

Volatilidad y Pronóstico del Mercado Bursátil Español Mediante Series Temporales

by

Diego Rolando Minga López

A thesis submitted in conformity with the requirements
for the MSc in Economics, Finance and Computer Science

University of Huelva & International University of Andalusia

uhu.es

un
i Universidad
Internacional
de Andalucía
A

Septiembre 2022

Volatility and Forecast of the Spanish Stock Market: Using Time Series

Diego Rolando Minga López
Máster en Economía, Finanzas y Computación

Dr. Francisco Alfredo Márquez Hernández
Universidad de Huelva y Universidad Internacional de Andalucía

2022

Abstract

The objectives of this research are to analyse the ARCH and GARCH volatility models in order to determine which model can most accurately explain the historical behaviour of the Ibex 35 and Solaria S.A. stock market indices and, subsequently, to analyse the stability of the models selected to estimate the profitability and volatility of both series. The data for the Ibex 35 started from 2 January 2006 to 25 August 2022 and for Solaria S.A. from 19 June 2007 to 25 August 2022 were obtained from Yahoo Finance, using RStudio software. It was found that the GARCH(1,1) model is more efficient for the Ibex 35 series and for Solaria S.A. the best model is the AR(2)-GARCH(1,1), both models were statistically significant for estimating the return and volatility of both series.

Key words: Stock exchange, investors, yields, volatility, ARCH, GARCH.

Resumen

Esta investigación tiene como objetivos, analizar los modelos de volatilidad ARCH y GARCH, para determinar cuál es el modelo que permite explicar con mayor precisión el comportamiento histórico del índice bursátil Ibex 35 y Solaria S.A. y, posteriormente, analizar la estabilidad de los modelos seleccionados para estimar la rentabilidad y volatilidad de ambas series. Los datos del Ibex 35 comenzaron del 2 de enero de 2006 al 25 de agosto de 2022 y de la empresa Solaria S.A. del 19 de junio del 2007 al 25 de agosto de 2022, fueron datos obtenidos de Yahoo Finance, a través del software RStudio. Se encontró que el modelo GARCH(1,1) es más eficiente para la serie del Ibex 35 y para Solaria S.A. el mejor modelo es el AR(2)-GARCH(1,1), ambos modelos resultaron estadísticamente significativos para estimar la rentabilidad y volatilidad de ambas series.

Palabras clave: Bolsa de valores, índices bursátiles, inversionistas, rendimientos, volatilidad, ARCH, GARCH.

Agradecimientos

A Dios y Jesús mi salvador por la salud y vida.

A mi familia, en especial mis padres por ser mi inspiración.

A mi director, Dr. Francisco Márquez Hernández por no haberme limitado la creatividad como estudiante y apoyarme durante la realización de este trabajo.

Al profesorado del máster de Economía, Finanzas y Computación curso 2018-2019 por su enseñanza y entrega durante todo el curso.

A la Universidad Internacional de Andalucía por la beca otorgada para poder cursar este máster curso 2018-2019.

Índice

Agradecimientos.....	iv
1. INTRODUCCIÓN.....	8
1.1 Objetivos.....	10
2. REVISIÓN DE LITERATURA.....	11
2.1 Definiciones.....	11
2.1.1 Inversionistas.....	11
2.1.2 Retornos Financieros.....	11
2.1.3 Volatilidad.....	11
2.2 Serie temporal.....	13
2.2.1 Pruebas de estacionariedad.....	14
2.2.2 Pruebas de Autocorrelación y Heterocedasticidad.....	15
2.3 Modelos de volatilidad.....	16
2.3.1 Modelo-ARCH (q).....	16
2.3.2 Modelo-GARCH (p,q).....	17
2.4 Evidencia Empírica.....	18
3. METODOLOGÍA.....	22
3.1 Datos.....	22
3.2 Fases.....	23
4. RESULTADOS.....	24
4.1 Análisis descriptivo: Ibex35 y Solaria S.A.....	24
4.2 Pruebas de estacionariedad de los retornos financieros.....	28
4.3 Análisis de volatilidad.....	30
4.4 Estimación de modelos.....	32
4.5 Validación de los modelos seleccionados.....	33
4.5.1 Serie: Ibex 35.....	33
4.5.2 Serie: Solaria S.A.....	35
4.6 Pronósticos de las series.....	37
4.6.1 Pronóstico de los Retornos Ibex35.....	38
4.6.2 Pronóstico de Volatilidad Ibex 35.....	38
4.6.3 Pronóstico Retornos Solaria S.A.....	39
4.6.4 Pronóstico de Volatilidad Solaria S.A.....	40
5. CONCLUSIONES.....	41
6. REFERENCIAS.....	42
A. Anexos.....	46
A.1 R Código.....	46

Índice de figuras

Figura 1. Cotizaciones del Ibex35 del 02/01/2006 al 25/08/2022	24
Figura 2. Descomposición de la serie Ibex35.....	25
Figura 3. Cotizaciones de la empresa Solaria S.A. del 19/06/2007 al 25/08/2022.....	26
Figura 4. Descomposición de la serie Solaria S.A.....	27
Figura 5. Retornos del Ibex35	29
Figura 6. Retornos de la empresa Solaria S.A.	29
Figura 7. Volatilidad del Índice Ibex 35	31
Figura 8. Volatilidad de la Empresa Solaria S.A.	31
Figura 9. Predicción de los retornos de la serie Ibex 35.	38
Figura 10. Predicción de la volatilidad de la serie Ibex 35.	39
Figura 11. Predicción de los retornos del activo Solaria S.A.	40
Figura 12. Predicción de la volatilidad del activo Solaria S.A.	40

Índice de tablas

Tabla 1. <i>Evidencia empírica</i>	20
Tabla 2. <i>Pruebas de estacionariedad</i>	27
Tabla 3. Pruebas de estacionariedad de los retornos financieros.....	30
Tabla 4. Pruebas de estacionariedad de la volatilidad.....	32
Tabla 5. Modelos estimados para la serie del Ibex 35	33
Tabla 6. Modelos estimados para Solaria S.A.	33
Tabla 7. GARCH (1,1): Serie Ibex35.....	34
Tabla 8. AR(2)-ARCH(1): Serie Solaria S.A.	36
Tabla 9. Valores de los retornos del Ibex 35	38
Tabla 10. Valores de volatilidad del Ibex 35.....	39
Tabla 11. Valores de los retornos de Solaria S.A.	40
Tabla 12. Valores de volatilidad de Solaria S.A.....	40

1. INTRODUCCIÓN

El sistema económico de un país se puede analizar en dos sectores -real y financiero: el sector real se refiere al valor total de la producción corriente de bienes y servicios, lo que se conoce como el Producto Interno Bruto (PIB), en cambio, el sector financiero está determinado por la intermediación financiera por medio del cual capta los ahorros de los clientes y empresas para reinvertirlos con personas que requieran financiamiento o activos financieros como bonos y acciones que se comercializan en las Bolsas de Valores (Canales Salinas, 2017).

Para Villanueva (2007), la Bolsa de Valores es “un mecanismo o institución del mercado que permite la interacción de la oferta y la demanda de activos financieros, determinándose los precios de estos activos en forma eficiente” (p. 23). Su principal indicador de la actividad bursátil se denomina Índice Bursátil (Canales Salinas, 2017), estos índices “son construidos por las bolsas de valores y por empresas vinculadas a los mercados de valores”, y son de gran importancia, ya que son usados por los inversionistas “para monitorear y/o analizar los cambios en los valores de un activo financiero en especial, un sector, un mercado, un país, una estrategia de inversión o un benchmark” (Fuertes, 2016, p. 2).

En esta investigación nos centramos al análisis de los índices bursátiles, concretamente a la predicción de los índices bursátiles, los cuales son indicadores numéricos que se reflejan en las bolsas de valores, sobre el crecimiento o el decrecimiento del valor o rentabilidades medias de las acciones más representativas que lo componen (Ramírez & Castaño, 2006).

En la actualidad existen diversos índices bursátiles. Por ejemplo, en Estados Unidos está el Dow Jones, SP&500, NASDAQ100. Por otro lado, los principales índices europeos está el Dax 40, que es el índice de referencia de la Bolsa de Fráncfort y de Alemania; El IBEX 35 reúne a las 35 empresas españolas con mayor liquidez y capitalización del mercado; El FTSE 100, compuesto por las 100 empresas más grandes de Reino Unido y lejos de Europa el Nikkei 225, que recoge las 225 empresas más líquidas de Japón (ING, 2022).

Sin embargo, algunos de estos índices bursátiles han cerrado el primer semestre del año 2022, con caídas poco alentadores, como el Dow Jones que ha caído un -15.3%; el SP&500 -21.1%, el NASDAQ100 -30.3% (Cobas, 2022), entre las bolsas europeas, el IBEX-35 salda una caída del 7% (Alejandro Sánchez, 2022), el Fráncfort presentaba caídas del 1% y del 0,99% en Londres (Valencia,

2022). Esta inestabilidad en los mercados internacionales, según el Banco de España, es debido al impacto de la guerra en Ucrania o los derivados de la Covid-19 (Valencia, 2022a). Por lo que, este escenario, según el informe de Estabilidad Financiera correspondiente a la primavera de 2022 del Banco de España, con relación a los mercados de financieros, ha provocado los siguientes problemas:

- Preocupación en los inversionistas sobre las perspectivas macroeconómicas y financieras de las empresas, ya que podrían desencadenar retrocesos o elevar nuevas correcciones en los precios de los activos, lo cual implica incertidumbre sobre los rendimientos futuros de las acciones y activos financieros que se cotizan en Bolsa.
- Incertidumbre en los inversionistas sobre el comportamiento de los índices bursátiles, lo que implica reducciones de sus programas de compras, porque las decisiones de consumo e inversión de familias y empresas limitarán el crecimiento económico que está en función de las perspectivas macroeconómicas y la situación financiera de la empresa.

De esta manera, se plantea que una forma posible de eliminar la preocupación e incertidumbre de los inversionistas es a través de realizar un pronóstico¹ a los beneficios empresariales, es decir, los rendimientos o rentabilidad de las acciones de cotización de su interés (Healy & Palepu, 2001), ya que “una predicción precisa del movimiento del precio de las acciones puede generar ganancias para los inversores” (Kara et al., 2011, p. 5311). Por ello, también “es muy importante predecir la volatilidad de un determinado activo” (Díaz, 2008, p. 12), puesto que la volatilidad describe el nivel de riesgo de un activo (Priyono et al., 2020; Dutillo et al., 2021).

En tal contexto, se han desarrollado varias investigaciones para la tarea apremiante de la previsión o pronóstico de los rendimientos y volatilidad de las acciones bursátiles (García et al., 2013; Ecer et al., 2020). Tales como: algoritmos de inteligencia artificial (Lo & MacKinlay, 1988), redes neuronales artificiales (Chen et al., 2003), regresión múltiple (Chang et al., 2000), y los modelos de la familia autorregresivos AR, ARMA, ARCH, GARCH, entre otros (Reddy, 2010). Estos últimos modelos han sido los más utilizados por los investigadores, ya que permiten estimar en gran medida los rendimientos y volatilidades de las acciones (Maté & Oliva, 2003; Parody-Camargo et al., 2012; Ecer

¹ Según Echeverría (2011) citado en (Parody-Camargo et al., 2012, p. 228), el concepto de pronóstico connota un “procedimiento objetivo en el que se utiliza la información recabada en un espacio de tiempo, para predecir el futuro, considerando que las tendencias actuales continuarán en el futuro”

et al., 2020; Falcón Canillas, 2021). Además, “los modelos GARCH, han ido acoplándose a nuevas metodologías como análisis de redes neuronales” (Melo & Hoyos, 2021, p. 148)

1.1 Objetivos

A partir de las aportaciones existentes, la presente investigación tiene como objetivo general pronosticar la dirección del movimiento del Índice Bursátil del Ibex 35 y de la Empresa Solaria S.A. utilizando los modelos volatilidad Autorregresivo Condicionales Heterocedásticos (ARCH) y el modelo Generalizado Autorregresivos Condicionalmente Heterocedásticos (GARCH). Entre los objetivos específicos en los que se plantea el estudio se puede destacar:

- i. Analizar el modelo ARCH y GARCH para determinar cuál es el modelo que permite explicar con mayor precisión el comportamiento histórico del índice bursátil Ibex 35 y Solaria S.A.
- ii. Analizar la estabilidad de los modelos seleccionados.
- iii. Estimar la rentabilidad y volatilidad de las acciones que conforman el Ibex 35 y de la Empresa Solaria S.A.

