, se ha probado el rendimiento de la volatilidad histórica como predictor de la volatilidad realizada, para lo cual se han empleado períodos de 10, 20 y 40 ruedas.

Al respecto, se observa que a menor plazo considerado, la efectividad del pronóstico decrece a pesar de exhibir gráficamente una reacción más rápida ante los cambios en los niveles de volatilidad. Por el contrario, a mayores plazos el rendimiento mejora bajo su medición por los criterios de AIC, BIC, y MSE. Su acercamiento a la volatilidad de largo plazo causaría esa mejor medición. Sin embargo, la medición bajo la función QL arroja una advertencia al compararlo contra los métodos paramétricos, puesto que exhibe rendimientos endeble.

Por otro lado, se ha construido un oscilador de volatilidad histórica, empleando los períodos de 10 y 20 ruedas, de manera tal de contar con un indicador de potenciales aceleraciones o desaceleraciones en el nivel de volatilidad. Además, se han graficado conjuntamente con los percentiles 20 y 80 como indicador de potenciales extremos en los cuales es de esperar una reversión hacia la media de largo plazo.

De esta manera, en el presente trabajo se ha propuesto la utilización complementaria de las herramientas no paramétricas a los efectos de contar con una guía adicional de la posición relativa del nivel de volatilidad.

6. Conclusiones y consideraciones finales

A lo largo de este trabajo, se han evaluado métodos paramétricos y no paramétricos para la predicción de la volatilidad en el mercado de valores argentino.

Entre los primeros, se han sometido a evaluación los modelos GARCH y TARCH, que presentan en general los mejores resultados en series financieras (Brownlees, Engle y Kelly, 2012). Asimismo, se ha propuesto que los resultados de estos modelos pueden complementarse con métodos no paramétricos, para lo cual se ha utilizado la volatilidad histórica como predictor, y la construcción de un oscilador de volatilidad histórica conjuntamente con percentiles de volatilidad.

A fines de validar la pertinencia de los métodos mencionados, se evaluó en primer término la serie MVL cuyos datos abarcan el período 2010 a 2017. Al respecto, se han encontrado características típicas de las series financieras que admiten la utilización de dichos modelos, tales como la ausencia de normalidad en la distribución de los retornos diarios, presencia de colas pesadas, estacionariedad, asimetría negativa y existencia de heterocedasticidad condicional autorregresiva o efectos ARCH, lo cual se evidencia gráficamente a través de la formación de agrupamientos o *clusters* de volatilidad. También se ha observado cierta persistencia en los niveles de volatilidad ante un determinado shock.

Posteriormente, se ha realizado la estimación de los parámetros de los modelos GARCH y TARCH bajo la suposición de una distribución normal y distribución *t* en los errores, así como también el grado de adecuación de los modelos. Además, se ha evaluado su rendimiento tanto con datos dentro de la muestra como con datos fuera de ella, para lo cual se ha utilizado como proxy de la volatilidad a la volatilidad realizada.

De las pruebas efectuadas, se ha concluido que el modelo GARCH (1,1) con distribución *t* en los errores ha resultado superior al resto. Por su parte, se infiere que la utilización de un modelo TARCH, si bien empleado para captar la asimetría que exhiben los retornos de las series financieras, no necesariamente mejora el poder de predicción para el índice MVL en el período analizado.

Además, la suposición de distribución t en los errores ha presentado mejoras en los resultados en el caso del modelo GARCH y no ha resultado concluyente respecto al modelo TARARCH, a excepción del caso en que se miden bajo la función QL.

A su vez, la gráfica de la volatilidad realizada y la pronosticada por el modelo seleccionado, ha denotado las capacidades del modelo para captar las características de la volatilidad y su seguimiento. Así, se ha observado la corrección de la predicción ante grandes shocks así como también la persistencia en los niveles de volatilidad luego de ocurrido los mismos. También se ha apreciado el decaimiento hacia el valor medio de largo plazo.

En cuanto a los métodos no paramétricos, se han evaluado las volatilidades históricas con períodos de 10, 20 y 40 ruedas, a partir de los cuales se ha concluido que a períodos más cortos, los rendimientos de la predicción resultan inferiores al de los modelos paramétricos. Por el contrario, al incrementar los períodos, los valores pronosticados se han acercado a los niveles de largo plazo y arrojan mejores resultados bajo los criterios AIC, BIC y MSE. Sin embargo, los resultados bajo la función QL han arrojado resultados que no permiten ser concluyentes para favorecerlos.

Con fines de elaborar una herramienta complementaria al modelo paramétrico seleccionado, se ha propuesto la construcción de un oscilador de la volatilidad histórica de 10 y 20 días y la utilización de los percentiles 20 y 80. A través de los mismos, se obtiene información de la posición relativa del nivel de volatilidad. Un cruce por encima o por debajo de los extremos, advierte sobre posibles inicios de reversiones hacia el valor medio de largo plazo.

