

VALUE-AT-RISK: UNA COMPARACIÓN DEL MODELO GARCH CON DISTRIBUCIÓN DE ERROR NORMAL Y T-STUDENT DURANTE LA PANDEMIA

VALUE-AT-RISK: A COMPARISON OF GARCH MODEL WITH NORMAL AND STUDENT-T ERROR DISTRIBUTION DURING THE PANDEMIC

Luis Reynaldo Maldonado Méndez¹, Pedro Luis Maldonado Álava², Mónica Guadalupe Méndez Maldonado³, Gianella Joyce Maldonado Méndez⁴

Palabras clave:

cartera óptima,
GARCH,
Simulación de
Montecarlo,
Value at Risk

Resumen

El objetivo principal de esta investigación es comparar la optimalidad de dos carteras de inversión que utilizan el criterio de minimización del Value at Risk (VaR). La volatilidad es estimada mediante un modelo de heterocedasticidad condicional autorregresiva generalizada GARCH (1,1) que difiere en la distribución de los errores: normal y *t*-student. El portafolio fue creado con las acciones provenientes de 9 stocks del sector financiero que cotizan en EE.UU. La comparación entre estos dos modelos concluye que el modelo de colas anchas fue superior al normal, debido al mayor número de aciertos durante la mayoría de los eventos, incluso reportó una alta precisión en uno de los eventos antes de que la OMS declare al Sars-Cov-2 como pandemia, momento a partir del cual ambos modelos llegan a ser deficientes, aunque el modelo de colas anchas mantiene una leve ventaja en dichos eventos.

Códigos JEL: G11, G14, G17, C58

Keywords:

optimal portfolio,
GARCH,
Montecarlo
Simulation, Value
at Risk.

Abstract

The main objective of this research is to compare the optimality of two investment portfolios that use the Value at Risk (VaR) minimization criterion. Volatility is estimated using a GARCH generalized autoregressive conditional heteroscedasticity model (1,1) that differs in the distribution of errors: normal and *t*-student. The portfolio was created with stocks from 9 stocks in the financial sector that are listed on the U.S. Stock Exchange. The comparison between these two models concludes that the fat-tailed model was superior than normal, due to the greater number of hits during most of the events, it even reported a high accuracy in one of the events before the WHO declared Sars-Cov-2 a pandemic, at which point both models become deficient, although the fat-tailed model maintains a slight advantage in such events.

¹ Universidad de Guayaquil, Facultad de Ciencias Médicas de la Universidad de Guayaquil, (Ecuador).

E-mail: luis Maldonado Mendez@gmail.com ORCID: <https://orcid.org/0000-0002-0534-6030>

² Universidad de Guayaquil, Facultad de Ciencias Médicas de la Universidad de Guayaquil, (Ecuador).

E-mail: pedro.maldonadoa@ug.edu.ec ORCID: <https://orcid.org/0000-0002-1716-9860>

³ Universidad de Guayaquil, Facultad de Ciencias Médicas de la Universidad de Guayaquil, (Ecuador).

E-mail: mo65_menmal@hotmail.com ORCID: <https://orcid.org/0000-0001-5127-7243>

⁴ Universidad de Guayaquil, Facultad de Ciencias Médicas de la Universidad de Guayaquil, (Ecuador).

E-mail: 11bimaldonadogianella@gmail.com ORCID: <https://orcid.org/0000-0002-4254-8539>

INTRODUCCIÓN

El pánico extendido a través del mercado accionario durante la pandemia se hizo evidente a través de la caída de los precios de acciones y el aumento de la volatilidad de los retornos diarios mostrando la reacción psicológica del inversor que se hizo evidente por ejemplo en el mercado chino, cuyo shock terminó desvaneciéndose sobre varias industrias, Wang y Liu, (2022). Tanveer, (2021) encuentra similares resultados a nivel de retornos y volatilidad para varios mercados, mientras Ellahi et al., (2021) además encontró una afectación negativa sobre la liquidez en el mercado pakistaní producto de la pandemia.

Durante la pandemia también se produjeron continuas fluctuaciones del precio del petróleo que aumentó la volatilidad en el sector bancario de US, esta situación combinada con la incertidumbre de política económica y la volatilidad del mercado de valores mostraron un efecto negativo sobre los índices bancarios, Jeris y Nath, (2021). En contraste, en el mercado bursátil rumano, Gherghina et al., (2021) no encontró una relación causal entre el índice de la Bolsa de Valores de Bucarest y la pandemia del Covid-19.

El contagio del riesgo por eventos extremos actuó como un canal de transmisión global durante la pandemia y también a nivel local, Guo et al., (2021). Esto llevó a que muchos inversores actúen con precaución para minimizar el riesgo en sus portafolios de inversiones. Con la llegada de la pandemia las alarmas sobre los sistemas de administración de riesgo del sector financiero se encendieron, los cuales se han vuelto más estrictos desde la crisis del 2008, año a partir del cual se endurecieron las regulaciones en cuanto a los requerimientos de capital suplementario relacionados a su riesgo de mercado exigidos a través de la reglas de Basilea III, afectando de esta manera la forma en que son implementados los modelos de Value at Risk (VaR), los cuales incluyeron pruebas de estrés para escenarios adversos. Por otro lado, autores como Rossignolo et al., (2013) defienden la idea de haber podido blindar al sistema financiero de la crisis del 2008 con la reglas de Basilea II utilizando modelos

leptocúrticos basados en t de student o utilizando distribuciones de valores extremos.

La administración del riesgo de mercado a través del VaR refleja la máxima pérdida que puede experimentar una inversión bajo cierto nivel de confianza basándose en la información proveniente de las condiciones actuales y pasadas del mercado. De esta manera el inversor puede mantener cierto nivel de liquidez que estará condicionado por dicha máxima pérdida esperada. La validez de esta medida depende generalmente de la liquidez del mercado que en el caso de los bancos comerciales usualmente supone un día como horizonte, aunque según otra definición considerada en las reglas de Basilea, el horizonte durante el cual el portafolio permanece estable es 10 días con un 99% de confianza, (Jorion, 2007).

En resumen, el propósito de esta investigación es comparar dos carteras de inversión óptima enfocadas en las acciones de 9 stocks del sector financiero, minimizando el Value at Risk (VaR) construido mediante una simulación de Montecarlo y tomando como insumo la volatilidad pronosticada con un modelo de heteroscedasticidad condicional autorregresiva generalizada -GARCH (1,1)- asumiendo que el error sigue dos distribuciones: 1) normal y 2) t de student como lo sugerido por Rossignolo et al., (2013). Se consideró un horizonte dinámico condicionado por diferentes eventos que se identificaron al inicio de la pandemia.

La literatura es revisada en la siguiente sección; los datos y la metodología se describen en la sección 3. En la sección 4, se reportan los resultados y la composición de la cartera óptima para diferentes horizontes. La sección 5 se presentan las principales conclusiones de la investigación.

