

Estimación del Valor a Riesgo del mercado accionario argentino mediante modelos GARCH.

Martin Segovia
Universidad de Buenos Aires (UBA).
martinsegovia26@gmail.com

Federico Favata
CIMaD – Universidad Nacional de San Martín (UNSAM).
ffavata@unsam.edu.ar

Resumen

El Valor a Riesgo (VaR) representa la máxima pérdida probable que puede experimentar un activo en un determinado horizonte de tiempo y con un determinado nivel de confianza. Este trabajo intenta estimar el modelo más adecuado para medir el riesgo del mercado accionario argentino, utilizando la serie diaria del índice S&P Merval. Para eso, se planteó un modelo de VaR paramétrico a través de varianzas condicionales GARCH(1,1), GJR-GARCH(1,1) y E-GARCH(1,1) en conjunto con las distribuciones normal, t de student y t de student sesgada. A través del *backtesting* se determinó la aptitud de cada modelo. Finalmente, el modelo más apropiado para la gestión del riesgo del mercado accionario argentino es el VaR paramétrico con un modelo E-GARCH(1,1) bajo distribución t de student.

Palabras claves: Mercados financieros, Valores en riesgo, modelos GARCH.

Códigos JEL: G0, G1, C22, C51.

Abstract

The Value at Risk (VaR) represents the maximum probable loss that an asset may experience in a given time horizon and with a given confidence level. This paper attempts to estimate the most appropriate model to measure the risk of the Argentinean stock market, using the daily series of the S&P Merval index. For this purpose, a parametric VaR model was proposed through GARCH(1,1), GJR-GARCH(1,1) and E-GARCH(1,1) conditional variances together with normal, student's t and skewed student's t distributions. Through backtesting, the suitability of each model was determined. Finally, the most appropriate model for risk management of the Argentine stock market is the parametric VaR with an E-GARCH(1,1) model with student's t distribution.

Key words: Financial markets, Value at Risk, GARCH models.

JEL code: G0, G1, C22, C51.

1. Introducción

Una adecuada gestión del riesgo es uno de los temas predominantes en los mercados financieros actuales. Con la crisis financiera del año 2007, el sector bancario sufrió serias presiones, necesitando la asistencia de bancos centrales e instituciones financieras para respaldar el funcionamiento de los mercados. A partir de ese entonces, cobró mucha importancia el hecho de poder captar y medir correctamente el riesgo en la cola de la distribución de pérdidas y ganancias de las carteras de activos financieros.

La volatilidad es uno de los conceptos más utilizados al momento de determinar cuan riesgoso es un activo financiero (Hull, 2018), donde un activo con más volatilidad en su precio es más riesgoso. Sin embargo, es muy importante para los inversores y *portfolio managers* distinguir si esa volatilidad responde a movimientos positivos o negativos en el precio. Si existe un activo cuya volatilidad es alta debido a que presenta grandes subidas en su precio, entonces será preferible tenerlo en cartera. Por esta razón, la volatilidad en sí misma no es suficiente para caracterizar el riesgo de un activo.

En ese sentido, parecería interesante utilizar dicha metodología para aplicar en el mercado financiero argentino. Para eso, utilizando la serie diaria del índice S&P Merval, se prueban distintas combinaciones de modelos paramétricos (GARCH, GJR-GARCH y E-GARCH) bajo distintas distribuciones (normal, t de student y t de student sesgada) con el fin de obtener la metodología más adecuada a través de *backtesting* para estimar el VaR correspondiente.

El artículo está organizado de la siguiente manera: la sección 2 presenta el repaso de la literatura correspondiente, la siguiente la metodología utilizada, luego se presentan la fuente de datos y su estadística descriptiva, después la elección del modelo optimo y finalmente las conclusiones.

2. Repaso de la literatura

A partir del documento técnico publicado por el *J.P. Morgan Group* en la década de los 90 (Morgan, 1996), se instauró al Valor a Riesgo (VaR) como una de las medidas de riesgo más utilizadas en el sistema financiero. El VaR se concentra en la cola izquierda de la distribución de resultados¹, indicando cuál es la máxima pérdida probable para un

¹ Se concentra en la cola izquierda siempre que se considere a las ganancias como resultados positivos y a las pérdidas como negativos.

horizonte y nivel de confianza determinados (Hull, 2018). Esta medida presenta dos características fundamentales que impulsaron su popularidad: i) estima una medida resumida del riesgo de mercado y de sencilla interpretabilidad y ii) es posible realizar de manera relativamente simple un *backtesting* para corroborar que se está midiendo el riesgo de forma adecuada (Abad, Benito, & López, 2013).

Con el fin de poder proyectar correctamente el VaR para una cartera, es necesario considerar los patrones de comportamiento de la volatilidad de los activos financieros². Tal como muestra Sewell (2011), la varianza de las series de estos activos tiende a cambiar a lo largo del tiempo (heterocedasticidad) y a manifestar un fenómeno conocido como *volatility clusters*. En otras palabras, se pueden diferenciar períodos de alta volatilidad y otros de baja volatilidad. Estas características de las series temporales comenzaron a ser estudiadas por Engle (1982), quien a partir del proceso autorregresivo (AR) desarrolló el modelo ARCH (*Autoregressive Conditional Heteroskedasticity*) para el estudio de la inflación británica.