El logro de los objetivos propuestos permitirá demostrar y verificar (con base en los modelos propuestos) una base objetiva y no subjetiva de la tendencia del mercado para la toma de decisiones. Dentro de esta perspectiva, conocer con mayor precisión la rentabilidad y volatilidad de los activos financieros en su cotización bursátil, respecto a comprar, vender o mantener ese tipo de activo financiero, justifica la importancia e interés de este trabajo.

La presente investigación se estructura de varias secciones: Tras este apartado introductorio, en la segunda sección, se hace una revisión teórica a los modelos objeto de estudio. En la tercera sección, se presenta la metodología utilizada. En la cuarta sección, se analiza los modelos de predicción utilizados, y a su vez, se presenta los principales resultados empíricos. Finalmente, la sección cinco se presentan las principales conclusiones a las que se ha llegado en esta investigación. Además, el presente estudio presenta una sección de anexos.

2. REVISIÓN DE LITERATURA

En esta sección se describe desde una perspectiva conceptual y técnica los modelos a desarrollar.

2.1 Definiciones

2.1.1 Inversionistas

Según Westreicher (2020), el inversor o inversionista es aquella persona o empresa que compromete su capital en el mercado financiero (con el objetivo de obtener ganancias) para comprar y vender activos financieros como acciones, bonos, contratos de futuros, divisas, materias primas, entre otros. Entre sus actividades diarias está realizar una revisión diaria de las cotizaciones o precios de los activos financieros de su interés y realizar un análisis financiero para el pronóstico de las ganancias (Healy & Palepu 2001), con el fin de obtener la mayor rentabilidad con el menor riesgo posible (Díaz, 2008).

2.1.2 Retornos Financieros

Según Parody-Camargo et al. (2012, p. 226), el rendimiento de un activo financiero es “el cambio de valor que se registra en un periodo respecto a su valor inicial”, es decir, mide cuanto por ciento ha ganado un activo o índice ante la exposición del riesgo, para conocer dicho rendimiento se definen en función del logaritmo (que se conoce como los logaritmos de los retornos financieros), su fórmula para su cálculo es la siguiente:

$$R_i = \text{Ln} \left(\frac{P_t}{P_{t-1}} \right) = p_t - p_{t-1}$$

Donde:

P_t : Es el precio o índice financiero

p_t : Índice o precio en términos logarítmicos

2.1.3 Volatilidad

La volatilidad significa movimiento y puede definirse “como las fluctuaciones en los movimientos de precios de los activos dentro de un cierto periodo de tiempo, cuanto mayor sea la volatilidad, se producirá mayores fluctuaciones en el precio de los activos” (Priyono et al., 2020, p. 46). Por ello, “la

volatilidad se utiliza principalmente como una medida del riesgo de un activo financiero, de manera que cuanto más volátil sea, mayor riesgo tendrá el inversionista de no recibir los rendimientos esperados” (Parody-Camargo et al., 2012, p. 226)

Por lo tanto, es un indicador importante que se expresa en porcentaje y permite a los inversores evaluar el nivel de riesgo de un activo financiero y así anticiparse a las variaciones (alzas y bajas) de los precios de las acciones. Para el cálculo de la volatilidad existen varias formas, según De Lara (2005, p. 44) se realiza aplicando la siguiente fórmula:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (R_i - \mu)^2}{n-1}}$$

Donde:

σ : la desviación estándar

R_i : Rendimiento

μ : es la media

n : tamaño de la muestra

Sin embargo, “la volatilidad de la cotización de las acciones no es directamente observable” por lo que, se necesita de los modelos de volatilidad o heterocedásticos (como los ARCH y GARCH para modelar la varianza condicional retardada de la serie temporal) que permiten pronosticar las rentabilidades del activo financiero que se quiera invertir y su volatilidad que va asociado a la decisión de invertir en el activo financiero (Maté & Oliva, 2003, p. 58)².

² Cabe mencionar que la estimación de la volatilidad no es una ciencia exacta, sin embargo, permite a los inversores estimar hacia donde se dirige el mercado². Para Mostafa y Atiya, 1996 en (Kara et al., 2011, p. 5311), la predicción en particular el efecto de la volatilidad para el precio de las acciones es bastante difícil y se considera una tarea desafiante de las series temporales financieras, ya que “el mercado de valores es esencialmente dinámico, no lineal, complicado, no paramétrico y de naturaleza caótica”. Por tanto, la previsión o pronóstico de las acciones es una tarea compleja por las diferentes anomalías, turbulencias o shocks económicos que experimentan los mercados de valores (Zhang et al., 2020; Ecer et al., 2020; Consoli et al., 2021).

2.2 Serie temporal

Una serie temporal o de tiempo ‘económica’ es un conjunto de observaciones de una variable, medidos y ordenados cronológicamente, donde sus propios datos o valores pasados se encuentran sujetos en el tiempo para la elaboración de pronósticos. Es decir, una colección de observaciones aleatorias que están concatenados a una fecha o periodo específico. Además, se le denomina un proceso estocástico (secuencia de datos o conjuntos de variables aleatorias que evoluciona en el tiempo) univariante $\{y_t\}$ (y_t es una variable aleatoria) donde el símbolo t representa el tiempo discreto y cada variable x_t es una observación que está definida sobre el mismo espacio de probabilidad de un proceso estocástico. Matemáticamente la definición de una serie de tiempo está dada por:

$$\{x_{t1}, x_{t2} \dots x_{tn}\} = \{x_{ti}; 1 \leq t \leq T\} = \{x_{ti}\}_{\varepsilon T}$$

Según Alonso (2006) la variable de una serie temporal se caracteriza porque es la consecuencia de tres componentes, cuya composición conjunta da como resultado los valores medidos que se detallan a continuación:

- Tendencia. - comúnmente representado por m_t , se dice es tendencia estocástica al cambio, movimiento o comportamiento aleatorio de una serie a largo plazo. Puede presentar periodos crecientes como decrecientes y determinista. Existen cuatro tipos de tendencia: a) Tendencia lineal. – es cuando la serie presenta un comportamiento alrededor de su media (incrementos y decrementos) siguiendo determinada pendiente, por medio de la diferenciación de la serie la tendencia se corrige. b) Tendencia creciente o decreciente. – similar a la anterior de tendencia en media, se diferencia porque no corresponde a una secuencia lineal, sino a curvas alcistas o bajistas por medio de la diferenciación de la serie, para corregir la no estacionalidad consiste en restar a cada parámetro el valor anterior el orden que requiera, por lo general habría que diferenciar la serie hasta dos veces. c) Tendencia periódica o sinusoidal. – conocida como estacionalidad se refiere a patrones que experimenta la serie o variables económicas cada cierto periodo, normalmente inferior o igual a un año. Es decir, es una característica de la serie que suele producirse en la misma época del año. Para eliminar la tendencia estacional (para poder predecir), se diferencia la serie directamente al valor anterior determinado. d) Tendencia en varianza. – la tendencia en varianza o heterocedasticidad se presenta también en series que tienen una tendencia en media, por tanto, al aumentar el valor de la media de forma proporcional su varianza también aumenta y de la misma forma cuando disminuye.

Mencionadas variaciones en la varianza (heteroscedasticidad), se puede eliminarla aplicando una transformación logarítmica a la serie.

- Movimiento estacional. - se representa s_t , es el componente de corto plazo y es el patrón que se repite año con año en el mismo número de periodos. Por ello, son llamadas “variaciones estacionales”, ya sea por causas climatológicas, vacacionales o fiscales.
- Movimientos aleatorios. - se representa ϵ_t , es el resultado de factores fortuitos o aleatorios que no se pueden atribuir a influencias cíclicas o estacionales. Es decir, son movimientos aislados y no observados o explicados dentro de la estacionalidad ni tendencia de la serie de tiempo. Por ejemplo, la Covid-19 fue algo no previsto.
- Observación. - Es la suma de los componentes recientemente detallados, se representa como x_t , matemáticamente está definida por:

$$x_t = m_t + s_t + \epsilon_t$$

Las series de tiempo se pueden clasificar en estacionarias y no estacionarias (Díaz, 2008):

- Estacionarias. – es una serie estable en el tiempo, es decir, su media y varianza y covarianza son constantes en el tiempo y la variabilidad también permanece constante en el tiempo.
- No estacionarias. – son series cuando la tendencia (crece o decrece a largo plazo) y/o variabilidad en el tiempo, es decir, no oscila alrededor de un valor constante. Por lo tanto, presentan caminata aleatoria o raíz unitaria.

Para comprobar el comportamiento de una serie de tiempo se pueden aplicar varias pruebas: A continuación, se detallan las pruebas a utilizar en la presente investigación:

2.2.1 Pruebas de estacionariedad

- Prueba de Dickey-Fuller Aumentada (ADF): Tiene la finalidad de ver si los coeficientes se correlacionan entre sí, por ende, toma en cuenta los shocks rezagados, obteniendo un valor crítico a niveles de confianza del 0.99%, 0.95% y 0.90%. Si el valor de probabilidad es menor que 0.05, se dice que se rechaza H_0 :No estacionariedad y se concluye mediante el error tipo I, lo que dicta la hipótesis nula H_a : Estacionariedad.
- Prueba de Phillips-Perron (PP): Esta prueba es similar a ADF, solo que en ella se mejoran las matrices de varianzas para que los regresores no se correlacionen, es decir, corrige las

inconsistencias de la matriz de varianzas y covarianzas mediante un procedimiento alternativo al ADF.

- Prueba KPSS: Formulada por Dennis Kwiatkowski, Peter Phillips, Peter Schmid y Yongcheol Shin, nos dirá si la serie de tiempo es estacionaria solo si su varianza es constante, ya que su objetivo es mejorar la pruebas al test (ADF y PP), mediante el multiplicador de lagrangeano.

2.2.2 Pruebas de Autocorrelación y Heterocedasticidad

Por otra parte, las series temporales suelen presentar problemas de autocorrelación y heterocedasticidad: Para detectar la autocorrelación se pueden utilizar diferentes métodos como el estadístico de Durbin-Watson, el contraste de Breush-Godfrey y el contraste de Ljung-Box (el cual se va a utilizar en la presente investigación).

- Test de Ljung-Box: Según Díaz (2008, p. 42), mediante el test de Ljung-Box permite saber si los coeficientes de un modelo son estadísticamente significativos para una predicción eficiente, matemáticamente está definido por:

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\hat{p}_k^2}{n-k} \right) \approx X^2 m$$

Donde:

H_0 : todos los p_k son iguales a cero

H_a : al menos un p_k es diferente de cero

- Los contrastes de heterocedasticidad permiten conocer si los errores no son constantes a lo largo del tiempo, la existencia de heterocedasticidad implica que el modelo no es confiable, sin embargo, si la varianza de los errores es constante a lo largo del tiempo el modelo es fiable 'homocedasticidad'. Para detectar la heterocedasticidad se puede hacer mediante el Multiplicador de Lagrange (LM), donde:

H_0 : La regresión es Homocedástica donde los errores tienen varianza constante

H_a : La regresión es Heterocedástica los errores no tienen varianza constante

2.3 Modelos de volatilidad

Como habíamos comentado anteriormente, las series de tiempo se pueden clasificar en estacionarias y no estacionarias, generalmente son no estacionarias y para poder predecir su comportamiento hay que conseguir la estacionariedad, es decir, su media, varianza y covarianza deben ser constantes en el tiempo este proceso y transformación se puede desarrollar aplicando un modelo Autorregresivo Integrado de Media Móvil (ARIMA) (Tercero, 2021). Sin embargo, la volatilidad de una serie financiera, la varianza no es constante en el tiempo (Casas & Cepeda, 2008), por lo que para poder predecir el riesgo o volatilidad de un activo financiero son muy útiles los modelos ARCH, de Engle (1982) y GARCH, de Bollerslev (1986).