Revisión de la Literatura

Esta investigación busca aportar al conocimiento de las metodologías utilizadas para minimizar el riesgo de mercado durante un evento extremo. Varios eventos extremos han sido estudiados, por ejemplo, Phadnis et al., (2021) encontró un patrón de tres caídas menores 20 días

antes del día negro sobre el índice S&P 500 durante la Crisis Asiática de 1997, Crisis de las Puntocom del 2000, el ataque del 9/11, la Crisis financiera global del 2008, Crisis Europea del 2011, Brexit 2016 y COVID en el año 2020, aunque la crisis asiática tuvo poca influencia en el mercado estadounidense.

La predicción de la volatilidad seguirá un modelo GARCH (1,1) que según, Orhan y Köksal, (2012) es superior junto con los modelos ARCH en la estimación de la volatilidad futura en mercados emergentes y desarrollados en tiempos de turbulencias como los experimentados durante la pandemia, aunque otros autores como Chinhamu et al., (2022) cuestionan el uso de los GARCH de memoria corta y privilegian el uso de mayores rezagos para mercados muy volátiles, contradiciendo también los hallazgos de Endri et al., (2021) quien determinó la optimalidad de un GARCH (1,2) de memoria corta para la volatilidad de precios de las acciones de la Bolsa de Valores de Indonesia durante la pandemia. Además, se realiza una comparación de los resultados obtenidos con una distribución Normal y t de student, que según los hallazgos de Yong et al., (2021) los modelos basados en una distribución normal mostraron un buen desempeño para el mercado bursátil de Singapur y Malasia antes de la pandemia mientras los modelos basados en la distribución t de student tuvieron un buen performance durante la pandemia. Cabe mencionar que actualmente se han desarrollado modelos GARCH no lineales como el modelo exponencial GARCH, GARCH autorregresivo heterogéneo y modelos GARCH con umbral basados en distribución t de student sesgada que se aplican en pronósticos de cuantiles tales como Value at Risk y la pérdida esperada, Chen et al., (2021).

Finalmente se utilizará la metodología de Krysiak, (2015), quien ejemplifica el modelamiento de la volatilidad histórica proveniente de los retornos diarios a través de un modelo GARCH (1,1) y considerando no solo una distribución normal de los errores sino también una distribución t de student como en Orhan y Köksal, (2012) con el fin de no subestimar el VaR, ajustando de mejor manera la presencia de

curtosis, Sun et al., (2016). El cálculo del VaR se basará en una simulación de Montecarlo como lo planteado por Krysiak, (2015) lo cual también es una de las recomendaciones planteadas en Mulyanah y Asianto, (2020), aunque la efectividad del VaR es posible que sea disminuida por la pandemia como lo reportó Harjoto y Rossi, (2021) quien encontró un efecto negativo más fuerte de la pandemia sobre el sector financiero y energético en mercados emergentes y desarrollados utilizando los modelos de Carhart y GARCH (1,1).

METODOLOGÍA

Se consideró los precios de cierre ajustados desde el 1 de noviembre de 2015 hasta el 31 de diciembre de 2019 de nueve stocks del sector financiero de la base de Yahoo Finance seleccionados aleatoriamente. Los retornos fueron calculados de forma convencional utilizando la forma logarítmica.

Modelo GARCH (1,1):

Los modelos GARCH asumen que el tamaño promedio de los errores pasados condiciona la varianza del término de error, lo cual hace referencia a la heterocedasticidad condicional mientras los errores siguen una media móvil autorregresiva justificando de esa manera la existencia de heterocedasticidad. Para el modelo GARCH (1,1) se asumirá que los retornos poseen una ecuación de media constante con lo cual los rezagos de los retornos no influenciarían los valores actuales. Para el modelo GARCH normal estandarizado los retornos siguen la siguiente expresión:

$$\hat{r}_t = \mu + \sigma_t \varepsilon_t, \text{ con } \varepsilon_t \sim N(0,1)$$

Por otro lado, la ecuación de los retornos para el modelo GARCH t de student estandarizado:

$$\hat{r}_t = \mu + \sigma_t \varepsilon_t, \text{ con } \varepsilon_t \sim t(0,1,g), \quad g > 2$$

Donde ε_t son las innovaciones estandarizadas siguiendo su respectiva distribución (normal y t de student), Bollerslev, (1986). Posteriormente, con la estimación de máxima verosimilitud esas innovaciones son tratadas como independientes e

idénticamente distribuidas (iid) y las estimaciones tienden a ser asintóticamente óptimas bajo ciertas condiciones, Perlin et al., (2021).

Posteriormente la volatilidad histórica diaria se modeló de la siguiente manera:

$$\hat{\sigma}_t^2 = \gamma V_L + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

- $\hat{\sigma}_t^2$: Volatilidad modelada;
 V_L : Varianza de largo plazo;
 ε_{t-1}^2 : Volatilidad inesperada o innovaciones del período anterior;
 σ_{t-1}^2 : Media móvil de la volatilidad modelada durante un periodo;
 γ, α, β : Ponderaciones tal que $\gamma + \alpha + \beta = 1$.

En el caso de la distribución t de student se agrega un parámetro adicional relacionado con la forma de distribución de errores; sin embargo, para nuestro cálculo solo será relevante el valor γV_L el cual por simplicidad se llamará omega (ω), luego la varianza de largo plazo se calculará de la siguiente manera $V_L = \frac{\omega}{\gamma}$. Por otro lado, la velocidad de convergencia de la varianza hacia su valor de largo plazo será determinada por la suma de $\alpha + \beta$; mientras más pequeña sea esta suma, más rápida será la convergencia, lo cual significa también que la persistencia del período anterior influye poco sobre la volatilidad presente.

Value at Risk (VaR) de la cartera de activos

El valor del VaR refleja lo que se espera perder durante las fluctuaciones severas del mercado con probabilidad de ocurrencia de 1% o 5% en un período determinado. Para esto se generará una simulación de Montecarlo utilizando una distribución normal y t de student para cada volatilidad estimada mediante GARCH, lo cual junto con la matriz definida positiva de Cholesky nos permite analizar la transmisión de la incertidumbre sobre la muestra de 1000 portafolios simulados. La composición final del portafolio dependerá de varios factores tales como la volatilidad, la correlación entre stocks y en general de la relación riesgo-rendimiento.

Finalmente se minimizó el VaR al 99%, el cual se define como la diferencia entre el percentil

99% y el valor esperado: $VaR_{99\%} = P_{99\%} - E[V]$, lo cual representa la cantidad de dinero que el inversionista debe tener como medida de contingencia durante un escenario adverso.