Desde entonces, surgieron numerosos aportes a este campo de la econometría financiera, específicamente modificaciones al modelo ARCH (Bollerslev, 2008). Dentro de esa variedad de contribuciones se encuentra la Generalización del modelo ARCH (GARCH) (Bollerslev, 1986), el modelo GARCH asimétrico (AGARCH) (Engle, 1990) que permite un efecto diferenciado de los retornos negativos y positivos en la varianza, y también modificaciones del AGARCH como el exponencial (E-GARCH)(Nelson, 1991) y el GJR-GARCH (Glosten, Jagannathan, & Runkle, 1993); entre otros.

Para la aplicación de modelos de series temporales es necesario decidir qué distribución del término de error se asumirá. Muchos trabajos suponen una distribución de probabilidad normal (Engle, 1982; Morgan, 1996). Sin embargo, las series financieras suelen presentar gran concentración entorno a su media (leptocurtosis) y mayor cantidad de casos extremos que la que logra captar la distribución normal. Por esta razón, algunos autores han optado utilizar distribuciones con colas más pesadas (Bollerslev, 1987; Engel & Gonzales-Rivera, 1991; Ait-Sahalia & Lo, 1998; Theodossiou & Trigeorgis, 2003; Giot & Laurent, 2003).

Por ejemplo, So & Yu (2006) analizaron la aplicación de una serie de modelos ARCH para la estimación del valor a riesgo aplicado a índices accionarios y a tipos de cambio, donde para ambos casos, la hipótesis de distribución t de student arrojó resultados

² Cuando se habla de volatilidad o varianza de activos financieros, se refiere a la volatilidad o varianza de las variaciones de su precio.

superadores a los obtenidos bajo distribución normal para el VaR al 99%. Por su parte, Cerovic Smolovic *et.al* (2017) mostraron que los modelos adecuados para la estimación del VaR del índice MONEX siguen distribuciones leptocúrticas, es decir, con colas mas pesadas. Adicionalmente, Nikolic-Djoric y Djoric (2011) investigaron el rendimiento de los modelos GARCH y GARCH integrado (IGARCH) en la previsión del VaR de un índice bursátil en el mercado financiero serbio, concluyendo que los modelos GARCH disminuyen el valor medio del VAR, y que estos modelos son mejores que el modelo IGARCH. Además, Bucevska (2013) demostró que los modelos de la familia GARCH más adecuados para estimar la volatilidad en el mercado de valores de Macedonia son el modelo GARCH exponencial asimétrico (EGARCH) con distribución t de Student, el modelo EGARCH con distribución normal y el modelo GJR-GARCH.

3. Metodología

3.1. Valor al Riesgo

El Valor al Riesgo (VaR) representa la máxima pérdida probable que puede experimentar un activo o una cartera de activos financieros (Hull, 2018), en un horizonte de tiempo h y con un nivel de confianza $(1 - \alpha)$, siendo α el nivel de significación. El VaR representa un cuantil de la distribución de rendimientos de un activo o una cartera de activos. A modo de ejemplo, siendo X una variable aleatoria que representa los resultados de un portafolio, con función de densidad $f(x)$, el Valor al Riesgo de la cartera surge de la siguiente expresión:

$$\int_{-\infty}^{VaR(X;\alpha)} f(x) dx = \alpha \quad (1)$$

Por lo tanto,

$$VaR(X; \alpha) = F_X^{-1}(\alpha) \quad (2)$$

Donde F_X^{-1} representa la inversa de la función de distribución de la variable X .

Existen distintas formas de calcular el Valor a Riesgo: i) método paramétrico, ii) método no paramétrico y iii) simulación. En este trabajo, se opta por utilizar el cálculo del VaR en forma paramétrica. A continuación, se muestra la fórmula de cálculo del VaR con un nivel de confianza $(1 - \alpha)$ para el momento $t+h$.

$$VaR(X; \alpha) = \mu_X + \sigma_{X;t+h} Z_\alpha \quad (3)$$

En esta expresión, μ_X representa la media de los retornos, $\sigma_{X;t+h}$ representa la volatilidad proyectada para el momento $t+h$ y z_α representa el percentil α de una distribución de probabilidad estandarizada (normal, t de student o t de student sesgada).

3.2. Modelos de volatilidad

3.2.1. Modelo ARCH (q)

Partiendo de un modelo donde la variable dependiente son los retornos, es decir, el logaritmo natural del ratio de los precios en t y $t-1$, se podría descomponer entre su media (μ) y un shock aleatorio (r_t). Estos modelos plantean que la varianza del término de error en el momento t depende del valor del error elevado al cuadrado observado en períodos anteriores. El parámetro q es el orden del modelo que representa la cantidad de rezagos incorporados en el mismo.

$$\ln\left(\frac{P_t}{P_{t-1}}\right) = \mu + r_t \quad (4)$$

$$r_t = \sigma_t \varepsilon_t \quad (5)$$

$$\sigma_t^2 = \omega + \sum_{j=1}^q \alpha_j r_{t-j}^2 \quad (6)$$

con $\omega > 0$ y $\alpha_j \geq 0$.

Donde, ε_t representa un ruido blanco con media cero y varianza unitaria. La restricción en los parámetros garantiza no encontrarse con valores negativos de la varianza condicionada σ_t^2 (Cimpean, 2017).