Si bien ambos modelos recogen los cambios sistemáticos que se presentan en la varianza, la diferencia de ambos modelos está en que el modelo ARCH, ‘toma en cuenta los cuadrados de las perturbaciones mientras que el modelo GARCH lo hace de forma generalizada al incluir las varianzas condicionales de periodos anteriores’ (Parody-Camargo et al., 2012, p. 227). Es decir, el modelo ARCH la varianza es heterocedástica y depende de los residuales al cuadrado rezagados, lo que se trata de un proceso Autorregresivo (AR), mientras que el modelo GARCH la varianza es heterocedástica y depende de los residuales al cuadrado más la varianza rezagada, lo que se trata de un proceso ARMA.

2.3.1 Modelo-ARCH (q)

El modelo ARCH, ocasionó el creciente inicio de la econometría financiera y puede interpretarse como el primer modelo econométrico aplicado a las finanzas con mayor previsión de estimación de los rendimientos y volatilidades de un activo financiero (Franses & McAleer, 2002). Para Melo & Hoyos (2021) es necesario una estructura de parámetros fijos, descrita de la siguiente forma (p. 150):

$$\epsilon_t (\psi_{t-1}) \sim N(0, h_t)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \sim \alpha_0 A(L) \epsilon_t^2 + B(L) h_t$$

Donde se debe cumplir:

$$p \geq 0, q > 0$$

$$\alpha_0 > 0, \alpha_i \geq 0, i = 1, \dots, q$$

$$\beta_i \geq 0, i = 1, \dots, q$$

2.3.2 Modelo-GARCH (p,q)

El modelo GARCH, incluye a la volatilidad pasada para explicar la volatilidad presente, ya que “los modelos GARCH(p,q) no solo va a depender de las innovaciones pasadas al cuadrado en t periodos hacia el pasado, sino también de los valores que tome la varianza rezagada en el tiempo” (Melo & Hoyos, 2021, p. 151). Además, estos autores indican que la especificación del modelo GARCH(1,1), para las series financieras extremadamente largas son útiles y eficientes dada la simplificación matemática para su cálculo que se describe de la siguiente manera (p. 151)

$$h_t = \alpha_0 \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}, \alpha_0 > 0, \alpha_1 \geq \beta_1 \geq 0$$

Por tanto, la importancia de los modelos ARCH y GARCH es que “El hecho de modelar la varianza asociada a la estructura temporal de una serie financiera reduce significativamente la incertidumbre de las predicciones sobre el precio, y proporciona información muy precisa de las posibilidades reales de rentabilidad que tiene ese activo financiero [...] es posible obtener para un día concreto además del precio, el valor estimado de la volatilidad que tendrá el activo en cuestión, con lo que se sabrá el margen de rentabilidad y el riesgo asociado a la decisión de invertir en él” (Maté & Oliva, 2003, p. 58).

- Para Nugroho et al. (2021, p. 10), la selección del mejor modelo se puede calcular bajo tres criterios, tales como: el criterio de información de Akaike (AIC), el criterio de información bayesiano (BIC) y el criterio de información de desviación (DIC). Para esta investigación usaremos el criterio (AIC), que según Casas & Cepeda (2008, p. 309) es el más utilizado y está dada por:

$$AIC = -2 \frac{\ln L}{T} + \frac{2k}{T}$$

Donde:

T = es el número de observaciones

k = es el número de parámetros estimados en el modelo.

2.4 Evidencia Empírica

Es importante destacar en función a los modelos anteriormente planteados, son diversos los estudios que se han realizado. A continuación, se sintetizan algunos trabajos de lo más importantes y relacionados con esta investigación. A nivel internacional, Parody-Camargo et al. (2012, p. 238), realizó una investigación con el objetivo de determinar el mejor modelo, tales como el ARCH, GARCH, EGARCH, y PARCH para pronosticar el índice general de la bolsa de valores de Colombia, durante el período 2008-2012, concluyeron que “los modelos de la familia ARCH y GARCH, son los que mayor capacidad de modelación de la volatilidad ofrecen”. De igual manera, Melo & Hoyos (2021), investigan el comportamiento de la volatilidad de la Bolsa de Valores de Colombia, entre los años 2008 y 2020, usando los criterios AIC, concluyen que los modelos más adecuados para describir el respectivo comportamiento accionario colombiano es el modelo GARCH (1,1) y un modelo Egarch no es el más eficiente en periodos de alta volatilidad. A su vez, Sosa Castro et al. (2018), analizan la dependencia condicional entre los mercados de valores de EE. UU, México y Canadá durante el periodo 2003-2018 mediante los modelos GARCH y TARARCH antes de la crisis global, los resultados indican un incremento promedio del 38% de la dependencia condicional: antes, durante y después de la crisis financiera.

Por otra parte, se reseña estudios realizados utilizando el índice bursátil Ibex 35. En ese orden, Ahmar & del Val (2020), realizan una investigación cuyo fin es predecir a corto plazo los casos confirmados de Covid-19 y la serie bursátil del Ibex35, para tres periodos, utilizando los métodos ARIMA y SutteARIMA, los resultados demostraron que el método SutteARIMA es el más adecuado para predecir los casos de Covid-19, (los cuales pronosticaron que los casos seguirán aumentando) y para las acciones del Ibex35 (seguirán las caídas de los precios de las acciones). En cambio, Bermejo Iglesias et al. (2009, p. 12), realizan un análisis empírico para pronosticar las cotizaciones de Gas Natural, a través del modelo ARIMA, “los resultados obtenidos aproximan a que los precios de las acciones tienden a incrementarse considerablemente a partir del año y se pierde precisión en la predicción”. Por su parte, Maté & Oliva (2003), realizan un análisis detallado de la estructura temporal del Ibex35, los resultados demostraron que la especificación GARCH (1,1) es modelo de referencia para mejores predicciones. Teniendo en cuenta a Nugroho et al. (2021), investigan varios índices bursátiles a través del modelo GARCH, donde demuestran que el modelo GARCH (1,1), es confiable, eficiente y se puede aplicar con éxito (conforme a los parámetros encontrados) para el pronóstico de las series financieras. Por su parte, Costa et al. (2020, p. 13) analizaron el impacto de las buenas o

malas noticias para evaluar el impacto del sentimiento de los inversores en la volatilidad del PSI 20 y el Ibex 35 mediante el modelo TGARCH, los resultados indicaron que para “Portugal y España el sentimiento inversor presenta significancia estadística con signo negativo, lo que sugiere que la volatilidad del mercado es más sencilla a los shocks negativos en la varianza condicional” por ello, determinan que el sentimiento de los inversores es un factor clave a la hora de seleccionar inversiones en el mercado. Finalmente, el estudio realizado por Dutillo et al. (2021), aplican un modelo GARCH (1,1), para analizar el impacto de las oleadas de infecciones por Covid-19 en los países de la zona euro, los hallazgos para el Ibex 35, muestran que durante el periodo de pandemia de Covid-19, España es uno de los países que alcanzó el pico de mayor volatilidad (0,0621) entre los países de la zona euro.

Tabla 1.*Evidencia empírica*

Autor (año)	Objetivos	Data	Método/Modelo	Resultados
(Parody-Camargo et al., 2012)	Determinar cuál es el mejor modelo para pronosticar el índice general de la Bolsa de Valores de Colombia.	Periodo del 01-01-2008 al 31-05-2012	ARCH; GARCH; EGARCH; PARCH	Concluyeron que los modelos ARCH y GARCH, son los que mayor capacidad de modelación ofrecen.
(Sosa Castro et al., 2018)	Analizar la dependencia condicional de diferentes mercados de valores.	Periodo del 01-2004 al 03-2018	- GARCH -TARCH	Demuestran que los modelos GARCH y TARCH son idóneos para el pronóstico de la volatilidad, ya que se evidenció un incremento promedio del 38% de la dependencia condicional en la crisis financiera.
(Melo & Hoyos, 2021)	Determinar el comportamiento de la volatilidad de la Bolsa de Valores de Colombia.	Periodo del 17-01-2008 al 30-04-2020	-GARCH -EGARCH	Los resultados sugieren que el uso del modelo GARCH (1,1) y EGARCH (1,1) son los más eficientes para captar la volatilidad de los retornos del índice.
(Maté & Oliva, 2003)	Analizar los modelos heterocedásticos ARCH, usado la serie Ibex 35.	Periodo Nov/02 y Dic/02	- ARCH - GARCH	Los resultados obtenidos demostraron que la especificación del modelo GARCH (1,1) es la que mejor recoge la variabilidad del Ibex35
(Bermejo Iglesias et al., 2009)	Describir cómo se puede utilizar el modelo univariante ARIMA.	Periodo del 01-2000 a 12-2007	- ARIMA	Los resultados demostraron predicciones con elevada precisión a los valores del precio de la acción.

Autor (año)	Objetivos	Data	Método/Modelo	Resultados
(Ahmar & del Val, 2020)	Evaluar a corto plazo los casos de Covid-19 y la serie Ibex 35.	Periodo del 14-04-2020 al 16-04-2020	- SutteARIMA - ARIMA	Los resultados indican que el método SutteARIMA es el más adecuado que ARIMA, para calcular los pronósticos diarios de casos Covid-19 y el Ibex 35.
(Priyono et al., 2020)	Analizar la volatilidad de rendimientos diarios del FTSE 100 e Ibex 35.	Periodo de enero de 2000 hasta diciembre 2017.	- GARCH	Los resultados indican que el modelo GARCH (1,1), pronóstico en los retornos un valor de 0,64 para el índice FTSE 100 y de 0,046 para el índice bursátil del Ibex 35.
(Costa et al., 2020)	Evaluar el impacto del sentimiento de los inversores en la volatilidad del PSI 20 y el Ibex 35.	Periodo de enero 1988 hasta mayo 2019.	- TGARCH	Los resultados indican que existe un efecto asimétrico de las buenas frente a las malas noticias sobre la volatilidad del Ibex 35. Para Portugal, a diferencia de España, el sentimiento no tiene relevancia en el retorno.
(Nugroho et al., 2021)	Analizar los retornos de varios índices bursátiles mediante el modelo GARCH.	Periodo de enero 2000 a diciembre 2007.	- GARCH	Concluyen que un modelo GARCH (1,1), es el que mejor se ajusta, y por lo tanto, es estadísticamente significativo para transformar los retornos.
(Duttilo et al., 2021)	Analizar y examinar el impacto de las dos oleadas de contagios de Covid-19 en la rentabilidad y volatilidad de los países de la zona euro.	Periodo del 4-01-2016 hasta el 31-12-2020.	- GARCH	- Los resultados indicaron que a todos los países de la zona euro muestran un debilitamiento del impacto del Covid-19 en la volatilidad a medida que evoluciona la crisis.

Fuente: elaboración propia

3. METODOLOGÍA

Para alcanzar los objetivos propuestos vamos a basarnos en un estudio de series temporales. Para ello, utilizaremos los modelos de volatilidad ARCH y GARCH, ya que se ajustan a las estructuras de los datos financieros (Engle, 1982; Bollerslev, 1986). La parametrización de los modelos econométricos, fueron procesados a través del Software RStudio, ya que es un software de código abierto para el análisis estadístico y gráfico; su filosofía Open Source hace que desde sus inicios una gran comunidad de usuarios y programadores contribuyan a desarrollar nuevas funciones, paquetes y actualizaciones que son accesibles de forma libre y gratuita; esto permite que R software sea una herramienta estable, confiable y a la vanguardia, ya que está en constante actualización (Ihaka & Gentleman, 1996; Ware et al., 2013)

3.1 Datos

En esta investigación, se utilizó los datos de Yahoo Finance de la serie bursátil Ibex 35 y de la empresa Solaria S.A.