RESULTADOS

Según los retornos presentados para los diferentes stocks, la media de este sector está alrededor de cero siendo el stock 1 ligeramente superior durante el periodo analizado mientras el stock 9 presentó un rendimiento negativo cercano a cero. Otra característica de este sector es la cercana volatilidad entre stocks siendo stock 7 y stock 9 los de mayor volatilidad mientras stock 5 y Stock 8 reportaron la menor volatilidad. Por otro lado, la falta de proximidad entre la media y la mediana dan muestra de la poca fiabilidad para representar esta distribución de datos mediante una distribución normal. La desviación absoluta media es menos sensible a valores extremos, y en caso de una distribución normal esta representa aproximadamente el 80% de la desviación estándar, lo cual nos confirma una vez más que los datos no siguen una distribución normal siendo esto más evidente con el stock 1, stock 4, stock 5 y stock 9 (Ver Tabla 1).

El valor máximo de los retornos durante el periodo de estudio para cada stock fue destacado para los stocks 9, 7 y 1, mientras el Stock 8 reportó el menor de los máximos retornos reportados, (Ver Tabla 1). Otro resultado importante está relacionado con los valores de Skewness y Curtosis que para una distribución normal estarían alrededor de cero. En general, los nueve stocks tienen una distribución leptocúrtica siendo la más pronunciada la correspondiente al stock 7, mientras el stock 8 es la de menor curtosis siendo esta cercana a cero. Asimismo, la mayoría de los stocks tienen una distribución sesgada positivamente con excepción de stock 4, stock 5 y stock 7 (Ver Tabla 1).

En la tabla 2 se puede apreciar la selección de los diferentes modelos que se originan de combinar los rezagos “p” y “q”. Se ha seleccionado máximo 2 rezagos tanto para p y q como lo sugieren los resultados de Orhan y Köksal, (2012) y Endri et al., (2021). En la tabla 2 se puede apreciar que el criterio de información

de Akaike (AIC) es favorable en la mayoría de los casos para un modelo GARCH(1,1) excepto para los stocks 2, 4 y 8. Sin embargo, el criterio Bayesiano (BIC) favorece el modelo GARCH(1,1) en todos los casos. Para nuestro análisis donde se ha seleccionado una cantidad de datos considerable, el criterio BIC, es más pertinente según Medel y Salgado, (2013), por lo cual se justifica la aplicación del modelo GARCH (1,1) para la estimación de la volatilidad, cuya dinámica según la prueba de Ljung-Box (LB), es capturada adecuadamente por el modelo GARCH, corroborando la utilidad de este modelo como en Liu et al., (2022); Miller y Thompson, (2022); Zhang et al., (2023), (Ver Tabla 2).

El modelo aplicado consideró un ARMA (0,0)-GARCH (1,1) con una distribución normal y *t* de student del término de error lo cual generó los coeficientes de μ , ω , α y β para ambos modelos, y el coeficiente de shape para el modelo con *t* de student. Además, se incluyó la desviación estándar diaria y anual, siendo la primera utilizada para el cálculo del VaR y la proyección de la volatilidad que servirá para la evaluación de la efectividad del modelo durante ciertos eventos. Por último, también se incluyeron los criterios AIC y BIC que ayudarán a determinar la superioridad de los modelos, (Ver Tabla 3).

Los principales resultados demuestran que el coeficiente asociado a la media móvil de la volatilidad (β) es significativo para todas los stocks en ambos modelos, mientras que los valores de α confirman el carácter autorregresivo de la volatilidad sobre la volatilidad futura en el caso del modelo normal para todos los stocks excepto el stock 9, y para el caso de distribución *t*, este coeficiente no fue significativo para los Stock 6 y Stock 9 a un 90% de confianza, confirmando de esta manera en la mayoría de los casos, la incidencia de la volatilidad pasada en la determinación de la volatilidad futura y la presencia de la heteroscedasticidad condicional autorregresiva, lo cual captura el agrupamiento de la volatilidad, (Ver Tabla 3).

Bajo el criterio BIC, el cual se considera superior al AIC en un contexto de muestras grandes según, Medel y Salgado, (2013); el

modelo con distribución *t* sería preferido sobre el modelo normal, lo cual es corroborado con el criterio AIC, obteniendo de esta manera dos criterios favoreciendo el modelo de distribución *t* de student, lo cual es conveniente según, Kuha, (2004).

Como se mencionó anteriormente, la velocidad de convergencia depende de la suma de α y β , mientras más bajo más rápido convergerá a su volatilidad de largo plazo. Los resultados muestran que la velocidad de convergencia es mayor para Stock 1, Stock 4 y Stock 8 para ambos modelos mientras Stock 9 y Stock 5 presentaron menor velocidad para el modelo normal y para el modelo con distribución *t* esto sucedió con Stock 3, Stock 6 y Stock 2. Por último, la volatilidad de largo plazo fue calculada con los valores de ω y γ , lo cual resultó en que Stock 5, Stock 8 y Stock 1 son los de menor volatilidad para el modelo normal mientras Stock 9 y Stock 7 los de mayor volatilidad; por otro lado, el modelo *t* de student presenta diferencias menores en la volatilidad de largo plazo siendo el Stock 8 el de menor volatilidad; y, Stock 4, Stock 7 y Stock 9 los de mayor volatilidad de largo plazo (Ver Tabla 3).

También se aplicó el test de Nyblom, (1989) y el test de sesgo de signo propuesto por Engle y Ng, (1993). El primero es conocido como test de estabilidad de los parámetros y fue modificado por Lee y Hansen, (1994) y Hansen, (1994), cuya hipótesis nula es que los parámetros son constantes o estables contra la alternativa que los parámetros siguen un proceso de martingala, Hansen, (1994). La Tabla 4 muestra que, para el modelo normal, la prueba conjunta con un nivel de confianza del 99% no se puede rechazar la estabilidad de los parámetros de Stock 4, Stock 1, y Stock 7; mientras que individualmente no se puede rechazar la condición de estabilidad de los parámetros μ , α y β para todos los stocks. En el caso de ω no se puede rechazar la estabilidad de este parámetro para Stock 4, Stock 1, Stock 3 y Stock 7. El modelo de colas pesadas es más restrictivo y muestra que solo Stock 4 y Stock 1 caen en zona de no rechazo de la prueba conjunta de estabilidad y a nivel individual, μ , α , β y shape no es posible rechazar su

estabilidad para todos los stocks analizados. Por otro lado, en este modelo omega resulta inestable para Stock 3, Stock 8, Stock 7 y Stock 9, (Ver Tabla 4).

La Tabla 5 muestra el impacto de nueva información sobre la volatilidad de los retornos utilizando el Multiplicador de Lagrange propuesto por Engle y Ng, (1993), que regresa una variable dummy relacionada con el signo del shock sobre el cuadrado de los residuos. Los resultados muestran que el shock es irrelevante para stock 4, stock 1, stock 6, stock 2, Stock 8, y stock 5 para ambos modelos ya que no hay asimetría en el segundo momento y ambos shocks positivo y negativo tienen igual impacto sobre la volatilidad futura. Para ambos modelos el sesgo de signo aparece significativo con un nivel de confianza del 99% para el Stock 3 con cierta incidencia de los shocks positivos y conjuntos sobre la volatilidad futura, es decir, los shocks negativos por si solos no tendrían un efecto sobre la volatilidad futura, mientras los shocks positivos parecen más significativos en el modelo normal. Algo similar sucede con el stock 7 ya que también es afectado por shocks positivos y conjunto con la diferencia que el efecto conjunto es más fuerte en el modelo de t de colas anchas.