3.2.2. Modelo GARCH (p, q)

El proceso GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*) fue introducido como una generalización a los modelos ARCH antes mencionados (Bollerslev, 1986). Los procesos GARCH (p,q) logran mejorar la estimación de la heterocedasticidad, incorporando la varianza condicionada de los p intervalos de tiempo previos además de los q valores previos de rendimientos al cuadrado.

$$\sigma_t^2 = \omega + \sum_{j=1}^q \alpha_j \times r_{t-j}^2 + \sum_{i=1}^p \beta_i \times \sigma_{t-i}^2 \quad (7)$$

En este trabajo se utilizará el modelo *GARCH* ($p=1, q=1$) debido a su simplicidad y tratabilidad empírica. En ese caso el modelo queda de la siguiente manera:

$$\sigma_t^2 = \omega + \alpha_1 \times r_{t-1}^2 + \beta_1 \times \sigma_{t-1}^2 \quad (8)$$

Donde ω representa el nivel de referencia de volatilidad a largo plazo, el parámetro α_1 mide la influencia del retorno al cuadrado del período anterior en la varianza condicionada del período t , y finalmente β_1 representa el impacto de la varianza condicionada del período anterior en la varianza condicionada del período actual. Para garantizar que la varianza condicionada sea positiva debe cumplirse lo siguiente:

$$\omega > 0 ; \alpha_1 > 0 ; \beta_1 > 0 ; \alpha_1 + \beta_1 < 1$$

3.2.3. Modelo GJR-GARCH (p, q)

Este modelo, que forma parte de la familia de modelos GARCH asimétricos, incorpora el efecto apalancamiento en la volatilidad (Glosten, Jagannathan & Runkle, 1993). Este efecto se refiere a que, variaciones negativas en las series de precios de los activos financieros tienen mayor impacto en la volatilidad que variaciones. La ecuación de la varianza condicionada toma la siguiente forma:

$$\sigma_t^2 = \omega + \sum_{j=1}^q (\alpha_j \times r_{t-j}^2 + \delta_j \times r_{t-j}^2 \times I_{t-j}) + \sum_{i=1}^p \beta_i \times \sigma_{t-i}^2 \quad (9)$$

donde la variable I función indicadora que toma el valor uno si r_{t-j} es negativo, y cero en caso contrario.

En este trabajo se utilizará el modelo *GJR-GARCH* ($p=1, q=1$), quedando la ecuación de la varianza condicionada de la siguiente manera:

$$\sigma_t^2 = \omega + \alpha_1 \times r_{t-1}^2 + \delta_1 \times r_{t-1}^2 \times I_{t-1} + \beta_1 \times \sigma_{t-1}^2 \quad (10)$$

Se puede ver que en caso de que el retorno del período previo sea negativo, entonces ese retorno tendrá un impacto en la varianza condicionada del período actual de $\alpha_1 + \delta_1$. Para garantizar que la varianza condicionada sea positiva debe cumplirse lo siguiente:

$$\omega > 0 ; \alpha_1 > 0 ; \beta_1 > 0 ; \alpha_1 + \delta_1 > 0$$

3.2.4. Modelo E-GARCH (p, q)

Este modelo llamado *Exponential GARCH* fue introducido por Nelson (1991). Lo que plantea es otra forma de incorporar el efecto de apalancamiento al modelo GARCH. Por lo tanto, la expresión de la varianza condicionada queda de la siguiente manera:

$$\log \sigma_t^2 = \omega + \sum_{j=1}^q \alpha_j \times \left| \frac{r_{t-j}}{\sigma_{t-j}} \right| + \sum_{j=1}^q \gamma_j \times \frac{r_{t-j}}{\sigma_{t-j}} + \sum_{i=1}^p \beta_i \times \log \sigma_{t-i}^2 \quad (11)$$

Donde γ_j es el parámetro que representa el efecto de apalancamiento. Este parámetro es el que define la simetría del modelo. Es decir, si γ_j es igual a cero para todo j entonces tanto los retornos positivos como negativos tienen el mismo impacto en la varianza. Si γ_j es distinto de cero, entonces los efectos de los retornos son distintos (el modelo es asimétrico). En el caso de que γ_j sea menor a cero, esto implica que los retornos negativos generan mayor volatilidad que los positivos.

Considerando que en este trabajo se utiliza un modelo *E-GARCH* ($p=1, q=1$), la ecuación de la varianza condicionada queda como se muestra a continuación.

$$\log \sigma_t^2 = \omega + \alpha_1 \times \left| \frac{r_{t-1}}{\sigma_{t-1}} \right| + \gamma_1 \times \frac{r_{t-1}}{\sigma_{t-1}} + \beta_1 \times \log \sigma_{t-1}^2 \quad (12)$$

3.3. Distribuciones de probabilidad de los modelos

Los parámetros de los modelos son estimados mediante el método de máxima verosimilitud. Este procedimiento se basa en la maximización del logaritmo de la función de verosimilitud. Esta función de verosimilitud depende de la distribución de probabilidad asumida para el modelo (Canavos, 1988). En este trabajo se utilizan 3 distribuciones: distribución *normal*, distribución *t-student* y distribución *t-student sesgada*.

3.3.1. Distribución normal

La distribución normal presenta dos parámetros: μ (la media) y σ^2 (la varianza). Sea X una variable aleatoria con distribución normal con media μ y varianza σ^2 , la función de densidad presenta la siguiente forma (Canavos, 1988):

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma} \right)^2} \quad (13)$$

Bajo el supuesto de que $\varepsilon_t \sim N(0,1)$, donde ε_t es una variable aleatoria normal estandarizada, el logaritmo de la función de verosimilitud, L_{Normal} , es:

$$L_{Normal} = -\frac{1}{2} \times \sum_{t=1}^T [\ln 2\pi + \ln \sigma_t^2 + \varepsilon_t^2] \quad (14)$$

Donde T es el número total de observaciones.