- La elección de la serie Ibex35, es debido a que está conformada por las 35 empresas más líquidas del mercado español (Falcón Canillas, 2021). Es decir, por los valores más líquidos cotizados en el Sistema de Interconexión Bursátil de la Bolsa Española (SIBE). Las empresas que conforman el Ibex35 son: Acciona, Acerinox, Grupo ACS, Aena, Almirall, Amadeus, ArcelorMittal, Banco Sabadell, Banco Santander, Bankinter, BBVA, CaixaBank, Cellnex Telecom, Cie Automotive, Colonial, Enagás, Endesa, Ferrovial, Fluidra, Grifols, IAG, Iberdrola, Indra, Inditex, Mapfre, Meliá Hotels, Merlín Properties, Naturgy, Pharmamar, Red eléctrica, Repsol, Siemens Gamesa, Solaria, Telefónica, Viscofan. Cabe mencionar, que “El índice no puede negociarse en sí mismo (no se pueden comprar o vender acciones del Ibex), aunque sí pueden realizarse inversiones sobre su evolución a través de los contratos de derivados” (Maté & Oliva, 2003, p. 61).
- Por otra parte, la empresa Solaria, es una compañía española creada en 2002, y está dedicada al sector de las energías renovables, sus actividades abarcan el diseño y la instalación de plantas de energía solar, térmica, fotovoltaica y eólica. Sus inicios fueron la producción de paneles solares, pero abandonó la fabricación, para concentrarse en la construcción y explotación de parques solares, es decir, produce energía con la ayuda del sol. - La compañía centra su negocio

en España donde proviene el 80% de facturación, el resto de la presencia en Italia y Latinoamérica en 2016 estaba valorada en 83,4 millones de euros y 2020 vale más de 1.600 millones, en 2019 cerró con unas ganancias de 23.9 millones de euros, para el primer trimestre del 2020 la Covid-19 no ha afectado sus cuentas, ya que ha instalado 50 megavatios nuevos lo que provocó la subida de las ventas un 29% generando 10,8 millones de euros con beneficio neto de 7,18 millones. La compañía es líder en energías renovables en España frente a las demás, su objetivo es alcanzar los 3.000 megavatios en 2023 (Aparicio, 2020).

3.2 Fases

Para el logro de los resultados, se aplicaron los siguientes pasos:

- i. Se partió a descargar los precios diarios del Ibex 35 a partir del 2-01-2006 al 25-08-2022 y de la empresa Solaria S.A. desde el 19-06-2007 al 25-08-2022, a través de las librerías “`library` (`quantmod`) y `getSymbols`”.
- ii. Luego se procedió a graficar ambas series para realizar un análisis descriptivo, determinar su tendencia y se comprobó la estacionariedad de las series, a través de las pruebas de estacionariedad (Dickey-Fuller Aumentada, Phillips-Perron y KPSS).
- iii. Después se procedió a realizar la transformación de cada una de las series en términos de tasas de retornos financieros y mediante las pruebas de estacionariedad se comprobó que las series son estacionarias. De la misma forma, que los retornos financieros, se calculó la volatilidad de ambas series y se procedió a realizar las pruebas de estacionariedad.
- iv. Al verificar que la volatilidad de ambas series persigue una estructura no lineal, el siguiente paso se modelizó mediante los modelos no lineales ARCH y GARCH (De Arce, 2004; Ecer et al. 2020), ambas series y mediante el criterio AIC se eligió el mejor modelo para el pronóstico de los retornos y volatilidad del Ibex35 y Solaria S.A.
- v. Seguidamente se realizó un análisis de estabilidad o validación de los modelos seleccionados, para demostrar si cumplen los supuestos tales como: Homocedasticidad, correlación serial y normalidad en los residuales de cada modelo (Peña, 2010).

- vi. Finalmente, se pronosticaron nuevos datos (respecto a sus rentabilidades y volatilidad) para ambas series objeto de estudio para la toma de decisiones (Gujarati & Porter, 2010).

4. RESULTADOS

4.1 Análisis descriptivo: Ibex35 y Solaria S.A.

La Figura 1, muestra la evolución de las cotizaciones diarias de las treinta y cinco empresas que conforman el Ibex35 a lo largo del tiempo. Donde el eje de abscisas X representa el tiempo que se toman las cotizaciones ($t = 1, \dots, 4255$) y el eje de ordenadas Y representa los valores de las acciones de cada empresa al cierre de cada día de mercado, desde el 2 de enero de 2006 al 25 de agosto de 2022.

```
getSymbols("^IBEX", scr='yahoo', from='2006-01-02',
           to='2022-08-25', periodicity='daily',
           format='xts')
```

```
chart_Series(IBEX)
```



Figura 1. Cotizaciones del Ibex35 del 02/01/2006 al 25/08/2022

La Figura 2, se refleja la descomposición de la serie del Ibex35, para poder observar su tendencia, movimiento estacional y movimientos aleatorios (Murphy, 2000; Alonso, 2006). En el gráfico se observa una tendencia decreciente, sobre todo en los años 2012 y 2021, donde alcanza sus mínimos, sin embargo, a partir de ahí empieza a recuperarse. En cuanto a movimientos estacionales no se

observa patrones que se repitan. En cambio, se puede observar fuertes movimientos aleatorios (o caídas importantes de la serie) en el precio de las acciones entre los años 2008, 2012 y finales del 2019 e inicios del 2020.




Figura 2. Descomposición de la serie Ibx35

Hemos buscado una explicación a estos sucesos y hemos comprobado que desde el comienzo de la crisis en 2007 la prima de riesgo española subió ese verano a máximos históricos (Hontoria de Francisco, 2014). En el año 2012, la crisis de la deuda soberana, del sistema bancario y del sistema económico en general afectó a todos los mercados bursátiles de los países europeos (Ahmar & del Val, 2020). De ahí que a finales de diciembre del 2019, se reportó por primera vez el caso de Covid-19 en China, y en España comenzaron a detectarse el 12 de febrero de 2020, para el mes de abril eran 148.220 casos confirmados y 14.792, por ello, “España inicio el cierre de restaurantes, bares, hoteles, escuelas y universidades teniendo como impacto en el Ibx35 un descenso de hasta el 14% al cierre de las acciones” (Ahmar & del Val, 2020, p. 2).

De la misma forma, en la figura 3 se muestra la evolución de las cotizaciones diarias de la empresa Solaria S.A. a lo largo del tiempo. Donde el eje de abscisas X representa el tiempo que se toman las cotizaciones (en este caso R descargó la información disponible) desde el 19-06-2007 hasta 25-08-2022, ($t = 1, \dots, 3881$) y el eje de ordenadas Y, representa los valores de las acciones de cada empresa al cierre de cada día de mercado.

`chart_Series(SLR.MC)`




Figura 3. Cotizaciones de la empresa Solaria S.A. del 19/06/2007 al 25/08/2022

En la Figura 4, se observa la descomposición de la serie de Solaria S.A., y así poder observar de mejor manera su tendencia, movimiento estacional y movimientos aleatorios (Murphy, 2000; Alonso, 2006). En el gráfico se observa claramente una tendencia creciente, a partir de finales del año del 2016, pero alcanza su pico más alto en el año 2020. Este crecimiento exponencial puede deberse a que la empresa en el año 2016 estaba valorada en 83,4 millones de euros y 2020 alcanza su valor de 1.600 millones de euros, por ende, grandes grupos inversores muestran interés por Solaria. En cuanto a movimientos estacionales, se podría decir que corresponde al intervalo de tiempo entre los años 2010 y 2016, ya que se observa patrones que se repiten. Se observa dos movimientos aleatorios, el primero cuando alcanza su pico más alto en el año 2020 y la caída leve del precio de las acciones entre finales del 2020 e inicios 2021, ya que la Covid-19 no ha afectado sus cuentas.

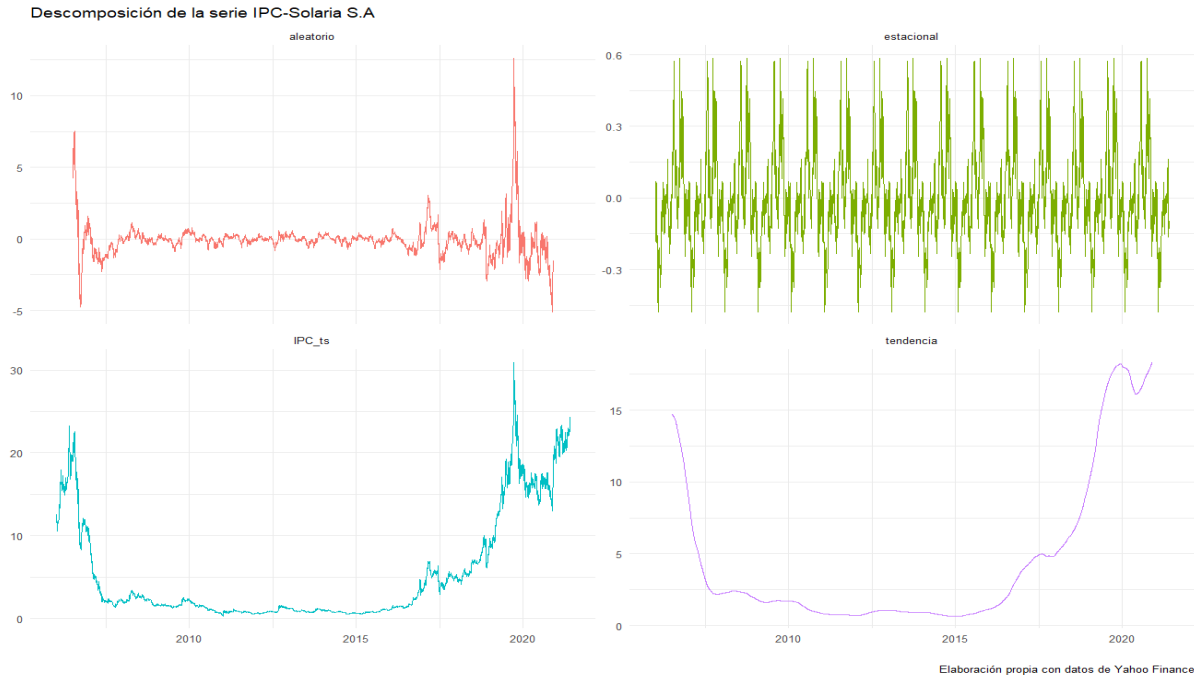


Figura 4. Descomposición de la serie Solaria S.A.

Por tanto, los gráficos anteriores nos dan a notar que la serie del Ibex35 y Solaria S.A. -no son estacionarias en media, ya que la media no es constante a lo largo del tiempo y reflejan, por un lado, tendencia decreciente y por el otro creciente, por lo cual nos encontramos ante una serie no estacionaria. Para comprobarlo se procede a realizar el cálculo de las pruebas de estacionariedad, aplicando las pruebas de Dickey-Fuller, Phillips-Perron y KPSS (Gujarati & Porter, 2010). A continuación, se muestran los resultados de las pruebas:

Tabla 2.

Pruebas de estacionariedad

Pruebas	SLR	IBEX
Dickey-Fuller Aumentada	0.9034414	0.2075205
Phillips-Perron	0.9105413	0.2084849
KPSS	0.0100000	0.0100000

Fuente: elaboración propia con soporte de RStudio

La interpretación de las pruebas son las siguientes:

- Dickey-Fuller Aumentada y Phillips-Perron. – Si el valor de probabilidad es menor que 0.05, se dice que se rechaza H_0 : No estacionariedad y se concluye mediante el error tipo I, lo que dicta la hipótesis nula H_a : Estacionariedad.
- KPSS. – Si el valor de probabilidad es mayor que 0.05, se dice que no se rechaza H_0 : Estacionariedad y se concluye mediante el error tipo II, que la serie es estacionaria.

Por lo tanto, las pruebas de Dickey-Fuller y Phillips-Perron arrojan valores de probabilidad mayores que 0.05, y se concluye que las series (Ibex35 y Solaria S.A.) no son estacionarias. La prueba KPSS, arrojó un valor de probabilidad menor que 0.05, por lo que se concluye que todas las series no son estacionarias.

*Las pruebas anteriores confirman que los precios y/o índices financieros (en nuestro caso la serie del Ibex 35 y de las acciones de la empresa Solaria) sin transformación alguna, son series no estacionarias. Por lo que queda transformar las series en un proceso estacionario para poder pronosticar (Gujarati & Porter, 2010).