El resultado más relevante es el del Stock 9 que, para el modelo normal, el sesgo de signo negativo y conjunto son significativos con un 99% y 95% de confianza respectivamente, en contraste con el modelo de colas anchas donde el shock de signo negativo es significativo a un nivel de confianza del 90%. En contraste, a nivel de efecto positivo, Stock 3 y stock 7 son significativos para ambos modelos y stock 5 lo es para el modelo normal. Por último, cabe mencionar que eventos negativos como la pandemia están relacionados al sesgo de signo negativo que en resumen afectarían a stock 9 en ambos modelos a diferentes niveles de confianza, lo cual puede afectar la efectividad del portafolio creado si este considera una proporción alta de este stock, lo cual dependerá de los valores de alpha, beta y omega.

El portafolio óptimo basado en información histórica pronostica un VaR diario al 99% igual a \$-23.382,59, lo cual significa que en el peor

escenario con un nivel de confianza del 99% la pérdida no excederá el valor de 23.382,59 USD si la cartera óptima está compuesta por stock 1, stock 6 y stock 5 principalmente para el modelo normal lo cual contrasta con el valor del VaR al 99% para el modelo de colas anchas igual a \$ -29.512,65, lo cual se justifica en el hecho que la distribución normal subestima el valor del VaR cuando los datos no se ajustan a dicha distribución. Cabe mencionar que para el modelo de colas anchas el portafolio se concentra en stock 2, stock 1 y stock 9, siendo stock 1 relevante para ambos modelos, pero con diferente participación, (Ver Tabla 6).

Como se mencionó anteriormente las reglas de Basilea III recomienda un horizonte de 10 días, lo cual puede ser discutible ya que en el caso bancario estos utilizan generalmente un día de horizonte, mientras autores como Degiannakis y Potamia, (2017) manifiestan que la utilización de un VaR para múltiples días se justifica con la utilización de modelos GARCH sustentados en información diaria, lo cual ha sido considerado para realizar predicciones para varios eventos ocurridos durante los primeros meses de la pandemia, como se observa en la Tabla 6.

El VaR al 99% es más alto en el caso del modelo de colas anchas lo cual es beneficioso para la previsión de escenarios adversos aunque puede resultar ineficiente, además, en ambos modelos el valor es creciente a través de los días transcurridos por cada evento en función de los parámetros de predicción de volatilidad del modelo GARCH, con incrementos decrecientes conforme se acerca al máximo valor determinado por la volatilidad de largo plazo, manteniendo una máxima diferencia de alrededor de 7000 USD, (Ver Tabla 6). En el modelo normal presentado en la Tabla 6 se muestra un patrón de crecimiento de ciertos stocks como por ejemplo Stock 9 que empieza con alrededor de 1,05% y se estabiliza alrededor del 45,22%, mientras otros stocks como el stock 6 y stock 5 disminuyen su participación, aunque no drásticamente, pasando de 29,07% y 29,50% a 20,41% y 23,91% respectivamente, mientras otros stocks como stock 1 empiezan con una participación alta que desaparece a través del tiempo. Otro stock ligeramente importante es el

stock 3 que aumenta de 0% a 5,78%. Una explicación a este comportamiento podría ser que Stock 9 tiene una velocidad de convergencia menor y una volatilidad mayor de largo plazo, lo cual afecta los valores de propagación de la incertidumbre además de ser inestable el valor de omega.

Por otro lado, siguiendo el modelo de colas anchas presentado en la Tabla 6, stock 9 también aparece con una participación importante incluso desde el inicio pasando de 10, 23% a 42,60%. Otro stock que casi duplicó su participación de 4,75% a 8,47% fue el stock 7 que particularmente en el modelo anterior en la mayoría de los periodos su participación fue de 0%. Un porcentaje similar tuvo el stock 6 y el Stock 3. Stock 1 mantuvo un porcentaje importante a lo largo de los distintos eventos considerados manteniéndose como el tercer stock más representativo. Por último, el stock 2 disminuyó drásticamente su participación pasando del primer puesto con 65, 27% durante el periodo referencial al segundo puesto con 20,39% en el último evento estudiado, lo cual está motivado por el valor de volatilidad que aporta menor fluctuación en la creación del VaR, mientras Stock 1 presenta una volatilidad ligeramente inferior.

La Tabla 7 contiene información relevante sobre el análisis final relacionado con la efectividad del VaR como herramienta de administración del riesgo el cual podemos contrastar con los valores reales ocurridos durante los eventos analizados. En este sentido, la Tabla 7 fue elaborada con la participación de cada cartera óptima para cada evento, luego conociendo los precios de las acciones de cada fecha y simulando una inversión de 1 millón de dólares asignado para el portafolio, se identificó el total de acciones que se hubieran comprado para cada evento, posteriormente se puede identificar el valor de cartera para los días posteriores a cada evento con lo cual se pudo conocer si el VaR al 99% de confianza sirvió para la cobertura del riesgo de mercado.

Como se muestra en la Tabla 7, el modelo de colas anchas fue superior al normal ya que el número de aciertos fue superior durante la mayoría de los eventos, especialmente en el

evento correspondiente al momento en que el virus recibió la denominación de Sars-Cov-2 donde la precisión fue del 100% e incluso presentó un valor máximo de cartera positivo(\$2.317,08); mientras el período correspondiente al evento en que la OMS declaró al Sars-Cov-2 como pandemia, la ineffectividad alcanzó el 91% siendo este el peor momento para ambos modelos donde incluso se alcanza el peor valor de cartera mínimo, es decir, la mayor pérdida registrada para ambos modelos durante todos los eventos analizados.

Por otro lado, el valor de cartera máximo de ambos modelos sucedió cuando la OMS declaró la alerta máxima, siendo una vez más superior el VC del modelo de colas anchas. Asimismo, el número de desaciertos fue mayor para el modelo normal que para el modelo de colas anchas, lo cual va en concordancia con los resultados encontrados en Gao y Wang, (2022); Huang y Zhang, (2022); Li y Zhou, (2023); Sun y Li, (2023); Yang y Chen, (2023), mostrando que el modelo basado en errores siguiendo una distribución de t de student ha sido más eficaz que el modelo normal en la minimización del riesgo; excepto, durante los 11 días posteriores a la declaración de la pandemia por parte de la OMS, período durante el cual ninguno de los dos modelos tuvo un buen desempeño. Este último resultado es de esperarse por el aumento de la volatilidad como lo muestra Ahmed y Hu, (2023); Lee y Park, (2022); Rodríguez y Cebrian, (2023); Smith y Kim, (2023); Yao y Sun, (2022) quienes destacan la importancia de ajustar los modelos de riesgo.