3.3.2. Distribución t -student

Esta distribución se incorpora al análisis ya que su función de densidad es leptocúrtica respecto de la distribución normal. Es decir, presenta un pico más alto y colas más pesadas. La distribución contiene un parámetro adicional, ρ , que representa los grados de libertad. Los grados de libertad miden el nivel de leptocurtosis de la función de densidad. La función de densidad de esta distribución viene dada por la siguiente expresión (Cimpean, 2017):

$$f(\varepsilon) = \frac{1}{\sqrt{\rho\pi}} \Gamma\left(\frac{\rho}{2}\right)^{-1} \Gamma\left(\frac{\rho+1}{2}\right) \left(1 + \frac{\varepsilon^2}{\rho}\right)^{-\frac{\rho+1}{2}} \quad (15)$$

Donde $2 < \rho < \infty$ y $\Gamma(\cdot)$ es la función Gamma. En la práctica suele utilizarse la distribución t -student estandarizada. Sea $\varepsilon \sim ST(0, \frac{\rho}{\rho-2}, \rho)$, se define a la variable estandarizada z como: $z = \frac{\varepsilon}{\sqrt{\rho/\rho-2}}$.

Por lo tanto, bajo el supuesto de que $z \sim ST(0, 1, \rho)$, el logaritmo de la función de verosimilitud, L_{ST} , es:

$$L_{ST} = T \left\{ -\frac{1}{2} [\ln(\rho - 2) + \ln \pi] - \ln \left(\Gamma\left(\frac{\rho}{2}\right) \right) + \ln \left(\Gamma\left(\frac{\rho+1}{2}\right) \right) \right\} - \frac{\rho+1}{2} \sum_{t=1}^T \ln \left(1 + \frac{z_t^2}{\sigma_t^2(\rho-2)} \right) \quad (16)$$

3.3.3. Distribución t -student sesgada

La distribución t -student descrita anteriormente no logra capturar la existencia de asimetría en la función de densidad. Con este objetivo, se incorpora al análisis la distribución t -student sesgada (SST, por sus siglas en inglés) propuesta por Hansen (1994). Esta distribución añade un parámetro φ , el cual capta la asimetría. Para el caso de que $\varphi < 0$, el modo de la distribución se ubicará hacia la derecha del cero y la variable será asimétrica por izquierda, y viceversa. La función de densidad para una variable aleatoria estandarizada con distribución SST (media cero y varianza unitaria) se define como:

$$f(z) = \begin{cases} bc \left(1 + \frac{1}{\rho-2} \left(\frac{bz+a}{1-\varphi} \right)^2 \right)^{-\frac{\rho+1}{2}}, & z < -\frac{a}{b} \\ bc \left(1 + \frac{1}{\rho-2} \left(\frac{bz+a}{1+\varphi} \right)^2 \right)^{-\frac{\rho+1}{2}}, & z \geq -\frac{a}{b} \end{cases} \quad (17)$$

Donde $2 < \rho < \infty$ y $-1 < \varphi < 1$. Las constantes a, b y c vienen dadas por las siguientes ecuaciones:

$$a = 4\varphi c \left(\frac{\rho - 2}{\rho - 1} \right) \quad (18)$$

$$b^2 = 1 + 3\varphi^2 - a^2 \quad (19)$$

$$c = \frac{\Gamma\left(\frac{\rho + 1}{2}\right)}{\sqrt{\pi(\rho - 2)} \Gamma\left(\frac{\rho}{2}\right)} \quad (20)$$

Finalmente, el logaritmo de la función de verosimilitud es (Cimpean, 2017):

$$\begin{aligned} L_{SST} = & \sum_{i=1}^I \ln(b) + \ln(c) - \frac{\rho + 1}{2} \ln \left[1 + \frac{1}{\rho - 2} \left(\frac{b z_i + a}{1 + \varphi} \right)^2 \right] + \\ & + \sum_{j=1}^J \ln(b) + \ln(c) - \frac{\rho + 1}{2} \ln \left[1 + \frac{1}{\rho - 2} \left(\frac{b z_j + a}{1 - \varphi} \right)^2 \right] - \\ & - \frac{1}{2} \sum_{t=1}^T \ln \sigma_t^2 \quad (21) \end{aligned}$$

Donde,

$$z = \begin{cases} z_i, & \text{si } z_t \geq -\frac{a}{b} \\ z_j, & \text{si } z_t < -\frac{a}{b} \end{cases} \quad (22)$$

3.4. Backtesting

En el contexto de la gestión del riesgo de mercado, el *backtesting* es un conjunto de procedimientos estadísticos diseñados para evaluar si las pérdidas reales observadas *ex post*, están en concordancia con las predicciones del VaR (Jorion, 2007).

En este trabajo se llevan a cabo dos pruebas estadísticas para determinar si las predicciones del VaR en cada una de las variantes, son consistentes con los supuestos en los que se basa el modelo. Según Campbell (2005), la aptitud de un modelo VaR puede verificarse si la secuencia de violaciones al VaR satisface las propiedades de cobertura incondicional e independencia.

En base a las recomendaciones del Comité de Basilea, se utiliza una muestra de dos años para llevar a cabo la prueba retrospectiva (Bank for International Settlements, 2019). Ya que se trabaja con cotizaciones de días hábiles, un año se compone por 252 observaciones.