Por último, debe destacarse que ciertas áreas no han sido abordadas en la presente obra y resultan de interés para futuros trabajos que versen sobre el mercado de valores argentino. En este sentido, la cantidad de datos empleados, el horizonte de la predicción y la frecuencia de la estimación de parámetros son aspectos que merecen atención, en particular ante la detección en el cambio de los regímenes de volatilidad (Ang y Timmermann, 2011).

7. Referencias bibliográficas

- Andersen, T. G. y Bollerslev, T. (1998). Answering the skeptics: yes, standard volatility models do provide accurate forecasts. *International Economic Review*, 39/(4), 885–905.
- Andersen, T. G., Bollerslev, T. y Diebold, F. X. (2002). Parametric and Nonparametric Volatility Measurement. En L. P. Hansen y Y. Ait-Sahalia (Eds.), *Handbook of Financial Econometrics* (pp. 67-138). Amsterdam: North-Holland.
- Ang, A. y Timmermann, A. (2011). Regime changes and financial markets. *NBER Working Paper No. 17182*. Recuperado de <http://www.nber.org/papers/w17182> (27/11/17).
- Bahi, A. (2007). *Modelos de medición de la volatilidad en los mercados de valores: aplicación al mercado bursátil argentino* (tesis de maestría). Universidad Nacional de Cuyo, Mendoza.
- Black, F., (1976). Studies of stock price volatility changes. *Proceedings of the 1976 Meeting of Business and Economics Statistics Section of the American Statistical association*, 27, 399-418.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31, 307–327.
- Box, G. E. P. y Jenkins, J. M. (1976). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Brownlees, C., Engle, R. y Kelly, B. (2012). A practical guide to volatility forecasting through calm and storm. *The Journal of Risk*, 14/(2), 3-22.
- Diebold, F. X., Hickman, A., Inoue, A. y Schuermann, T. (1998). Scale models. *Risk Magazine*, 11, 104–107.
- Ding, Z., Granger, C. W. J. y Engle, R. F. (1993). A long memory property of stock market returns and a new model. *Journal of Empirical Finance*, 1, 83–106.
- Enders, W. (2015). *Applied Econometric Time Series*. Alabama: Wiley.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50/(4), 987–1007.

- Engle, R. F., Ng, V. K. y Rothschild M. (1990). Asset pricing with a factor-ARCH covariance structure. *Journal of Econometrics*, 45, 213–237.
- 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.
- Engle, R. F. (2001). GARCH 101: The use of ARCH/GARCH models in applied econometrics. *The Journal of Economic Perspectives*, 15/(4), 157–168.
- Engle, R. F. y Patton, A. J. (2001). What good is a volatility model? *Quantitative Finance*, 1/(2), 237–245.
- González Isolio D. y Tapia G. (2017). *Instrumentos de renta fija y variable*. Buenos Aires: La Ley.
- Fabris, J. E. (2015). Estimación del riesgo bursátil mediante regresión por cuantiles. *Revista de Investigación en Modelos Financieros*, 1/(4), 87-102.
- Fassio, A. y Pascual, L. (2016). *Apuntes para desarrollar una investigación en el campo de la administración y el análisis organizacional*. Buenos Aires: Eudeba.
- French, K. R., Schwert, G. W., and Stambaugh, R. F. (1987). Expected stock returns and volatility. *Journal of Financial Economics*, 19, 3–29.
- Figlewski, S. (1997). Forecasting volatility. *Financial Markets, Institutions and Instruments*, 6/(1), 1–88.
- 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. *Journal of Finance*, 48/(5), 1779–1801.
- Hull, J. C. (2015). *Options, futures, and other derivatives*. New Jersey: Pearson.
- IAMC (2017). *Metodología MERVAL* Recuperado de http://iamcmediamanager.prod.ingeccloud.com/mediafiles/iamc/2017/9_7/0/10/76/674819.pdf (27/11/17).
- Natenberg, S. (1994). *Option volatility and pricing*. New York: McGraw-Hill.

- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*, 59/(2), 347–370.
- Pagan, A. R. y Sossounov K. R. (2003). A simple framework for analyzing bull and bear markets. *Journal of Applied Econometrics*, 18, 23–46.
- Patton, A. J. (2011). Volatility forecast comparison using imperfect volatility proxies. *Journal of Econometrics*, 160, 246–256.
- Poon, S. H. y Granger C. W. J. (2003). Forecasting volatility in financial markets. *Journal of Economic Literature*, 41, 478–539.
- Randal, J., Lally, M. y Thomson, P. J. (2004). Non-parametric estimation of historical volatility. *Quantitative Finance*, 4/(4), 427–440.
- Sampieri, R. H., Fernández Collado, C., y Baptista Lucio, M. (2010). *Metodología de la Investigación*. México: McGraw-Hill.
- Tsay, R. S. (2010). *Analysis of Financial Time Series*. New Jersey: Wiley.
- Walsh, D. M. y Tsou, G. Y. (1998). Forecasting index volatility: sampling interval and non-trading effects. *Applied Financial Economics*, 8, 477–485.