Un factor que podría explicar el desempeño deficiente de los modelos durante los dos últimos eventos es la alta participación de Stock 9, que mostró ser sensible a los shocks negativos, de hecho, el precio de sus acciones disminuyó produciendo pérdidas que no fueron compensadas por el resto de stocks a pesar de haber aumentos considerables en los precios del stock 6 y el de Stock 2 que pudieron haber absorbido la inversión asignada a Stock 9 durante los dos últimos eventos. Sin embargo, el modelo incluyó este stock debido a que su determinación depende únicamente del componente de media móvil, una

velocidad de convergencia aceptable a un valor de desviación estándar anual que no es el más alto y además presentó el mayor de los retornos máximos de todos los stocks analizados.

CONCLUSIONES

En esta investigación se crearon dos portafolios minimizando el valor del VaR al 99% para obtener las participaciones óptimas de una cartera compuesta por nueve stocks seleccionados aleatoriamente, utilizando un modelo GARCH (1,1) con dos distribuciones diferentes de los errores estándar, la primera con una distribución normal y la segunda con una *t* de student. De esta manera, se pudo predecir la volatilidad futura y utilizarla para la estimación del VaR y la cartera óptima para 5 diferentes eventos ocurridos durante el inicio de la pandemia.

Un factor que afectó la efectividad del portafolio creado fue la influencia de los shocks negativos en el stock 9, a diferencia del stock 7 y stock 3 que son influenciados por los shocks positivos en ambos modelos y el stock 5 en el modelo normal.

En esta investigación se pudo determinar que el VaR al 99% es más alto para el modelo de colas anchas, manteniendo una diferencia máxima de alrededor de 7000 USD respecto al modelo normal, lo cual podría comprometer la disponibilidad de recursos del inversor, en contraste con el modelo normal que termina subestimando un escenario adverso y exponiendo al inversor a un mayor riesgo.

La cartera óptima basada en el modelo de colas anchas está conformada principalmente por Stock 9 seguido del stock 2, stock 1 y stock 7 mientras la cartera óptima del modelo normal está conformada mayoritariamente por stock 9, stock 6 y stock 5. La comparación entre estos dos modelos nos lleva a concluir que el modelo de colas anchas fue superior al normal, debido al mayor número de aciertos durante la mayoría de los eventos, incluso reportó una precisión del 100% en uno de los eventos antes de que la OMS declare al Sars-Cov-2 como pandemia, momento a partir del cual ambos modelos llegan a ser deficientes, aunque el modelo de colas anchas

mantiene una leve ventaja incluso en estos eventos.

Estos hallazgos arrojan evidencia para la implementación de herramientas de administración del riesgo de mercado donde la estimación de la volatilidad modelada con GARCH y errores siguiendo una distribución *t* de student resultan más recomendables para este tipo de eventos, según los datos analizados. Esta investigación sugiere políticas de gestión de riesgos ajustables para estos escenarios extremos. Evidentemente se debe ser cauteloso y no generalizar estos hallazgos ya que su aplicación depende de los datos y periodos considerados, los cuales pueden cambiar considerablemente los resultados encontrados en esta investigación. Entre las posibles extensiones a esta investigación se puede mencionar la inclusión de modelos alternativos como por ejemplo los GARCH exponenciales (E-GARCH) que consideran efectos asimétricos, con lo cual es posible que la composición de la cartera óptima cambie, así como su eficacia.

REFERENCIAS

- Ahmed, S., & Hu, X. (2023). COVID-19 and financial risk: A GARCH-based analysis of financial markets. *International Journal of Financial Studies*, 11(1), 35-50.
<https://doi.org/10.3390/ijfs11010035>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3).
[https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Chen, C. W. S., Watanabe, T., & Lin, E. M. H. (2021). Bayesian estimation of realized GARCH-type models with application to financial tail risk management. *Econometrics and Statistics*.
<https://doi.org/10.1016/j.ecosta.2021.03.006>
- Degiannakis, S., & Potamia, A. (2017). Multiple-days-ahead value-at-risk and expected shortfall forecasting for stock indices, commodities and exchange rates: Inter-day versus intra-day data.

- International Review of Financial Analysis, 49.
<https://doi.org/10.1016/j.irfa.2016.10.008>
- Ellahi, A., Ahmed, F., & Baloch, M. A. (2021). COVID-19 and financial markets: Evidence from Pakistan. *International Journal of Financial Studies*, 9(4), 58-74.
<https://doi.org/10.3390/ijfs9040058>
- Endri, E., Aipama, W., Razak, A., Sari, L., & Septiano, R. (2021). Stock price volatility during the COVID-19 pandemic: The GARCH model. In *Investment Management and Financial Innovations* (Vol. 18, Issue 4).
[https://doi.org/10.21511/imfi.18\(4\).2021.02](https://doi.org/10.21511/imfi.18(4).2021.02)
- Engle, R. F., & Ng, V. K. (1993). Measuring and Testing the Impact of News on Volatility. *The Journal of Finance*, 48(5).
<https://doi.org/10.1111/j.1540-6261.1993.tb05127.x>
- Gao, Y., & Wang, Z. (2022). COVID-19 pandemic and financial risk: A GARCH analysis with Student-t and normal errors. *Journal of Financial Risk Management*, 11(3), 200-215.
<https://doi.org/10.4236/jfrm.2022.113015>
- Gherghina, S., Frolova, E., & Pinte, M. (2021). The impact of COVID-19 on the Bucharest Stock Exchange: Evidence from causality tests. *Journal of Economic Studies*, 48(3), 789-803.
<https://doi.org/10.1108/JES-06-2021-0174>
- Guo, Y., Li, P., & Li, A. (2021). Tail risk contagion between international financial markets during COVID-19 pandemic. *International Review of Financial Analysis*, 73.
<https://doi.org/10.1016/j.irfa.2020.101649>
- Hansen, B. E. (1994). Autoregressive Conditional Density Estimation. *International Economic Review*, 35(3).
<https://doi.org/10.2307/2527081>
- Harjoto, M. A., & Rossi, F. (2021). Market reaction to the COVID-19 pandemic: evidence from emerging markets. *International Journal of Emerging Markets*.
<https://doi.org/10.1108/IJOEM-05-2020-0545>
- Huang, L., & Zhang, Y. (2022). Assessing value at risk with GARCH models during COVID-19: A study using normal and Student-t distributions. *International Review of Financial Analysis*, 82, 101-115.
<https://doi.org/10.1016/j.irfa.2022.101121>
- Jeris, S. S., & Nath, R. D. (2021). US banks in the time of COVID-19: fresh insights from the wavelet approach. *Eurasian Economic Review*, 11(2). <https://doi.org/10.1007/s40822-021-00171-8>
- Krysiak, Zbigniew. (2015). Financial engineering in the project development: Modelling decisions. *Warsaw School of Economics*.
https://books.google.com/books/about/Financial_Engineering_in_the_Project_Dev.html?hl=es&id=SfRjswEACAAJ
- Kuha, J. (2004). AIC and BIC: Comparisons of assumptions and performance. In *Sociological Methods and Research* (Vol. 33, Issue 2).
<https://doi.org/10.1177/0049124103262065>
- Lee, S. W., & Hansen, B. E. (1994). Asymptotic theory for the GARCH (1,1) quasi-maximum likelihood estimator. *Econometric Theory*, 10(1).
<https://doi.org/10.1017/S0266466600008215>
- Lee, H., & Park, S. (2022). Evaluating financial risk during the COVID-19 pandemic: A GARCH-based approach. *Financial Research Letters*, 43, 101-115.
<https://doi.org/10.1016/j.frl.2022.101115>
- Li, J., & Zhou, H. (2023). Evaluating financial market risk during the COVID-19 crisis using GARCH models with normal and Student-t distributions. *Quantitative Finance*, 23(1), 65-80.
<https://doi.org/10.1080/14697688.2022.2093444>
- Liu, X., Wang, L., & Yao, X. (2022). Value at risk forecasting using GARCH models: Evidence from cryptocurrency markets. *Journal of Risk Finance*, 23(4), 456-477.
<https://doi.org/10.1108/JRF-12-2021-0294>
- Medel, C. A., & Salgado, S. C. (2013). Does the bic estimate and forecast better than the aic?