En primer lugar, se define una variable indicativa I_t , la cual toma el valor uno si la pérdida real supera al VaR, o el valor cero en caso contrario. En el caso que la variable tome el valor uno, se dice que hay un *hit*.

$$I_t = \begin{cases} 1, & \text{si } r_t < VaR \\ 0, & \text{si } r_t \geq VaR \end{cases} \quad (23)$$

A partir de esto, se define el ratio de violaciones ($\hat{\pi}$) de la siguiente manera:

$$\hat{\pi} = \frac{n_1}{N} \quad (24)$$

En este caso, n_1 representa la cantidad de *hits* observados y N la cantidad total de observaciones (Cimpean, 2017).

Lo que se espera para que el modelo sea válido, es que $\hat{\pi}$ sea similar al α definido. Además, es importante que las observaciones de la variable indicativa I sean independientes entre sí. En otras palabras, la probabilidad de ocurrencia de I_t no debe verse afectada por la probabilidad de ocurrencia de I_{t-1} . Entonces, se debe cumplir que la secuencia de observaciones de la variable I debe ser una sucesión de variables aleatorias bernoulli independientes e idénticamente distribuidas con probabilidad de éxito α . Por lo tanto, se utiliza un test de cobertura incondicional (Test de Kupiec) para validar el valor de α , y un test de cobertura condicional (Test de Christoffersen) que evalúa conjuntamente el valor de α y la independencia.

4. Fuente de datos y proceso de estimación

4.1. Análisis de los datos

Como insumo principal se utilizó la serie de Standard & Poor's (S&P) Merval (mercado de valores) desde el 4 de enero de 2016 al 30 de diciembre de 2021. Este indicador es utilizado como proxy del mercado accionario argentino. Su función es medir el valor en pesos de un portafolio compuesto por una cantidad nominal de acciones de empresas líderes argentinas que cotizan en la Bolsa de Comercio de Buenos Aires. Actualmente está compuesta por 20 empresas en las que se destacan: Aluar, YPF, Loma Negra, Edenor, Cablevisión, Banco Macro, BBVA Argentina, entre otras.

4.2. Estadística descriptiva

El gráfico siguiente representa la evolución del índice a lo largo del tiempo. Se puede observar que desde el 2016 hasta fines de 2021, la serie aumento a excepción de periodos de estancamiento como en 2020.

Gráfico 1: Serie diaria del Índice S&P Merval.



Fuente: Elaboración propia en base a la serie del S&P Merval


Sin embargo, debido a que se busca aplicar modelos de series temporales, es fundamental trabajar con una serie estacionaria (constantes en media y varianza en el tiempo). En la anterior se puede observar que la serie en nivel del S&P Merval presenta una tendencia alcista. Esta característica es un primer indicio de que la serie no es estacionaria, donde además también se podría apreciar heterocedasticidad, a partir del año 2018. Para corroborar esta hipótesis, se aplica el test de Dickey-Fuller Aumentado (Dickey & Fuller, 1979), donde la hipótesis nula sostiene que la serie no es estacionaria. Los resultados indican un p -valor de 0.7212, por lo que se concluye que no hay evidencia para rechazar la hipótesis nula al 5% de significancia.

En consecuencia, se calcula la serie de variaciones logarítmicas diarias del índice. La fórmula que se aplica es la siguiente:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (25)$$


Donde r_t es el retorno en el día t , P_t es el valor del índice en el día t y P_{t-1} es el valor del índice en el día anterior.

Gráfico 2: Distribución de los retornos diarios.



Fuente: Elaboración propia en base a la serie del S&P Merval

Gráfico 3: Histograma de la distribución de retornos observada.



Fuente: Elaboración propia en base a la serie del S&P Merval

En el gráfico 2 se puede ver como la serie de retornos se desarrolla entorno a su promedio, denominándose regresión a la media. Al aplicar la prueba de ADF, se obtuvo un p -valor < 0.01 . Con un nivel de significancia de 5%, hay evidencia para rechazar la hipótesis nula de no estacionariedad. Adicionalmente el gráfico 3 se puede observar la distribución de estos retornos, donde su forma parece ser tener distribución normal.

En la tabla 1 se exhibe el análisis descriptivo de los datos del Índice S&P Merval. Se puede ver que la media de la distribución se ubica en 0,0017 (0,17% de rendimiento diario) y el coeficiente de curtosis es superior a 3, indicando que se trata de una distribución cuyos valores se concentran tanto muy cerca como muy alejados de su media

(pico más alto y colas más pesadas que la distribución normal). En cuanto al coeficiente de asimetría, éste indica una leve asimetría a la izquierda.³ Adicionalmente, se realiza el test de normalidad de Jarque-Bera (Jarque & Bera, 1980), el cual arroja un p -valor < 0.000 , rechazando la hipótesis nula de normalidad.


Tabla 1: Estadística descriptiva de la serie de retornos diarios

Estadístico	Resultado
Media	0.0017
Desvío estándar	0.0239
Mínimo	-0.1563
Mediana	0.0021
Máximo	0.0977
Asimetría	-0.4452
Curtosis	7.5142

Fuente: Elaboración propia en base a la serie del S&P Merval

Cabe destacar que si los modelos GARCH plantean que la varianza condicional depende de los retornos pasados elevados al cuadrado, es necesario que exista autocorrelación en la serie para que sea posible la predicción. Por lo tanto, se analiza la autocorrelación en la serie de retornos elevados al cuadrado. A través del gráfico de la función de autocorrelación, se observa que hay correlaciones significativas prácticamente en todos los retardos. Además, se aplicó el estadístico de prueba de Ljung-Box utilizando 15 retardos (Ljung & Box, 1978), donde se obtuvo un p -valor $< 0,000$, por lo tanto, se rechaza la hipótesis nula de no existencia de autocorrelación en la serie.

Gráfico 4: Función de Autocorrelación.