4.2 Pruebas de estacionariedad de los retornos financieros

Para ello, realizamos la transformación de las series tanto del Ibex35 y Solaria S.A. en términos de tasas de retornos financieros. Vale recordar que los retornos financieros, mide en cuanto porciento ha ganado un activo o índice ante la exposición al riesgo (Poon & Taylor, 1992; López Gracia, 1992; Maté & Oliva, 2003). Con fines demostrativos, la figura 5 y 6 muestran gráficamente las series en términos de tasas de retornos financieros y con ello revisaremos si el comportamiento de dichos cálculos se parece a un proceso de ruido blanco, que es equivalente a un proceso estacionario.




Figura 5. Retornos del Ibex35




Figura 6. Retornos de la empresa Solaria S.A.

Las gráficas anteriores de las series Ibex35 y Solaria, muestran un comportamiento muy parecido al de ruido blanco, ya que la media parece comportarse o fluctuar alrededor de 0, aunque la varianza no parece ser del todo constante hay indicios de un proceso estacionario, sin embargo, procedemos a confirmarlo, a través de las pruebas de estacionariedad.

La tabla 3, presentan los valores de probabilidad realizados a las series del Ibex35 y Solaria S.A.

Tabla 3.

Pruebas de estacionariedad de los retornos financieros.

Pruebas	SLR	IBEX
Dickey-Fuller Aumentada	0.01	0.01
Phillips-Perron	0.01	0.01
KPSS	0.01	0.10

Fuente: elaboración propia con soporte de RStudio

En la tabla anterior, se puede observar los siguiente:

- Para las pruebas Dickey-Fuller y Phillips-Perron en ambas series, los valores probabilísticos son inferiores a 0.05, por lo tanto, al coincidir con la regla de decisión, se rechaza H_0 de no estacionariedad y mediante el error tipo I, se puede concluir que las series son estacionarias.
- La prueba KPSS sucede un fenómeno contrario, ya que el valor de probabilidad es mayor que 0.05, por lo cual mediante la regla de decisión se puede concluir que hay un error tipo II, en este caso para la serie del Ibex35 se concluye que las series son estacionarias.

*Se demuestra que los retornos financieros (Ibex 35 y Solaria S.A.) son variables financieras que se comportarán como un proceso estacionario, las mismas que se utilizarán (más adelante) para elaborar pronósticos de series de tiempo objeto de estudio.

4.3 Análisis de volatilidad

La volatilidad que es un indicador para saber el nivel de riesgo de los activos (Parody-Camargo et al., 2012; Priyono et al., 2020; Dutillo et al., 2021). En ocasiones no presentan estructuras lineales, ya que los activos al cambiar su nivel de precio en el tiempo se traducen en una varianza no constante y representa una estructura no lineal.

A continuación, las figuras 7 y 8 muestran gráficamente la volatilidad de los precios, de la serie del Ibex35 y Solaria S.A.




Figura 7. Volatilidad del Índice Ibex 35




Figura 8. Volatilidad de la Empresa Solaria S.A.

Las gráficas anteriores de las series Ibex 35 y Solaria no presentan estructuras lineales, ya que se reflejan periodos de baja volatilidad, que le siguen un periodo más alto de volatilidad, y a un periodo de alta volatilidad le siguen periodos de volatilidad normal. Sin embargo, para comprobarlo realizamos las pruebas de estacionariedad (de la misma manera que los rendimientos), la prueba KPSS es la que determina si la volatilidad persigue una estructura lineal, ya que al ser una prueba de varianza (Tabla 4).

Tabla 4.

Pruebas de estacionariedad de la volatilidad

Pruebas	SLR	IBEX
Dickey-Fuller Aumentada	0.01	0.01
Phillips-Perron	0.01	0.01
KPSS	0.01	0.10

Fuente: elaboración propia con soporte de RStudio

La interpretación de las pruebas son las siguientes:

- Las series del Ibex35 y Solaria, a través de las pruebas de Dickey-Fuller y Phillips-Perron son estacionarias en medias.
- La prueba KPSS, resultó rechazar H_0 para los dos índices bursátiles, por lo que, es indicativo que no son estacionarias en varianza.

Por lo tanto, se procede a modelar mediante los modelos ARCH y GARCH, ya que son los adecuados cuando la varianza no es constante (Parody-Camargo et al., 2012).

4.4 Estimación de modelos

La tabla 5 y 6, muestra los modelos estimados para la serie de los retornos financieros del Ibex35 y Solaria, mediante el criterio de AIC.

- Los modelos que se estimaron para la serie del Ibex35, son los modelos de varianza ARCH (1) y GARCH (1,1). El resultado indica que el modelo más eficiente es un GARCH (1,1), ya que tiene un AIC óptimo.

Tabla 5.

Modelos estimados para la serie del Ibex 35

Modelos	AIC
ARCH(1)	-5.666924
GARCH(1,1)	-5.903507

Fuente: elaboración propia con soporte de RStudio

- Los modelos que se estimaron para la serie de los retornos financieros de Solaria S.A., son: AR(2)-ARCH(1) y AR(2)-GARCH(1,1). Se encontró que el mejor modelo es el AR(2)-GARCH(1,1), ya que tiene un AIC óptimo.

Tabla 6.

Modelos estimados para Solaria S.A.

Modelos	AIC
AR(2)-ARCH(1)	-3.469057
AR(2)-GARCH(1,1)	-3.533810

Fuente: elaboración propia con soporte de RStudio

4.5 Validación de los modelos seleccionados

En la presente sección, se mostrará la estabilidad o validación de los modelos seleccionados, con la finalidad de presentar si se cumplen los supuestos esenciales tales como: homocedasticidad, no correlación serial y normalidad en los residuales de cada modelo (Peña, 2010).

4.5.1 Serie: Ibex 35

A continuación, la tabla 7 y 8 se muestran las pruebas de coeficientes de cada serie, lo cual tiene la finalidad de demostrar si los multiplicadores en el tiempo son estadísticamente diferentes de 0, para ello, se debe considerar que si el p-value es menor que 0.05, entonces habrá evidencia suficiente para poder validar que los valores estimados son significativos (Díaz, 2008).

- Para la serie del Ibex 35, se observa que los coeficientes estimados, todos se encuentran con un p-valor menor que 0.05, por lo que hay significancia estadística para cada estimador.

Tabla 7.

GARCH (1,1): Serie Ibex35

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000	0.000	2.118	0.034
omega	0.000	0.000	2.971	0.003
alpha1	0.122	0.010	11.946	0.000
beta1	0.859	0.012	73.946	0.000

Fuente: elaboración propia con soporte de RStudio

A continuación, se presentan diversas pruebas de autocorrelación y heterocedasticidad que se realizó a los residuales, en este caso el p-value debe ser mayor que 0.05 para validar la ausencia de autocorrelación y de heteroscedasticidad.

```
##
## *-----*
## * GARCH Model Fit *
## *-----*
##
## Conditional Variance Dynamics
## -----
## GARCH Model : sGARCH(1,1)
## Mean Model : ARFIMA(0,0,0)
## Distribution : norm
##
## Optimal Parameters
## -----
## Estimate Std. Error t value Pr(>|t|)
## mu 0.000359 0.000169 2.1182 0.034159
## omega 0.000005 0.000002 2.9708 0.002971
## alpha1 0.121793 0.010195 11.9461 0.000000
## beta1 0.859377 0.011622 73.9459 0.000000
##
## Robust Standard Errors:
## Estimate Std. Error t value Pr(>|t|)
## mu 0.000359 0.000163 2.19751 0.027984
## omega 0.000005 0.000006 0.86243 0.388453
## alpha1 0.121793 0.016636 7.32111 0.000000
## beta1 0.859377 0.025684 33.45951 0.000000
##
## LogLikelihood : 12548.95
##
## Information Criteria
## -----
##
## Akaike -5.9035
## Bayes -5.8975
## Shibata -5.9035
## Hannan-Quinn -5.9014
##
## Weighted Ljung-Box Test on Standardized Residuals
## -----
## statistic p-value
## Lag[1] 2.087 0.1486
## Lag[2*(p+q)+(p+q)-1][2] 2.258 0.2234
## Lag[4*(p+q)+(p+q)-1][5] 3.056 0.3969
## d.o.f=0
## H0 : No serial correlation
##
## Weighted Ljung-Box Test on Standardized Squared Residuals
## -----
## statistic p-value
## Lag[1] 1.904 0.16765
## Lag[2*(p+q)+(p+q)-1][5] 6.311 0.07592
## Lag[4*(p+q)+(p+q)-1][9] 9.891 0.05292
## d.o.f=2
```

```

##
## Weighted ARCH LM Tests
## -----
## Statistic Shape Scale P-Value
## ARCH Lag[3] 0.6022 0.500 2.000 0.43775
## ARCH Lag[5] 7.4603 1.440 1.667 0.02704
## ARCH Lag[7] 9.1643 2.315 1.543 0.02867
##
## Nyblom stability test
## -----
## Joint Statistic: 1.1011
## Individual Statistics:
## mu 0.3022
## omega 0.1833
## alpha1 0.2134
## beta1 0.3561
##
## Asymptotic Critical Values (10% 5% 1%)
## Joint Statistic: 1.07 1.24 1.6
## Individual Statistic: 0.35 0.47 0.75
##
## Sign Bias Test
## -----
## t-value prob sig
## Sign Bias 1.67203 0.0945920 *
## Negative Sign Bias 0.03354 0.9732426
## Positive Sign Bias 1.96722 0.0492233 **
## Joint Effect 16.94296 0.0007261 ***
##
## Adjusted Pearson Goodness-of-Fit Test:
## -----
## group statistic p-value(g-1)
## 1 20 121.8 5.143e-17
## 2 30 140.8 1.267e-16
## 3 40 159.0 2.029e-16
## 4 50 165.3 1.572e-14
## Elapsed time : 0.271503

```

- Se aprecia que la prueba LM (ARCH) tiene efectos heterocedásticos, sin embargo, las pruebas de Ljung-Box resultan contar con un p-value mayor que 0.05, por lo que la serie no tiene autocorrelación, lo cual es adecuado para realizar la estimación o pronóstico de la rentabilidad y volatilidad de la serie Ibex 35.

4.5.2 Serie: Solaria S.A.

A continuación, se muestra la prueba de coeficientes que se realizó a la serie de la empresa Solaria S.A.

- Los resultados indican que la mayoría de los coeficientes son significativos, salvo el valor correspondiente a la constante del proceso AR(2).

Tabla 8.

AR(2)-ARCH(1): Serie Solaria S.A.