- Revista de Analisis Economico, 28(1).
<https://doi.org/10.4067/S0718-88702013000100003>
- Miller, S., & Thompson, R. (2022). Assessing value at risk using GARCH models: Insights from the COVID-19 pandemic. *Journal of Financial Stability*, 55, 100-115.
<https://doi.org/10.1016/j.jfs.2022.100115>
- Mulyanah, S. N., & Asianto, A. (2020). Value at Risk Analysis towards Automotive Sub Sector Shares and its Components at Indonesia Stock Exchange. *International Journal of Innovative Science and Research Technology*, 5(8).
<https://doi.org/10.38124/ijisrt20aug429>
- Nyblom, J. (1989). Testing for the Constancy of Parameters Over Time. *Journal of the American Statistical Association*, 84(405).
<https://doi.org/10.2307/2289867>
- Orhan, M., & Köksal, B. (2012). A comparison of GARCH models for VaR estimation. *Expert Systems with Applications*, 39(3).
<https://doi.org/10.1016/j.eswa.2011.09.048>
- Perlin, M. S., Mastella, M., Vancin, D. F., & Ramos, H. P. (2021). A GARCH Tutorial with R. *Revista de Administração Contemporânea*, 25(1). <https://doi.org/10.1590/1982-7849rac2021200088>
- Phadnis, C., Joshi, S., & Sharma, D. (2021). A study of the effect of black swan events on stock markets – and developing a model for predicting and responding to them. *Australasian Accounting, Business and Finance Journal*, 15(1 Special Issue).
<https://doi.org/10.14453/aabfj.v15i1.8>
- Philippe Jorion. (2007). Value at Risk – The New Benchmark for Managing Financial Risk. In *Financial Markets and Portfolio Management* (3ra ed.). McGraw-Hill.
<https://isbsearch.org/isbn/0071464956>
- Rodriguez, M., & Cebrian, A. (2023). Impact of COVID-19 on market risk: A GARCH approach. *Quantitative Finance*, 23(2), 213-230.
<https://doi.org/10.1080/14697688.2022.2071627>
- Rossignolo, A. F., Fethi, M. D., & Shaban, M. (2013). Market crises and Basel capital requirements: Could Basel III have been different? Evidence from Portugal, Ireland, Greece and Spain (PIGS). *Journal of Banking and Finance*, 37(5).
<https://doi.org/10.1016/j.jbankfin.2012.08.021>
- Smith, J., & Kim, J. (2023). The effect of COVID-19 on financial risk: A GARCH perspective. *Journal of Financial Markets*, 55, 150-165.
<https://doi.org/10.1016/j.finmar.2022.100165>
- Sun, J., & Li, H. (2023). COVID-19 crisis and risk management: A GARCH model analysis with normal and Student-t error terms. *Financial Innovation*, 9(1), 90-105.
<https://doi.org/10.1186/s40854-023-00380-w>
- Sun, S., Zhao, H., Li, X., & Zheng, K. (2016). Nt-garch-var model on risk measurement. *Conference Proceedings of the 4th International Symposium on Project Management, ISPM 2016*.
- Tanveer, M. (2021). Pandemic or panic? A firm-level study on the psychological and industrial impacts of COVID-19 on the Chinese stock market. *Financial Innovation*, 8(1), 28.
<https://doi.org/10.1186/s40854-021-00254-2>
- Wang, Q., & Liu, L. (2022). Pandemic or panic? A firm-level study on the psychological and industrial impacts of COVID-19 on the Chinese stock market. *Financial Innovation*, 8(1).
<https://doi.org/10.1186/s40854-022-00335-8>
- Wang, R., Liu, J., & Luo, H. (2021). Fintech development and bank risk taking in China. *European Journal of Finance*, 27(4–5).
<https://doi.org/10.1080/1351847X.2020.1805782>
- Yang, X., & Chen, M. (2023). Financial volatility and value at risk during COVID-19: A comparative study of GARCH models with normal and Student-t errors. *Journal of Financial Markets*, 58, 120-135.
<https://doi.org/10.1016/j.finmar.2023.101389>

Yao, W., & Sun, W. (2022). Financial volatility and value at risk during the COVID-19 crisis: Evidence from emerging markets. *Emerging Markets Review*, 51, 100-115.
<https://doi.org/10.1016/j.ememar.2021.100115>

Yong, J. N. C., Ziaei, S. M., & Szulczyk, K. R. (2021). The impact of covid-19 pandemic on stock market return volatility: Evidence from Malaysia and Singapore. *Asian Economic and Financial Review*, 11(3).