Fuente: Elaboración propia en base a la serie del S&P Merval

³ El día 13 de Agosto de 2019 por las elecciones el índice cayó 44%, como fue un caso atípico se lo excluye del análisis.

4.3. Proceso para la estimación del VaR

A partir de la muestra de 1465 (T) observaciones de retornos, se toman inicialmente 961 (t) datos con los cuales se estiman los parámetros de los modelos. De esta manera se dejan las 504 ($T - t$) observaciones más recientes para evaluar las proyecciones del VaR. Esto equivale a dos años, ya que se toman días hábiles.

El proceso arranca estimando el modelo (GARCH, E-GARCH o GJR-GARCH) con 961 (t) datos, proyectando la volatilidad a un día ($t + 1$), luego se calcula el Valor a Riesgo y finalmente se contrasta con la observación real. En la siguiente iteración, se estima el modelo tomando ($t + 1$) observaciones y se proyecta la volatilidad para ($t + 2$), se obtiene el Valor a Riesgo y se lo contrasta con la observación. Este proceso se repite hasta haber obtenido una serie de ($T - t$) estimaciones del valor a riesgo, que junto con la serie de retornos reales, es utilizada para llevar a cabo el *backtesting*.

5. Resultados

A continuación, se exhiben los resultados del *backtesting* para cada uno de los modelos de estimación del valor a riesgo. En la Tabla 2 se presentan los resultados para los modelos GARCH(1,1), GJR-GARCH(1,1) y E-GARCH(1,1) para las tres distribuciones posibles. En todos los casos se analizó el poder de predicción del VaR a un día para un nivel de confianza del 95% y 99%. Las pruebas estadísticas de Kupiec y Christoffersen se realizaron con un nivel de significatividad del 1%.

Los resultados indican que para un valor a riesgo estimado con un 95% de confianza, el modelo GARCH(1,1) que sigue una distribución normal resulta ser el más preciso. El porcentaje de violaciones al VaR observado es de 5,35% mientras que el esperado es de 5%. Cabe destacar que en los tres casos se obtienen resultados favorables en los *tests* de cobertura incondicional y cobertura condicional.

Sin embargo, al analizar los resultados del VaR al 99% de confianza se observa una superioridad de los modelos con distribuciones con colas más pesadas (t de student y t de student sesgada). El modelo con distribución normal presenta un 43% más de violaciones al VaR y el p -valor de la prueba de Kupiec no es concluyente. Esto está en concordancia con el coeficiente de curtosis de la distribución de retornos. Es decir, al trabajar más en el extremo de la cola de la distribución, la distribución t de student y t de student sesgada logran captar mejor la presencia de valores extremos.

Tabla 2: Backtesting de los modelos

GARCH(1,1)				
Distribución		Normal	t-student	t-student sesgada
VAR 5%	Hits Esperados	25	25	25
	Hits Observados	27*	30	28
	Kupiec (p-valor)	0.716	0.34	0.574
	Christoffersen (p-valor)	0.158	0.193	0.178
VAR 1%	Hits Esperados	5	5	5
	Hits Observados	10	7*	7*
	Kupiec (p-valor)	0.05	0.407	0.407
	Christoffersen (p-valor)	0.12	0.643	0.643
GJR-GARCH(1,1)				
Distribución		Normal	t-student	t-student sesgada
VAR 5%	Hits Esperados	25	25	25
	Hits Observados	28*	31	29
	Kupiec (p-valor)	0.574	0.252	0.448
	Christoffersen (p-valor)	0.178	0.186	0.19
VAR 1%	Hits Esperados	5	5	5
	Hits Observados	8	6*	6*
	Kupiec (p-valor)	0.22	0.677	0.677
	Christoffersen (p-valor)	0.417	0.853	0.853
E-GARCH(1,1)				
Distribución		Normal	t-student	t-student sesgada
VAR 5%	Hits Esperados	25	25	25
	Hits Observados	28*	32	30
	Kupiec (p-valor)	0.574	0.181	0.34
	Christoffersen (p-valor)	0.466	0.171	0.428
VAR 1%	Hits Esperados	5	5	5
	Hits Observados	9	6*	6*
	Kupiec (p-valor)	0.11	0.677	0.677
	Christoffersen (p-valor)	0.237	0.853	0.853

Fuente: Elaboración propia en base a la serie del S&P Merval. Se señala con un asterisco el modelo más preciso para cada nivel de confianza del VaR.

En cuanto a los modelos GARCH asimétricos se observa el mismo patrón. Al analizar los resultados para el VaR al 95% de confianza se ve que aquellos que suponen una distribución normal logran predecir mejor. En el caso del GJR-GARCH(1,1), las distribuciones con colas más pesadas presentan en promedio un 7% más de violaciones al valor a riesgo, mientras que para el E-GARCH(1,1) los *hits* aumentan un 11%. Angelidis et al. (2004) muestran que los modelos bajo distribución normal logran predicciones adecuadas del valor a riesgo a un 95% de confianza, mientras que fallan el *backtesting* para un VaR al 99% (Angelidis, Benos, & Degiannakis, 2004).

Por otro lado, si se utiliza un VaR al 99% de confianza, los modelos con distribuciones de colas pesadas arrojan mejores resultados. En los modelos GJR-GARCH(1,1), si se supone distribución normal los *hits* ascienden un 33% respecto a las distribuciones t de student y t de student sesgada. Si se aplica E-GARCH(1,1) bajo distribución normal los

excesos al valor a riesgo superan en 50% a los observados bajo las otras dos distribuciones analizadas.