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000	0.000	1.275	0.202
ar1	-0.572	0.017	-32.828	0.000
ar2	-0.259	0.013	-19.173	0.000
omega	0.001	0.000	31.469	0.000
alpha1	0.373	0.033	11.467	0.000

Fuente: elaboración propia con soporte de RStudio

A continuación, se presentan las diversas pruebas de autocorrelación y heterocedasticidad que se realizó a los residuos del modelo, para validar la ausencia de autocorrelación y de heteroscedasticidad.

```
##
## *-----*
## * GARCH Model Fit *
## *-----*
##
## Conditional Variance Dynamics
## -----
## GARCH Model : sGARCH(1,0)
## Mean Model : ARFIMA(2,0,0)
## Distribution : norm
##
## Optimal Parameters
## -----
## Estimate Std. Error t value Pr(>|t|)
## mu 0.000429 0.000336 1.2745 0.20248
## ar1 -0.571886 0.017421 -32.8280 0.00000
## ar2 -0.258662 0.013491 -19.1734 0.00000
## omega 0.001344 0.000043 31.4685 0.00000
## alpha1 0.373311 0.032556 11.4666 0.00000
##
## Robust Standard Errors:
## Estimate Std. Error t value Pr(>|t|)
## mu 0.000429 0.000209 2.0476 0.040600
## ar1 -0.571886 0.020608 -27.7513 0.000000
## ar2 -0.258662 0.025555 -10.1219 0.000000
## omega 0.001344 0.000091 14.7985 0.000000
## alpha1 0.373311 0.078258 4.7703 0.000002
##
## LogLikelihood : 6734.97
##
## Information Criteria
## -----
##
## Akaike -3.4691
## Bayes -3.4610
## Shibata -3.4691
## Hannan-Quinn -3.4662
##
## Weighted Ljung-Box Test on Standardized Residuals
## -----
## statistic p-value
## Lag[1] 36.36 1.64e-09
## Lag[2*(p+q)+(p+q)-1][5] 221.54 0.000e+00
## Lag[4*(p+q)+(p+q)-1][9] 263.68 0.000e+00
## d.o.f=2
## H0 : No serial correlation
##
## Weighted Ljung-Box Test on Standardized Squared Residuals
## -----
## statistic p-value
## Lag[1] 0.8189 3.655e-01
## Lag[2*(p+q)+(p+q)-1][2] 7.4796 8.890e-03
```

```

## Lag[4*(p+q)+(p+q)-1][5] 53.2177 7.550e-15
## d.o.f=1
##
## Weighted ARCH LM Tests
## -----
## Statistic Shape Scale P-Value
## ARCH Lag[2] 13.31 0.500 2.000 2.64e-04
## ARCH Lag[4] 61.20 1.397 1.611 1.110e-16
## ARCH Lag[6] 76.67 2.222 1.500 0.00e+00
##
## Nyblom stability test
## -----
## Joint Statistic: 1.8652
## Individual Statistics:
## mu 0.05328
## ar1 0.38876
## ar2 0.05197
## omega 1.18605
## alpha1 0.62501
##
## Asymptotic Critical Values (10% 5% 1%)
## Joint Statistic: 1.28 1.47 1.88
## Individual Statistic: 0.35 0.47 0.75
##
## Sign Bias Test
## -----
## t-value prob sig
## Sign Bias 1.441 0.1498
## Negative Sign Bias 1.079 0.2806
## Positive Sign Bias 1.102 0.2707
## Joint Effect 2.650 0.4488
##
##
## Adjusted Pearson Goodness-of-Fit Test:
## -----
## group statistic p-value(g-1)
## 1 20 218.8 6.130e-36
## 2 30 227.5 1.097e-32
## 3 40 264.2 3.126e-35
## 4 50 284.0 7.552e-35
##
## Elapsed time : 0.58564

```

- Se observa que el modelo AR(2)-GARCH(1,1), tiene presencia de heterocedasticidad y de autocorrelación. Sin embargo, tomando en cuenta el criterio de Akaike fue el mejor, pero no cumple con la homocedasticidad y no autocorrelación. No obstante, tiene significancia individual por lo que se puede utilizar para estimar la rentabilidad y volatilidad de la serie Solaria S.A.

4.6 Pronósticos de las series

Con base a los modelos elegidos a continuación se realiza la estimación para la serie del Ibex35 y de la empresa Solaria S.A., tanto de los rendimientos y volatilidades a cinco periodos futuros, es decir, una semana financiera debido a la robustez estadística o de predicción que existe al realizar predicciones a corto plazo (Bermejo Iglesias et al., 2009).

4.6.1 Pronóstico de los Retornos Ibex35

La tabla 9, indica una estimación del rendimiento que tendrán el precio de las acciones o activos financieros de las 35 empresas que conforman el Ibex 35. Es decir, los días entre el 26 de agosto al 01 septiembre se estima una rentabilidad del 0.03588%. Este resultado positivo puede incidir en la decisión en las decisiones de los inversionistas con respecto a comprar o vender activos financieros del Ibex35. Hemos buscado noticias sobre como acabó la sesión el Ibex 35 el jueves 25 de agosto, y nos encontramos que cerró con una variación del 0,15% y con un rango de cotización del 1.17%, lo que podemos considerar normal, lo cual se refleja en el pronóstico (línea roja) sin afectaciones.

Tabla 9. Valores de los retornos del Ibex 35

	Retorno	Fecha
T+1	0.03588	2022-08-26
T+2	0.03588	2022-08-29
T+3	0.03588	2022-08-30
T+4	0.03588	2022-08-31
T+5	0.03588	2022-09-01



Figura 9. Predicción de los retornos de la serie Ibex 35. En términos porcentuales a 5 días.

4.6.2 Pronóstico de Volatilidad Ibex 35

La tabla 10 indican los valores (en términos porcentuales) del nivel de riesgo que presentan los activos financieros del Ibex 35. Se estima que la medida de riesgo o volatilidad de los activos financieros para el día 26 de agosto será del 0.83888%, y como el precio de las acciones es cambiante la serie pronostica leves subidas de volatilidad en los próximos días.

Tabla 10. Valores de volatilidad del Ibex 35

	Volatilidad	Fecha
T+1	0.83888	2022-08-26
T+2	0.85912	2022-08-29
T+3	0.87853	2022-08-30
T+4	0.89716	2022-08-31
T+5	0.91507	2022-09-01




Figura 10. Predicción de la volatilidad de la serie Ibex 35. En términos porcentuales a 5 días.

4.6.3 Pronóstico Retornos Solaria S.A.

Los resultados para empresa Solaria S.A., indican una estimación de rentabilidad del precio de las acciones del 0.0295641%, y para los próximos días sus números seguirán siendo al alza en positivo, no obstante, su volatilidad es mayor de 0.0388534% y creciente, ya que puede deberse a los riesgos de inversión que hace la empresa para su crecimiento. Hemos buscado sobre el cierre de Solaria S.A. el día anterior al pronóstico que pudiera explicar sus rendimientos positivos, y se anunció que las energías renovables continúan su tendencia alcista y que para Solaria S.A. en lo que va del año acumula una subida del 34%.

Tabla 11. Valores de los retornos de Solaria S.A.

	Retorno	Fecha
T+1	0.0295641	2022-08-26
T+2	0.0403972	2022-08-29
T+3	0.0433773	2022-08-30
T+4	0.0382606	2022-08-31
T+5	0.0410045	2022-09-01

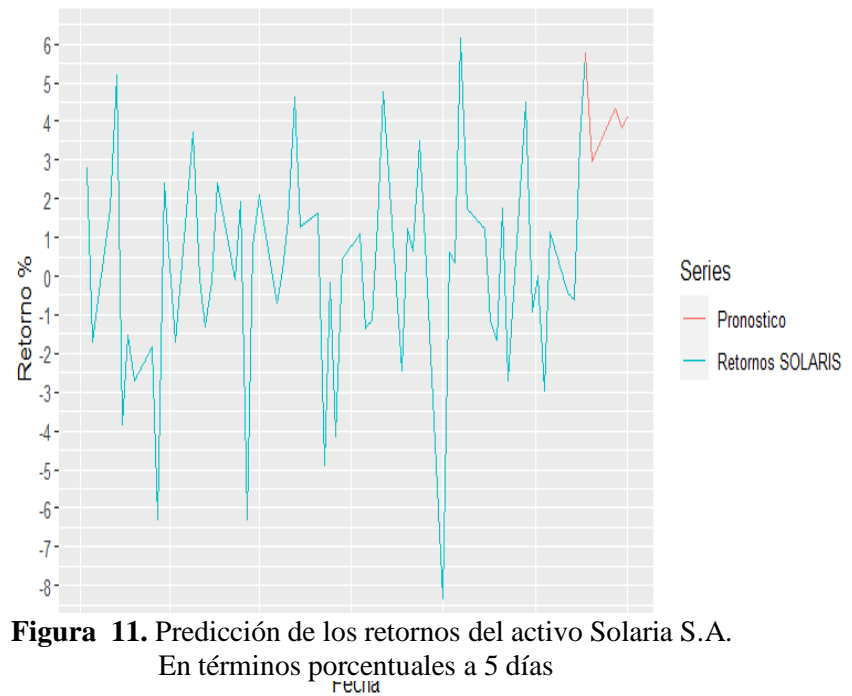


Figura 11. Predicción de los retornos del activo Solaria S.A. En términos porcentuales a 5 días

4.6.4 Pronóstico de Volatilidad Solaria S.A.

Tabla 12. Valores de volatilidad de Solaria S.A.

	Volatilidad	Fecha
T+1	0.0388534	2022-08-26
T+2	0.0395479	2022-08-29
T+3	0.0401499	2022-08-30
T+4	0.0406730	2022-08-31
T+5	0.0411283	2022-09-01




Figura 12. Predicción de la volatilidad del activo Solaria S.A. En términos porcentuales a 5 días.

5. CONCLUSIONES

Esta investigación tenía como objetivos, en primer lugar, *¿Analizar el modelo ARMA y GARCH para determinar cuál es el modelo que permite explicar con mayor precisión el comportamiento histórico del índice bursátil Ibex 35 y Solaria S.A.?* Para este objetivo que ambas serie siguen modelos diferentes, se encontró que el mejor modelo mediante el criterio de Akaike para el Ibex 35 es el GARCH (1,1) lo que coincide con los estudios (Maté & Oliva, 2003; Melo & Hoyos, 2021; Nugroho et al., 2021; Priyono et al., 2020), mientras que la empresa Solaria S.A. fue una especificación AR(2)-GARCH(1,1), lo cual los retornos van a depender del comportamiento de la serie rezagada en dos periodos en el tiempo.

Ambos modelos a través de las pruebas de coeficientes fueron estadísticamente significativos. Sin embargo, las pruebas de autocorrelación y heterocedasticidad que se realizó a los residuales para comprobar *la estabilidad de los modelos seleccionados (ii objetivo)* se encontró presencia de heteroscedasticidad, pero no autocorrelación, lo que es un punto a favor para un buen pronóstico de la serie Ibex 35. Por su parte, la serie Solaria S.A. el modelo tiene presencia de heterocedasticidad y de autocorrelación, pero el modelo tiene significancia, lo cual se pudo utilizar para realizar las predicciones con él. Por tanto, se pasó a realizar las estimaciones con los modelos seleccionados, se encontró para la serie bursátil del Ibex 35 una rentabilidad de 0.03588% asociado aún riesgo del 0.83888%. En cambio, la empresa Solaria S.A. se estima que el precio de las acciones tendrá una rentabilidad del 0.0295641% asociado con un riesgo del 0.0388534%.

Todo ello pone de relieve, que los modelos de volatilidad utilizados captan las noticias malas como el conflicto bélico entre Rusia y Ucrania, ya que en los últimos meses ambas series objeto de estudio han tenido una volatilidad muy presente y los pronósticos elaborados tienden a que los próximos días la volatilidad siga subiendo. No obstante, al ser el mercado muy dinámico, las rentabilidades y volatilidades pronosticadas suelen ser muy cortas, por lo que se sugiere actualizar los datos semana a semana o día con día, para mejorar los pronósticos o estimaciones de los modelos.

Las limitaciones de la investigación están determinadas por la selección de dos modelos (ARCH y GARCH), los cuales este tipo de modelos tienen muchas extensiones como los modelos EGARCH (*Exponencial Autoregressive Conditional Heteroscedasticity*), entre otros (De Arce, 2004). Por ello, para futuras investigaciones se podría utilizar los modelos EGARCH, para evidenciar que generan las noticias en los inversionistas, como también un análisis de regresión, redes neuronales y varios tipos

de inteligencia computacional para pronosticar la dirección de los diferentes índices bursátiles (Ecer et al., 2020; Melo & Hoyos, 2021).