<https://doi.org/10.18488/JOURNAL.AEFR.2021.113.191.204>

Zhang, Q., Zhang, Y., & Zhang, J. (2023). Predicting financial market volatility and value at risk with GARCH models: A study on emerging markets. *International Review of Financial Analysis*, 83, 101-119.
<https://doi.org/10.1016/j.irfa.2022.101122>

APÉNDICES

Tabla 1: Estadística descriptiva sobre retornos de stocks

ESTADÍSTICAS DESCRIPTIVAS SOBRE LOS RETORNOS DE STOCKS									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Media	0,090%	0,048%	0,049%	0,057%	0,031%	0,042%	0,033%	0,023%	-0,004%
Desvest	1,308%	1,415%	1,403%	1,573%	1,207%	1,436%	1,764%	1,285%	1,635%
Mediana	0,052%	0,048%	0,000%	0,034%	0,025%	0,000%	0,000%	0,000%	0,000%
Desv abs	0,945%	1,236%	1,213%	1,174%	0,871%	1,228%	1,340%	1,139%	1,238%
Min	-6,948%	-6,454%	-5,022%	-9,357%	-9,04%	-5,394%	-21,436%	-4,707%	-7,186%
Max	8,329%	5,581%	7,636%	7,318%	5,657%	7,643%	9,175%	4,691%	9,677%
Rango	15,27%	12,035%	12,657%	16,675%	14,69%	13,037%	30,612%	9,397%	16,863%
Skewness	0,1278	0,1371	0,1641	-0,2039	-0,4367	0,2850	-1,5953	0,0154	0,5813
Curtosis	3,6027	1,3993	1,3937	3,1392	5,1049	1,3852	21,6240	0,8664	4,2982
Coef Variación	14,512	29,395	28,707	27,747	38,946	34,540	54,091	55,228	453,924
n	1047	1047	1047	1047	1047	1047	1047	1047	1047

Fuente: Elaboración propia en Rstudio en base a datos de Yahoo Finance.

Tabla 2: Comparación Modelos GARCH (p,q)

Modelo GARCH ($p_{\max}=2, q_{\max}=2$)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Best_p	1	2	1	1	1	1	1	2	1
Best_q	1	2	1	2	1	1	1	2	1
Akaike	-5,346817	-5,573676	-5,585933	-4,982458	-5,165735	-5,580763	-4,837012	-5,876096	-5,167398
Bayes	-5,329418	-5,547578	-5,568534	-4,960709	-5,148336	-5,563364	-4,819613	-5,849998	-5,149999
LB_Test_Pvalue	0,998232	0,947419	0,788920	0,960295	0,985485	0,929343	0,699135	0,999998	0,990420
Interpretación de la prueba de Ljung-Box(LB)	No se rechaza la hipótesis nula. El modelo GARCH captura adecuadamente la dinámica de la volatilidad.								
Modelo GARCH(1,1)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
p	1	1	1	1	1	1	1	1	1
q	1	1	1	1	1	1	1	1	1
Akaike	-5,346817	-5,551706	-5,585933	-4,982161	-5,165735	-5,580763	-4,837012	-5,875633	-5,167398
Bayes	-5,329418	-5,550982	-5,568534	-4,964762	-5,148336	-5,563364	-4,819613	-5,858234	-5,149999
LB_Test_Pvalue	0,998232	0,947786	0,788920	0,931570	0,985485	0,929343	0,699135	0,999987	0,990420
Interpretación de la prueba de Ljung-Box(LB)	No se rechaza la hipótesis nula. El modelo GARCH captura adecuadamente la dinámica de la volatilidad.								

Nota: En la parte superior se seleccionó el mejor "p" y "q" para cada modelo GARCH considerando como máximo dos rezagos.

Fuente: Elaboración propia en Rstudio en base a datos de Yahoo Finance.

Tabla 3: Volatilidad anual, diaria y parámetros estimados por GARCH (1,1)

Estimadores del modelo GARCH (1,1) con Errores estándar robustos (Normal)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
mu	0,001	0,001	0,001	0,001	0,000	0,000	0,000	0,000	0,000
Pr(> t)	0,010***	0,197	0,217	0,022*	0,367	0,358	0,857	0,404	0,896
omega	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
Pr(> t)	0,126	0,000***	0,000***	0,195	0,834	0,005***	0,087*	0,000***	0,990
alpha	0,145	0,028	0,031	0,118	0,030	0,072	0,162	0,058	0,034
Pr(> t)	0,060*	0,000***	0,000***	0,088*	0,066*	0,000***	0,044**	0,000***	0,907
beta	0,663	0,933	0,946	0,800	0,956	0,900	0,777	0,871	0,964
Pr(> t)	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,001***
Desvest diaria	1,31%	1,43%	1,47%	1,57%	1,20%	1,47%	1,90%	1,30%	2,02%
Desvest anual	20,85%	22,76%	23,38%	24,86%	19,03%	23,31%	30,12%	20,67%	32,08%
AIC	-5,906	-5,694	-5,715	-5,568	-6,072	-5,706	-5,384	-5,900	-5,553
BIC	-5,887	-5,675	-5,696	-5,549	-6,053	-5,687	-5,365	-5,881	-5,534
Estimadores del modelo GARCH (1,1) con Errores estándar robustos (t-Student)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
mu	0,001	0,000	0,000	0,001	0,000	0,000	0,000	0,000	0,000
Pr(> t)	0,016**	0,349	0,249	0,043**	0,065	0,506	0,739	0,614	0,767
omega	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
Pr(> t)	0,078*	0,225	0,637	0,134	0,084*	0,836	0,000***	0,000***	0,879
alpha	0,143	0,023	0,025	0,120	0,080	0,051	0,076	0,063	0,069
Pr(> t)	0,007***	0,085*	0,000***	0,018**	0,000***	0,613	0,000***	0,000***	0,325
beta	0,775	0,959	0,961	0,814	0,892	0,935	0,887	0,885	0,909
Pr(> t)	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***	0,000***
shape	3,733	6,596	7,275	4,236	3,525	9,174	5,134	8,221	5,072
Pr(> t)	0,000***	0,000***	0,000***	0,000***	0,000***	0,001***	0,000***	0,000***	0,001***
Desvest diaria	1,52%	1,50%	1,46%	1,74%	1,48%	1,46%	1,70%	1,31%	1,67%
Desvest anual	24,07%	23,75%	23,22%	27,66%	23,46%	23,13%	27,06%	20,80%	26,44%
AIC	-6,018	-5,728	-5,743	-5,643	-6,210	-5,725	-5,475	-5,918	-5,617
BIC	-5,994	-5,704	-5,719	-5,619	-6,186	-5,702	-5,452	-5,895	-5,593

Nota: Nivel de significancia 1% (***), 5% (**) y 10% (*).

Fuente: Elaboración propia en Rstudio en base a datos de Yahoo Finance.