Es relevante aclarar que en términos del *backtesting* los modelos E-GARCH y GJR-GARCH arrojan los mismos resultados para las distribuciones t de student y t de student sesgada. Esto está en línea con el coeficiente de asimetría expuesto en la Tabla 1. Si bien es un valor negativo, no resulta ser muy significativo. Por lo tanto, considerando un criterio de parsimonia, no se justifica utilizar la distribución sesgada para el índice S&P Merval.

Tabla 3: Akaike Information Criteria (AIC)

Modelo	Distribución	AIC
GARCH(1,1)	Normal	-4.8637
GARCH(1,1)	T-student	-4.8947*
GARCH(1,1)	T-student sesgada	-4.8946
GJR-GARCH(1,1)	Normal	-4.8690
GJR-GARCH(1,1)	T-student	-4.9021*
GJR-GARCH(1,1)	T-student sesgada	-4.9017
E-GARCH(1,1)	Normal	-4.8764
E-GARCH(1,1)	T-student	-4.9088*
E-GARCH(1,1)	T-student sesgada	-4.9082

Fuente: Elaboración propia en base a la serie del S&P Merval.

Finalmente, la tabla 3 compara de los valores de AIC para cada modelo. Los resultados indican que los modelo bajo distribución t de student son preferibles ya que poseen un valor de AIC menor que los que tienen distribución normal o t de student sesgada. Por último, los modelos E-GARCH arrojan valores de AIC menores que el resto de los modelos.

6. Conclusión

Considerando todas las variantes expuestas, se puede decir que para la estimación del valor a riesgo a un día con un 95% de confianza, resulta más adecuado utilizar un modelo GARCH(1,1) bajo la hipótesis de distribución normal. Por otro lado, para la estimación del valor a riesgo a un día con un nivel de confianza del 99% es conveniente aplicar un modelo E-GARCH(1,1) asumiendo una distribución t de student.

Según las recomendaciones del Comité de Basilea (Bank for International Settlements, 2019) y el Banco Central de la República Argentina (Banco Central de la República Argentina, 2019), el nivel de confianza que se debe utilizar para la estimación del Valor

a Riesgo es del 99%. En conclusión, el modelo más adecuado para gestionar el riesgo de mercado diario del Índice S&P Merval es el E-GARCH(1,1) bajo distribución t de student.

Este trabajo se enfocó en el análisis del mercado accionario. Sin embargo, los títulos públicos son los instrumentos financieros con mayor volumen efectivo operado en el mercado de capitales argentino. En consecuencia, como líneas futuras de investigación se extenderá el análisis a una cartera de bonos. Por otro lado, si bien los modelos analizados pasaron el *backtesting*, todos estimaron un porcentaje de *hits* superior al esperado. Sería aconsejable analizar la eficiencia de otras alternativas para la estimación de la varianza (Guermat & Harris, 2002); (Morgan, 1996).

Bibliografía

- Abad, P., Benito, S., & López, C. (2013). A comprehensive review of Value at Risk methodologies. *The Spanish Review of Financial Economics*.
- Ait-Sahalia, Y., & Lo, A. (1998). Nonparametric estimation of state-price densities implicit in financial asset prices. *Journal of Finance*, 53(2), 499-547.
- Andersen, J. (4 de 10 de 2019). *Towards Data Science*. Obtenido de <https://towardsdatascience.com/how-banks-manage-risk-26557d782477>
- Angelidis, T., Benos, A., & Degiannakis, S. (2004). The use of GARCH models in VaR estimation. *Statistical Methodology*, 105-128.
- Baillie, R., & DeGennaro, R. (1990). Stock Returns and Volatility. *The Journal of Financial and Quantitative Analysis*, 203-214.
- Banco Central de la República Argentina. (2019). *Lineamientos para la Gestión de Riesgos en las Entidades Financieras*. Obtenido de www.bcra.gov.ar
- Bank for International Settlements. (2019). *Basel Committee on Bankin Supervision*. Obtenido de Basel III: international regulatory framework for banks: https://www.bis.org/bcbs/basel3.htm?m=3_14_572
- Bauwens, L., Laurent, S., & Rombouts, J. V. (2006). MULTIVARIATE GARCH MODELS: A SURVEY. *Journal of Applied Econometrics*, 21, 79-109.
- Bessis, J. (2015). *Risk Management in Banking* (Fourth ed.). West Sussex: Wiley & Sons Ltd.
- Bhowmik, R., & Wang, S. (2020). Stock Market Volatility and Return Analysis: A Systematic Literature Review. *Entropy*.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
- Bollerslev, T. (1987). A Conditional Heteroskedastic Time Series Model for Speculative Prices and Rates of Return. *The Review of Economics and Statistics*, 69(3), 542-547.
- Bollerslev, T. (2008). Glossary to ARCH (GARCH). *CREATES*.
- Bollerslev, T., Chou, R., & Kroner, K. (1992). ARCH modeling in finance. A review of the theory and empirical evidence. *Journal of Econometrics*, 52, 5-59.
- Bucevska, V. (2013). An Empirical evaluation of GARCH models in value-at-risk estimation: Evidence from the Macedonian stock exchange. *Business Systems Research: International journal of the Society for Advancing Innovation and Research in Economy*, 4(1), 49-64.
- Campbell, S. D. (2005). *A Review of Backtesting and Backtesting Procedures*. Division of Research & Statistics and Monetary Affairs. Washington, DC.: Finance and Economics Discussion Series.
- Canavos, G. (1988). *PROBABILIDAD Y ESTADISTICA, Aplicaciones y métodos*. Mexico: McGraw-Hill/Interamericana de Mexico.
- Cerovic Smolovic, J., Lipovina-Bozovic, M., & Vujosevic, S. (2017). GARCH models in value at risk estimation: empirical evidence from the Montenegrin stock exchange. *Economic Research-Ekonomska Istrazivanja*, 30(1), 477-498.