6. REFERENCIAS

- Ahmar, A. S., & del Val, E. B. (2020). SutteARIMA: Short-term forecasting method, a case: Covid-19 and stock market in Spain. *Science of the Total Environment*, 729, 2–6. <https://doi.org/10.1016/J.SCITOTENV.2020.138883>
- Alejandro Sánchez, M. A. (2022, June 30). *El Ibex pierde los 8.100 puntos y salda el semestre con una caída del 7%*. Expansión. <https://amp.expansion.com/mercados/cronica-bolsa/2022/06/30/62bd3a7b468aebc1038b462b.html>
- Alonso, J. H. (2006). *Análisis de series temporales económicas I*. ESIC Editorial.
- Aparicio, L. (2020, July 27). *Así es la empresa española que valía 83 millones hace cuatro años y ahora se tasa en 1.600 millones*. EL PAÍS. <https://elpais.com/economia/2020-07-26/asi-es-la-empresa-espanola-que-valia-83-millones-hace-cuatro-anos-y-ahora-se-tasa-en-1600-millones.html>
- Bermejo Iglesias, A., Torres Pruñonosa, J., & Masferrer Llavínés, N. (2009). La utilización de los modelos ARIMA en la estimación del precio de acciones: una aplicación preliminar. In ESIC (Ed.), *En Administrando en entornos inciertos. XXIII Congreso Anual AEDEM* (pp. 1–13).
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Canales Salinas, R. J. (2017). Estado actual de los Índices Bursátil en el mundo. *Revista Electrónica de Investigación En Ciencias Económicas*, 5(9), 65–84. <https://revistasnicaragua.cnu.edu.ni/index.php/reice/article/view/3175>
- Casas, M., & Cepeda, E. (2008). Modelos ARCH, GARCH y EGARCH: aplicaciones a series financieras. *Cuadernos de Economía*, 27(48), 287–319. http://www.scielo.org.co/scielo.php?pid=S0121-47722008000100011&script=sci_abstract&tlng=pt
- Chang, Y., Yeung, C., & Yip, C. (2000). Analysis of the influence of economic indicators on stock prices using multiple regression. *Exchange Organizational Behavior Teaching Journal*, 24(1), 321–327.
- Chen, A. S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 30(6), 901–923. [https://doi.org/https://doi.org/10.1016/S0305-0548\(02\)00037-0](https://doi.org/https://doi.org/10.1016/S0305-0548(02)00037-0)
- Cobas Asset Management. (2022). *El Value ante el peor arranque bursátil en 50 años - Cobas AM -*. Cobas AM Cobas Asset Management. <https://www.youtube.com/watch?v=DaPstX6lkyw>
- Consoli, S., Reforgiato Recupero, D., & Saisana, M. (2021). Data Science for Economics and Finance.

- In *Data Science for Economics and Finance*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-66891-4>
- Costa, S. A., Reis, P. M. N., & Pinto, A. P. S. (2020). Subjective/ Behavioural Factors Influence the PSI 20 and IBEX 35. *International Journal of Financial Research*, 11(5), 13–27. <https://doi.org/10.5430/IJFR.V11N5P13>
- De Arce, R. (2004). 20 años de modelos ARCH: una visión de conjunto de las distintas variantes de la familia. *Estudios de Economía Aplicada*, 22(1), 1–27. <https://www.redalyc.org/pdf/301/30122111.pdf>
- De Lara, A. H. (2005). *Medición y control de riesgos financieros*. Limusa.
- Díaz, J. (2008). *Aplicación del modelo ARCH Y GARCH para el cálculo de la volatilidad en riesgo de mercado* [Universidad Autónoma de Bucaramanga]. <https://repository.unab.edu.co/handle/20.500.12749/13930>
- Dutillo, P., Antonio Gattone, S., Di Battista, T., Alberto Ferreira, M. M., & Carfi, D. (2021). Volatility Modeling: An Overview of Equity Markets in the Euro Area during COVID-19 Pandemic. *Mathematics*, 9(11), 1–18. <https://doi.org/10.3390/MATH9111212>
- Ecer, F., Ardabili, S., Band, S. S., & Mosavi, A. (2020). Training Multilayer Perceptron with Genetic Algorithms and Particle Swarm Optimization for Modeling Stock Price Index Prediction. *Entropy*, 22(11), 1239. <https://doi.org/10.3390/E22111239>
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 1007. <https://doi.org/10.2307/1912773>
- Falcón Canillas, S. (2021). *Previsão do índice bursátil IBEX 35 usando redes neurais artificiais* [Universidade Estadual Paulista (Unesp)]. <https://doi.org/10.17616/R31N39>
- Franses, P. H., & McAleer, M. (2002). Financial volatility: an introduction. *Journal of Applied Econometrics*, 17(5), 419–424. <https://doi.org/10.1002/jae.693>
- Fuertes, A. (2016). *Los índices bursátiles de sostenibilidad: registrando el valor del nuevo paradigma (parte I)*. <https://repositorio.pucp.edu.pe/index/handle/123456789/54908>
- García, M. C., Jalal, A. M., Garzón, L. A., & López, J. M. (2013). Métodos para predecir índices bursátiles. *Ecos de Economía*, 37, 51–82. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1657-42062013000200003
- Gujarati, D. N., & Porter, D. C. (2010). *Econometría. 5ª edición*.
- Healy, P. M., & Palepu, K. G. (2001). Information asymmetry, corporate disclosure, and the capital markets: A review of the empirical disclosure literature. *Journal of Accounting and Economics*, 31(1–3), 405–440. [https://doi.org/10.1016/S0165-4101\(01\)00018-0](https://doi.org/10.1016/S0165-4101(01)00018-0)
- Hontoria de Francisco, P. (2014). *Modelización de empresas financieras mediante series temporales* [Universidad de Valladolid]. <https://uvadoc.uva.es/handle/10324/6308>

- Ihaka, R., & Gentleman, R. (1996). R: A Language for Data Analysis and Graphics. *Journal of Computational and Graphical Statistics*, 5(3), 299–314. <https://doi.org/10.1080/10618600.1996.10474713>
- Internationale Nederlanden Groep. (2022, April 12). *Estos son los principales índices bursátiles mundiales que debes conocer*. Grupo ING. <https://www.ing.es/ennaranja/invertir-dinero/bolsa-y-mercados/principales-indices-bursatiles/>
- Kara, Y., Acar Boyacioglu, M., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311–5319. <https://doi.org/10.1016/J.ESWA.2010.10.027>
- Lo, A. W., & MacKinlay, A. C. (1988). Stock Market Prices Do Not Follow Random Walks: Evidence from a Simple Specification Test. *The Review of Financial Studies*, 1(1), 41–66. <https://doi.org/https://doi.org/10.1093/rfs/1.1.41>
- López Gracia, J. L. (1992). Evidencia empírica de la capacidad predictiva de los informes financieros intermedios. *Revista Económica de Financiación y Contabilidad*, 70, 57–76. <https://www.jstor.org/stable/42780946>
- Maté, C., & Oliva, A. (2003). La predicción en los mercados de derivados financieros. Una introducción al MEFY y los modelos ARCH (II/II). *Anales de Mecánica y Electricidad*, 56–64. https://www.researchgate.net/profile/Carlos-Mate/publication/28125139_La_prediccion_en_los_mercados_de_derivados_financieros_Una_introduccion_al_MEFY_y_los_modelos_ARCH_III/links/02e7e521c7245cb08b000000/La-prediccion-en-los-mercados-de-derivados-financi
- Melo, E. G., & Hoyos, C. F. (2021). Estimadores de volatilidad basados en información de alta frecuencia del índice de capitalización accionaria. *Semestre Económico*, 24(56), 143–166. <https://doi.org/10.22395/seec.v24n56a6>
- Murphy, J. J. (2000). *Análisis técnico de los mercados financieros* (2016th ed.). Gestión.
- Nugroho, D. B., Mahatma, T., & Pratomo, Y. (2021). GARCH Models under Power Transformed Returns: Empirical Evidence from International Stock Indices. *Austrian Journal of Statistics*, 50(4), 1–18. <https://doi.org/10.17713/AJS.V50I4.1075>
- Parody-Camargo, E., Charris Fontanilla, A., & García Luna, R. (2012). Modelación de la volatilidad y pronóstico del índice general de la bolsa de valores de Colombia (IGBC). *Clío América*, 6(12), 223–239.
- Peña, D. (2010). *Análisis de series temporales* (A. Editorial (ed.)). <https://dialnet.unirioja.es/servlet/libro?codigo=584206>
- Poon, S. H., & Taylor, S. J. (1992). Stock returns and volatility: an empirical study of the UK stock market. *Journal of Banking & Finance*, 16(1), 37–59. <https://www.sciencedirect.com/science/article/pii/037842669290077D>

- Priyono, A., Nugroho, D. B., & Susanto, B. (2020). Pemodelan volatilitas return indeks saham menggunakan model GARCH(1,1) berdistribusi skew-normal. *PRISMA, Prosiding Seminar Nasional Matematika*, 3, 46–51. <https://journal.unnes.ac.id/sju/index.php/prisma/article/view/37769>
- Ramírez, F. O. . P., & Castaño, H. F. (2006). Análisis de la volatilidad del índice general de la bolsa de valores de Colombia utilizando modelos ARCH. *Revista Ingenierías Universidad de Medellín*, 5(8), 13–33. <https://www.redalyc.org/pdf/750/75050803.pdf>
- Reddy, B. S. (2010). Prediction of stock market indices—using SAS. In *2nd IEEE International Conference on Information and Financial Engineering*, 112–116.
- Sosa Castro, M., Pacheco, C., & Cabello Rosales, M. (2018). Dependencia condicional en el bloque TLCAN: un análisis con modelos GARCH y Cópula. *Ecos de Economía*, 22(47), 73–91. <https://doi.org/https://doi.org/10.17230/ecos.2018.47.4>
- Tercero, N. (2021). *La Estacionariedad y la Resiliencia del Turismo: Cómo actúan las economías en función de su perfil y del suceso crítico*. [Tesis de Maestría] Universidad Internacional de Andalucía.
- Valencia Plaza. (2022a, April 27). *El Banco de España alerta de una retirada de estímulos monetarios “más rápida que la esperada”*. Valenciaplaza. <https://valenciaplaza.com/banco-espana-alerta-retirada-estimulos-monetarios-rapida-esperada>
- Valencia Plaza. (2022b, July 5). *El Ibex 35 invierte la tendencia alcista de la apertura y va camino de ceder los 8.100 puntos*. Valenciaplaza. <https://valenciaplaza.com/ibex-invierte-tendencia-alcista-apertura-camino-perder-8100-puntos>
- Villanueva, A. V. (2007). Mercados financieros: una aproximación a la Bolsa de Valores de Lima. *Contabilidad y Negocios*, 2(3), 23–33. <https://www.redalyc.org/pdf/2816/281621764004.pdf>
- Ware, W. B., Ferron, J. M., & Miller, B. M. (2013). Introductory statistics: A conceptual approach using R. In *Introductory Statistics: A Conceptual Approach Using R*. Routledge. <https://doi.org/10.4324/9780203837375/INTRODUCTORY-STATISTICS-CONCEPTUAL-APPROACH-USING-WILLIAM-WARE-JOHN-FERRON-BARBARA-MILLER>
- Westreicher, G. (2020, April 27). *Inversionista*. Economipedia.Com. <https://economipedia.com/definiciones/inversionista.html>
- Zhang, D., Hu, M., & Ji, Q. (2020). Financial markets under the global pandemic of COVID-19. *Finance Research Letters*, 36, 101528. <https://doi.org/https://doi.org/10.1016/j.frl.2020.101528>

A. Anexos

A.1 R Código

```

1 # Librerías a usar
2 library(tidyverse)
3 library(lubridate)
4 library(tseries)
5 library(xts)
6 library(zoo)
7 library(reshape)
8
9 #Estracción de datos
10 library(quantmod)
11 getSymbols("^IBEX", scr='yahoo', from='2006-01-02',
12   to='2022-08-25', periodicity='daily',
13   format='xts')
14
15 getSymbols("SLR.MC", scr='yahoo', from='2007-06-19',
16   to='2022-08-26', periodicity='daily',
17   format='xts')
18 #Visualización de los datos
19 chart_Series(IBEX)
20 chart_Series(SLR.MC)
21 #Pruebas de estacionariedad
22 library(tseries)
23
24 SLR.MC <- na.omit(SLR.MC)
25
26 ADF_SLR<-adf.test(SLR.MC$SLR.MC.Adjusted)
27 PP_SLR<-pp.test(SLR.MC$SLR.MC.Adjusted)
28 KPSS_SLR<-kpss.test(SLR.MC$SLR.MC.Adjusted)
29
30 IBEX<-na.omit(IBEX)
31
32 ADF_IBEX<-adf.test(IBEX$IBEX.Adjusted)
33 PP_IBEX<-pp.test(IBEX$IBEX.Adjusted)
34 KPSS_IBEX<-kpss.test(IBEX$IBEX.Adjusted)
35
36 Pruebas <-c('Dickey-Fuller Aumentada',
37   'Phillips-Perron', 'KPSS')
38
39 Pruebas_SLR<-c(ADF_SLR$p.value,
40   PP_SLR$p.value,
41   KPSS_SLR$p.value)
42
43 Pruebas_IBEX<-c(ADF_IBEX$p.value,
44   PP_IBEX$p.value,
45   KPSS_IBEX$p.value)
46
47 Estacionariedad<-data.frame(Pruebas,
48   SLR=Pruebas_SLR,
49   IBEX=Pruebas_IBEX)
50 ### Diferencias logarítmicas de los activos: Tasa de retorno/rendimiento
51 SLR_rt<-diff(log(SLR.MC$SLR.MC.Adjusted))
52 SLR_rt<-na.omit(SLR_rt)
53 IBEX_rt<-diff(log(IBEX$IBEX.Adjusted))