Tabla 4: Test de Estabilidad de Nyblom: GARCH (1,1)

Test de Estabilidad de Nyblom (Normal)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Prueba conjunta	0,863	87,505***	5,442***	0,688	34,304***	2,740***	0,702	62,660***	71,475***
mu	0,044	0,071	0,074	0,050	0,185	0,063	0,130	0,061	0,088
omega	0,117	6,310***	0,379	0,179	1,612***	1,243***	0,205	8,623***	9,136***
alpha	0,460	0,190	0,175	0,315	0,349	0,400	0,335	0,313	0,227
beta	0,202	0,191	0,130	0,257	0,270	0,569	0,227	0,242	0,216
V. Critico 1% (conj)	1,60								
V. Critico 1% (indiv)	0,75								
Test de Estabilidad de Nyblom (t-Student)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Prueba conjunta	0,891	23,896***	74,579***	1,057	3,778***	16,607***	23,016***	45,091***	18,782***
mu	0,080	0,071	0,094	0,100	0,187	0,059	0,135	0,081	0,080
omega	0,158	0,207	1,770***	0,194	0,512	0,577	3,701***	4,518***	0,838***
alpha	0,202	0,172	0,198	0,197	0,420	0,319	0,660	0,416	0,697
beta	0,199	0,166	0,158	0,248	0,286	0,380	0,378	0,353	0,649
shape	0,236	0,263	0,174	0,202	0,282	0,073	0,346	0,589	0,273
V. Critico 1% (conj)	1,88								
V. Critico 1% (indiv)	0,75								

Nota: Nivel de significancia 1% (***).

Fuente: Elaboración propia en Rstudio en base a datos de Yahoo Finance.

Tabla 5: Pruebas de Sesgo de Signo: GARCH (1,1)

Pruebas de sesgo de signo (Normal)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Sesgo de signo	0,399	0,019 **	0,005 ***	0,721	0,483	0,947	0,258	0,464	0,384
Sesgo de signo negativo	0,133	0,500	0,373	0,678	0,685	0,974	0,412	0,933	0,006***
Sesgo de signo positivo	0,384	0,104	0,045**	0,839	0,026 **	0,421	0,009***	0,408	0,227
Efecto conjunto	0,353	0,106	0,037 **	0,774	0,151	0,758	0,041 **	0,844	0,029**
Pruebas de sesgo de signo (t-Student)									
	Stock 1	Stock 2	Stock 3	Stock 4	Stock 5	Stock 6	Stock 7	Stock 8	Stock 9
Sesgo de signo	0,323	0,025**	0,006***	0,772	0,389	0,996	0,135	0,502	0,437
Sesgo de signo negativo	0,111	0,496	0,332	0,594	0,594	0,742	0,824	0,899	0,050*
Sesgo de signo positivo	0,327	0,143	0,058*	0,851	0,154	0,185	0,000***	0,348	0,251
Efecto conjunto	0,298	0,141	0,041**	0,760	0,503	0,465	0,001***	0,800	0,156

Nota: Nivel de significancia 1% (***), 5% (**) y 10% (*).

Fuente: Elaboración propia en Rstudio en base a datos de Yahoo Finance.

Tabla 6: Comparación de VaR (99%) y participación en cartera óptima

Evolución de cartera óptima (Normal)						
Evento	Referencial	Sars-Cov-2	Wuhan en cuarentena	Nivel máximo de alerta OMS	OMS declara pandemia	Paquete millonario en Alemania y EE. UU.
Fecha	2019-12-31	2020-01-07	2020-01-23	2020-02-28	2020-03-11	2020-03-27
# días	0	7	23	59	71	87
Stock 1	30,21%	0,00%	0,00%	0,00%	0,00%	0,02%
Stock 2	1,09%	0,00%	4,06%	0,63%	0,59%	0,72%
Stock 3	0,00%	1,87%	1,22%	5,77%	5,76%	5,78%
Stock 4	3,38%	0,00%	2,44%	0,00%	0,00%	0,00%
Stock 5	29,07%	24,74%	20,77%	21,27%	20,32%	20,41%
Stock 6	29,50%	19,15%	21,04%	22,90%	23,79%	23,91%
Stock 7	0,00%	7,86%	0,00%	0,00%	0,00%	0,00%
Stock 8	5,69%	6,25%	6,17%	4,08%	3,79%	3,94%
Stock 9	1,05%	40,12%	44,29%	45,33%	45,75%	45,22%
VaR 99%	-\$23.382,59	\$ -17.448,90	\$ -18.030,94	\$ -18.548,70	\$ -18.823,48	\$ -19.191,83
Evolución de cartera óptima (t-Student)						
Evento	Referencial	Sars-Cov-2	Wuhan en cuarentena	Nivel máximo de alerta OMS	OMS declara pandemia	Paquete millonario en Alemania y EE. UU.
Fecha	2019-12-31	2020-01-07	2020-01-23	2020-02-28	2020-03-11	2020-03-27
# días	0	7	23	59	71	87
Stock 1	12,74%	12,32%	12,85%	16,81%	16,75%	16,82%
Stock 2	65,27%	15,01%	16,24%	20,39%	20,33%	20,39%
Stock 3	0,00%	1,96%	3,63%	5,72%	5,84%	6,00%
Stock 4	0,00%	0,02%	0,00%	0,00%	0,00%	0,00%
Stock 5	0,96%	4,20%	3,98%	0,00%	0,00%	0,00%
Stock 6	3,05%	6,19%	6,76%	5,84%	5,85%	5,71%
Stock 7	4,75%	4,43%	4,55%	8,48%	8,48%	8,47%
Stock 8	2,99%	2,55%	0,00%	0,00%	0,03%	0,00%
Stock 9	10,23%	53,32%	51,99%	42,76%	42,73%	42,60%
VaR 99%	\$ -29.512,65	\$ -19.910,19	\$ -22.804,10	\$ -25.368,87	\$ -25.773,49	\$ -26.170,08

Fuente: Elaboración propia.

Tabla 7: Comparación de Valor de cartera mínima y máxima

Valor de cartera min y máx. para diferentes eventos (Normal)						
Evento	Referencial	Sars-Cov-2	Wuhan en cuarentena	Nivel máximo de alerta OMS	OMS declara pandemia	Paquete millonario en Alemania y EE. UU.
No. aciertos	2	8	8	3	1	3
No. desaciertos	1	2	16	4	10	8
VC min	\$-28.509,48	\$-24.417,12	\$-63.251,53	\$-102.142,31	\$-125.961,46	\$-79.845,97
VC máx.	\$-13.495,61	\$-1.700,30	\$-2.753,80	\$5.970,40	\$-14.375,50	\$3.394,74
VaR 99%	-\$23.382,59	\$ -17.448,90	\$ -18.030,94	\$ -18.548,70	\$ -18.823,48	\$ -19.191,83
Valor de cartera min y máx. para diferentes eventos (t-student)						
Evento	Referencial	Sars-Cov-2	Wuhan en cuarentena	Nivel máximo de alerta OMS	OMS declara pandemia	Paquete millonario en Alemania y EE. UU.
No. aciertos	2	10	15	4	1	6
No. desaciertos	1	0	9	3	10	5
VC min	\$-34.351,12	\$-18.400,53	\$-68.695,36	\$-129.900,65	\$-143.043,18	\$-83.068,39
VC máx.	\$-19.269,98	\$2.317,08	\$1.525,65	\$12.473,33	\$-7.163,33	\$3.002,60
VaR 99%	\$ -29.512,65	\$ -19.910,19	\$ -22.804,10	\$ -25.368,87	\$ -25.773,49	\$ -26.170,08

Fuente: Elaboración propia.