- Cheng, W.-H., & Hung, J.-C. (2011). Skewness and leptokurtosis in GARCH-typed VaR estimation of petroleum and metal asset returns. *Journal of Empirical Finance*, 160-173.
- Christoffersen, P. (1998). Evaluating Interval Forecasts. *International Economic Review*, 39, 841-862.
- Cimpean, L. (2017). *Tesis de Maestría. El uso de expectiles en la medición del riesgo. Comparativa con el VaR y con el ES*. Universidad Complutense de Madrid.
- Dickey, D., & Fuller, W. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366), 427-431.
- Efimova, O., & Serletis, A. (2014). Energy markets volatility modelling using GARCH. *Energy Economics*, 43, 264-273.
- Engle, R. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
- Engle, R. (1990). Discussion on Schwert. *The Review of Financial Studies*, 103-106.
- Engle, R., & Gonzales-Rivera, G. (1991). Semiparametric ARCH models. *J. Bus. Econ. Stat.*, 9(4), 345-359.
- Giot, P., & Laurent, S. (2003). Market risk in commodity markets: a VaR approach. *Energy Econ.*, 25(5), 435-457.
- Glosten, L. R., Jagannathan, R., & 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.
- Guermat, C., & Harris, R. (2002). Forecasting value at risk allowing for time variation in the variance and kurtosis of portfolio returns. *International Journal of Forecasting*, 409-419.
- Halibegovic, S., & Vehabovic, M. (2016). Backtesting Value at Risk Forecast: the Case of Kupiec Pof-Test. *European Journal of Economic Studies*, 17(3), 393-404.
- Hansen, B. (1994). Autoregressive conditional density estimation. *International Economic Review*, 35, 705-730.
- Harvey, A., & Sucarrat, G. (2013). EGARCH models with fat tails, skewness and leverage. *Computational Statistics and Data Analysis*.
- Hull, J. C. (2018). *Risk Management and Financial Institutions* (Fifth ed.). Hoboken, New Jersey: Wiley & Sons, Inc.
- Hung, J.-C., Lee, M.-C., & Liu, H.-C. (2008). Estimation of value-at-risk for energy commodities via fat-tailed GARCH models. *Energy Economics*, 1173-1191.
- Jarque, C., & Bera, A. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6(3), 255-259.
- Jorion, P. (2007). *Value at Risk The New Benchmark for Managing Financial Risk* (Third ed.). McGraw-Hill Companies, Inc.
- Kupiec, P. (1995). Techniques for Verifying the Accuracy of Risk Measurement Models. *Journal of Derivatives*, 3, 73-84.
- Ljung, G., & Box, G. (1978). On a Measure of a Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297-303.

- Malmsten, H., & Teräsvirta, T. (2004). Stylized Facts of Financial Time Series and Three Popular Models of Volatility. (S. S. Economics, Ed.) *SSE/EFI Working Paper Series in Economics and Finance*.
- Morgan, J. (1996). *RiskMetrics-Technical Document*. New York: Morgan Guaranty Trust Company.
- Nelson, D. (1991). Conditional heteroscedasticity in asset returns: a new approach. *Econometrica*, 59, 347-370.
- Nikolic-Djoric, E., & Djoric, D. (2011). Dynamic value at risk estimation for BELEX15. *Metodološki zvezki*, 8, 79–98.
- Nugroho, D., Kurniawati, D., Panjaitan, L., Kholil, Z., Susanto, B., & Sasongko, L. (2019). Empirical performance of GARCH, GARCH-M, GJR-GARCH and log-GARCH models for returns volatility. *Journal of Physics*, Conf. Ser. 1307.
- Orhan, M., & Köksal, B. (2012). A comparison of GARCH models for VaR estimation. *Expert Systems with Applications*, 3582-3592.
- Sadeghu, M., & Shavvalpour, S. (2006). Energy risk management and value at risk modeling. *Energy Policy*, 34(18), 3367-3373.
- Seong-Min, Y., & Sang-Hoon, K. (2007). A Skewed Student-t Value-at-Risk Approach for Long Memory Volatility Processes in Japanese Financial Markets. *Journal of International Economic Studies*, 11(1).
- Sewell, M. (2011). *Characterization of Financial Time Series*. UCL Department of Computer Science.
- So, M. K., & Yu, P. L. (2006). Empirical analysis of GARCH models in value at risk estimation. *Journal of International Financial Markets, Institutions & Money*, 180-197.
- Theodossiou, P., & Trigeorgis, L. (2003). Option pricing when log-returns are skewed and leptokurtic. *Working paper. Rutgers University, School of Business*.
- Ugurlu, E., Thalassinou, E., & Muratoglu, Y. (2014). Modeling Volatility in the Stock Markets using GARCH Models: European Emerging Economies and Turkey. *International Journal in Economics and Business Administration*, 2(3), 72-87.
- Wai-Sum, C., & Yiu-Kuen, T. (2018). *Financial Mathematics for Actuaries*. Singapore: World Scientific Publishing Co. Pte. Ltd.
- Werner, T., & Upper, C. (2004). Time variation in the tail behavior of bond future returns. *The Journal of Futures Markets*, 24, 387-398.