```

```

54 IBEX_rt<-na.omit(IBEX_rt)
55 ### Visualización de las tasas de retorno
56 plot(SLR_rt)
57 plot(IBEX_rt)
58 ## Pruebas de estacionariedad de los retornos financieros
59 ADF_SLR<-adf.test(SLR_rt)
60 PP_SLR<-pp.test(SLR_rt)
61 KPSS_SLR<-kpss.test(SLR_rt, null = "Level")
62
63 ADF_IBEX<-adf.test(IBEX_rt)
64 PP_IBEX<-pp.test(IBEX_rt)
65 KPSS_IBEX<-kpss.test(IBEX_rt, null = 'Level')
66
67 Pruebas <-c('Dickey-Fuller Aumentada',
68   'Phillips-Perron','KPSS')
69
70 Pruebas_SLR<-c(ADF_SLR$p.value,
71   PP_SLR$p.value,
72   KPSS_SLR$p.value)
73
74 Pruebas_IBEX<-c(ADF_IBEX$p.value,
75   PP_IBEX$p.value,
76   KPSS_IBEX$p.value)
77
78 Estacionariedad<-data.frame(Pruebas,
79   SLR=Pruebas_SLR,
80   IBEX=Pruebas_IBEX
81   )
82 ### Cálculo de la volatilidad
83 Volatilidad_SLR<- log(SLR.MC$SLR.MC.High/SLR.MC$SLR.MC.Low)
84 Volatilidad_IBEX <- log(IBEX$IBEX.High/IBEX$IBEX.Low)
85
86 ### Visualización de la volatilidad
87 plot(Volatilidad_SLR)
88 plot(Volatilidad_IBEX)
89 ## Pruebas de estacionariedad de la volatilidad
90 ADF_SLR<-adf.test(Volatilidad_SLR)
91 PP_SLR<-pp.test(Volatilidad_SLR)
92 KPSS_SLR<-kpss.test(Volatilidad_SLR)
93
94 ADF_IBEX<-adf.test(Volatilidad_IBEX)
95 PP_IBEX<-pp.test(Volatilidad_IBEX)
96 KPSS_IBEX<-kpss.test(Volatilidad_IBEX)
97
98 Pruebas <-c('Dickey-Fuller Aumentada',
99   'Phillips-Perron','KPSS')
100
101 Pruebas_SLR<-c(ADF_SLR$p.value,
102   PP_SLR$p.value,
103   KPSS_SLR$p.value)
104
105 Pruebas_IBEX<-c(ADF_IBEX$p.value,
106   PP_IBEX$p.value,
107   KPSS_IBEX$p.value)
108
109 Estacionariedad<-data.frame(Pruebas,
110   SLR=Pruebas_SLR,
111   IBEX=Pruebas_IBEX)

```

```

112 # Estimación de los modelos para Solaria S.A.
113 library(forecast)
114 library(rugarch)
115 AR2<-arima(SLR_rt, order=c(2,1,0))
116 SLR_d <- na.omit(diff(SLR_rt))
117 arch1_AR2<-ugarchspec(variance.model = list(model='sGARCH',
118     garchOrder=c(1,0)),
119     mean.model = list(armaOrder=c(2,0)))
120 arch1_ar2<-ugarchfit(spec=arch1_AR2, data=SLR_d)
121 garch11_AR2<-ugarchspec(variance.model = list(model='sGARCH',
122     garchOrder=c(1,1)),
123     mean.model = list(armaOrder=c(2,0)))
124 garch11_ar2<-ugarchfit(spec=garch11_AR2, data=SLR_d)
125
126 Modelos <- c("AR(2)", "AR(2)-ARCH(1)", "AR(2)-GARCH(1,1)")
127 AIC <-c(AR2$aic, infocriteria(arch1_ar2)[1],
128     infocriteria(garch11_ar2)[1])
129
130 ## Modelos para la serie IBEX35
131 library(forecast)
132 library(rugarch)
133 arch1<-ugarchspec(variance.model = list(model='sGARCH',
134     garchOrder=c(1,0)),
135     mean.model = list(armaOrder=c(0,0)))
136 arch1<-ugarchfit(spec=arch1, data=IBEX_rt)
137 garch11<-ugarchspec(variance.model = list(model='sGARCH',
138     garchOrder=c(1,1)),
139     mean.model = list(armaOrder=c(0,0)))
140 garch11<-ugarchfit(spec=garch11, data=IBEX_rt)
141
142 Modelos <- c("ARCH(1)", "GARCH(1,1)")
143 AIC <-c(infocriteria(arch1)[1],
144     infocriteria(garch11)[1])
145 ## Análisis de estabilidad o validación de los modelos seleccionados
146 ##Serie Solaria S.A.
147 library(lmtest)
148 library(knitr)
149 Prueba_coef_SOLARIAS<-arch1_ar2@fit$matcoef
150
151 kable(Prueba_coef_SOLARIAS,
152     digits = 3, caption = 'AR(2)-ARCH(1): Serie SOLARIA')
153 print(arch1_ar2)
154 ## Serie Ibex35
155 Prueba_coef_IBEX<-garch11@fit$matcoef
156 kable(Prueba_coef_IBEX,
157     digits = 3, caption = 'GARCH (1,1): Serie IBEX')
158 print(garch11)
159
160 #Pronóstico para Solaria S.A.
161 library(tidyverse)
162
163 fcast_SLR_d <- ugarchforecast(garch11_ar2,
164     n.ahead =5)
165
166 Puntual <-as.vector(fcast_SLR_d@forecast$seriesFor)
167 Puntual <- diffinv(Puntual, xi=0.0575697671)
168 Sigma <- as.vector(fcast_SLR_d@forecast$sigmaFor)
169

```



```

170 Pronosticos_SLR_rt <- data.frame(
171   Retorno=Puntual[-1],
172   Volatilidad=Sigma)
173
174 Pronosticos_SLR_rt<-Pronosticos_SLR_rt %>%
175   mutate(Fecha=c("2022-08-26",
176     "2022-08-29",
177     "2022-08-30",
178     "2022-08-31",
179     "2022-09-01"),
180     Fecha=as.Date(Fecha, format="%Y-%m-%d"))
181 kable(Pronosticos_SLR_rt,
182   caption = 'Tabla de pronósticos de SOLARIA')
183 ##Pronóstico de los retornos de Solaria S.A.
184 library(tidyverse)
185
186 SLR_df <- data.frame(Fecha=index(SLR_rt$SLR.MC.Adjusted),
187   Rt=coredata(SLR_rt$SLR.MC.Adjusted),
188   Vol=coredata(Volatilidad_SLR$SLR.MC.High[-1,]))
189 data <- merge(SLR_df, Pronosticos_SLR_rt, all=TRUE, fill=NA)
190 last_data_value = data[data$Fecha == as.Date("2022-08-25"),
191   "SLR.MC.Adjusted"]
192 extra_row = data.frame(Fecha=as.Date("2022-08-25"),
193   SLR.MC.Adjusted=NA_real_,
194   SLR.MC.High=NA_real_,
195   Retorno=last_data_value,
196   Volatilidad=last_data_value)
197 frame = rbind(data, extra_row)
198 frame %>%
199   filter(Fecha>"2022-06-01") %>%
200   ggplot()+
201   geom_line(aes(x=Fecha, y=SLR.MC.Adjusted*100, col='Retornos SOLARIA'))+
202   geom_line(aes(x=Fecha, y=Retorno*100, col='Pronostico'))+
203   scale_x_date(date_labels = '%Y-%m')+
204   scale_y_continuous(breaks = seq(-10,10,1))+
205   labs(title = 'Pronosticos de los retornos del activo SOLARIA',
206     subtitle = 'En términos porcentuales a 5 días',
207     x='Fecha',
208     y='Retorno %',
209     colour='Series')
210 ##Pronóstico de volatilidad de Solaria S.A.
211 frame %>%
212   filter(Fecha>"2022-06-01") %>%
213   ggplot()+
214   geom_line(aes(x=Fecha, y=SLR.MC.High*100, col='Volatilidad'))+
215   geom_line(aes(x=Fecha, y=Volatilidad*100, col='Pronostico'))+
216   scale_x_date(date_labels = '%Y-%m')+
217   scale_y_continuous(breaks = seq(-10,10,1))+
218   labs(title = 'Pronosticos de la volatilidad del activo SOLARIA',
219     subtitle = 'En términos porcentuales a 5 días',
220     x='Fecha',
221     y='Volatilidad %',
222     colour='Series')
223 #Valores de los retornos del Ibex35
224 fcast_IBEX <- ugarchforecast(garch11,
225   n.ahead =5)
226 Puntual <-fcast_IBEX@forecast$seriesFor
227 Sigma <- fcast_IBEX@forecast$sigmaFor

```

```

228 Pronosticos_IBEX <- data.frame(Retorno=Puntual,
229   Volatilidad=Sigma)
230 Pronosticos_IBEX<-Pronosticos_IBEX %>%
231   mutate(Fecha=c("2022-08-26",
232     "2022-08-29",
233     "2022-08-30",
234     "2022-08-31",
235     "2022-09-01"),
236   Fecha=as.Date(Fecha, format="%Y-%m-%d"))
237 names(Pronosticos_IBEX)<-c("Retorno", "Volatilidad", "Fecha")
238 kable(Pronosticos_IBEX,
239   caption = 'Pronósticos de los retornos de IBEX')
240
241 ##Pronostico de los retornos del Ibex35
242 IBEX_df <- data.frame(Fecha=index(IBEX_rt$IBEX.Adjusted),
243   Rt=coredata(IBEX_rt$IBEX.Adjusted),
244   Vol=coredata(Volatilidad_IBEX$IBEX.High[-1,]))
245 data <- merge(IBEX_df, Pronosticos_IBEX, all=TRUE, fill=NA)
246 # Tome el valor de y correspondiente a la fecha justo antes de la brecha.
247 last_data_value = data[data$Fecha == as.Date("2022-08-25"),
248   "IBEX.Adjusted"]
249 extra_row = data.frame(Fecha=as.Date("2022-08-25"),
250   IBEX.Adjusted=NA_real_,
251   IBEX.High=NA_real_,
252   Retorno=last_data_value,
253   Volatilidad=last_data_value)
254 # Agregue una fila adicional al data.frame principal.
255 frame = rbind(data, extra_row)
256 frame %>%
257   filter(Fecha>"2022-06-01") %>%
258   ggplot()+
259   geom_line(aes(x=Fecha, y=IBEX.Adjusted*100, col='Retornos IBEX'))+
260   geom_line(aes(x=Fecha, y=Retorno*100, col='Pronostico'))+
261   scale_x_date(date_labels = '%Y-%m')+
262   scale_y_continuous(breaks = seq(-10,10,1))+
263   labs(title = 'Pronosticos de los retornos IBEX',
264     subtitle = 'En términos porcentuales a 5 días',
265     x='Fecha',
266     y='Retorno %',
267     colour='Series')
268 #Pronóstico de la volatilidad del Ibex35
269 frame %>%
270   filter(Fecha>"2022-06-01") %>%
271   ggplot()+
272   geom_line(aes(x=Fecha, y=IBEX.Adjusted*100, col='Volatilidad IBEX'))+
273   geom_line(aes(x=Fecha, y=Volatilidad*100, col='Pronostico'))+
274   scale_x_date(date_labels = '%Y-%m')+
275   labs(title = 'Pronosticos de la volatilidad de IBEX',
276     subtitle = 'En términos porcentuales a 5 días',
277     x='Fecha',
278     y='Volatilidad %',
279     colour='Series')

```