

Trabajo Fin de Grado

Estudio de modelos de predicción de
volatilidad aplicado a algunas empresas del
IBEX35

Autor/es

Mario García Martínez

Director/es

Laura Andreu Sánchez

Facultad de Economía y Empresa
2023/2024

Autor: Mario García Martínez

Director: Laura Andreu Sánchez.

Título: Estudio de modelos de predicción de volatilidad aplicado a algunas empresas del IBEX35.

Titulación: Grado en Finanzas y Contabilidad (FICO)

Resumen

La volatilidad es un fenómeno altamente impredecible, aunque resulta imprescindible poder cuantificarlo en ámbitos financieros. Para ello, la econometría ha desarrollado una serie de modelos que permiten no sólo cuantificarla, sino también realizar predicciones aproximadas de la misma, facilitando la toma de decisiones de los inversores. Este trabajo se centra en la programación y validación de dos modelos de predicción de volatilidad, basados en modelos econométricos; GARCH y predicción basada en volatilidad muestral. El análisis se realiza sobre tres empresas del IBEX35; Iberdrola, Inditex y Banco Santander, entre el 2007 y 2024. Los resultados del estudio muestran que el modelo GARCH realiza una mejor predicción de los rendimientos reales que el modelo de volatilidad muestral, lo cual se deduce gracias a la aplicación de *backtest* creados para medir el número de errores de cada modelo.

Palabras Clave: GARCH, IBEX 35, Modelo econométrico, VaR, Volatilidad.

Abstract

Volatility is a highly unpredictable phenomenon, although it is essential to be able to quantify it in financial spheres. To this end, econometrics has developed a series of models that allow not only to quantify volatility, but also to make approximate predictions of it, facilitating investors' decision-making. This paper focuses on the programming and validation of two volatility prediction models based on econometric models: GARCH and sample-based volatility prediction. The analysis is carried out on three IBEX35 companies; Iberdrola, Inditex and Banco Santander, between 2007 and 2024. The results of the study show that the GARCH model performs a better prediction of real returns than the sample volatility model, which is deduced thanks to the application of backtests created to measure the number of errors of each model.

Keywords: GARCH, IBEX35, Econometric Model, VaR, Volatility.

Índice

Motivación	5
1.- Contextualización del mercado bursátil y análisis econométrico.	6
2.- Análisis del Nivel de Volatilidad de las Compañías bursátiles.....	16
3.- Datos.	17
4.- Metodología.	20
5.- Resultados.	29
6.- Conclusiones.	50
Bibliografía.....	52

Índice de Figuras

Figura 1. Derechos de los accionistas en una empresa.....	6
Figura 2. Estructura del ahorro financiero de las familias.....	7
Figura 3. Evolución histórica de la cotización del IBEX 35.	8
Figura 4. Top 10 Componentes IBEX35 a 21 de junio de 2024.	10
Figura 5. Evolución histórica del Ibex35 y variación interanual del PIB.....	10
Figura 6. Evolución del precio del IBEX 35 entre 2017 y 2021.	12
Figura 7. Evolución del precio del IBEX 35 en 2023.	13
Figura 8. Comparación de rentabilidad y volatilidad del IBEX35.	18
Figura 9. Instalación y carga de paquetes de funciones.	19
Figura 10. Obtención de datos de las compañías.	20
Figura 11. Importación y limpieza de datos.	20
Figura 12. Graficación de datos normalizados.	21
Figura 13. Cálculo de los rendimientos logarítmicos.	22
Figura 14. Cálculo de los rendimientos del Banco Santander.....	23
Figura 15. Graficación simultánea de rendimientos y precios de SAN.MC	23
Figura 16. Autocorrelación de precios, rendimientos y rendimientos (Valor absoluto)	24
Figura 17. Distribución de rendimientos de SAN.MC	25
Figura 18. Vector generado ‘Sample_VolatilitySAN’	26

Figura 19. Predicción de volatilidad con volatilidad histórica.	26
Figura 20. Predicción VaR y graficación sobre los rendimientos reales.	27
Figura 21. Recuento de errores de predicción.	28
Figura 22. Predicción de la volatilidad y el VaR con modelo GARCH.	29
Figura 23. Backtesting de predicción con volatilidad muestral.	47
Figura 24. Backtesting de predicción con modelo GARCH.	47
Figura 25. Backtesting de predicción con modelo GARCH (Iberdrola).	54
Figura 26. Backtesting de predicción con volatilidad muestral (Iberdrola).	54
Figura 27. Backtesting de predicción con volatilidad muestral (Inditex).	54
Figura 28. Backtesting de predicción con modelo GARCH (Inditex).	54

Índice de Gráficos

Gráfico 1. Precios de Banco Santander en el periodo 01-01-2007 a 27-08-2024.	31
Gráfico 2. Comparación normalizada de IBE.MC, ITX.MC y SAN.MC.	33
Gráfico 3. Superposición de variación de los rendimientos de las tres compañías.	35
Gráfico 4. Rendimientos de Banco Santander en el periodo de 01-01-07 a 27-08-24 ..	37
Gráfico 5. Precios y rendimientos del Banco Santander.	39
Gráfico 6. Autocorrelación de precios de cierre de Banco Santander.	41
Gráfico 7. Autocorrelación de los rendimientos de Banco Santander.	42
Gráfico 8. Autocorrelación de los rendimientos de SAN.MC en valor absoluto.	43
Gráfico 9. Curvas de distribución de rendimientos superpuestas.	45
Gráfico 10. Serie temporal de rendimientos de y la volatilidad muestral anualizada. ..	46
Gráfico 11. Comparación de rendimientos reales con la predicción del VaR.	48
Gráfico 12. Rendimientos reales con la predicción VaR a través del GARCH model. ..	49

Motivación

El presente Trabajo de Fin de Grado se centra en el desarrollo de dos modelos de predicción de volatilidad, comparando su precisión a través de un *backtest* sobre el Valor en Riesgo (VaR) calculado con cada una de las predicciones. Las razones que me llevan a abordar este tema son varias. Por un lado, en el ámbito de las finanzas, la medición y predicción de la volatilidad es crucial para la gestión de riesgos, la valoración de activos, y la toma de decisiones de inversión. La volatilidad no solo refleja la incertidumbre en los mercados, sino que también permite a los analistas anticipar posibles fluctuaciones en los precios de los activos. En este sentido, la creación de un modelo de análisis a medida del inversor ha sido lo que me ha impulsado a desarrollar este trabajo.

Este trabajo se centra en la comparación de estos dos enfoques para modelar la volatilidad de las acciones de tres compañías del IBEX35: Iberdrola (IBE.MC), Inditex (ITX.MC) y Banco Santander (SAN.MC). La contextualización del trabajo se realiza sobre las tres compañías, pero debido a las limitaciones de extensión del mismo, el análisis de resultados se realiza únicamente sobre Banco Santander. El objetivo principal del estudio es evaluar la precisión de ambos modelos en la predicción de la volatilidad futura y determinar cuál de ellos ofrece mejores resultados en términos de ajuste a la realidad observada. Para ello, se emplea el backtesting como método de validación, lo que permite verificar la capacidad predictiva de los modelos comparando sus estimaciones con los rendimientos reales.

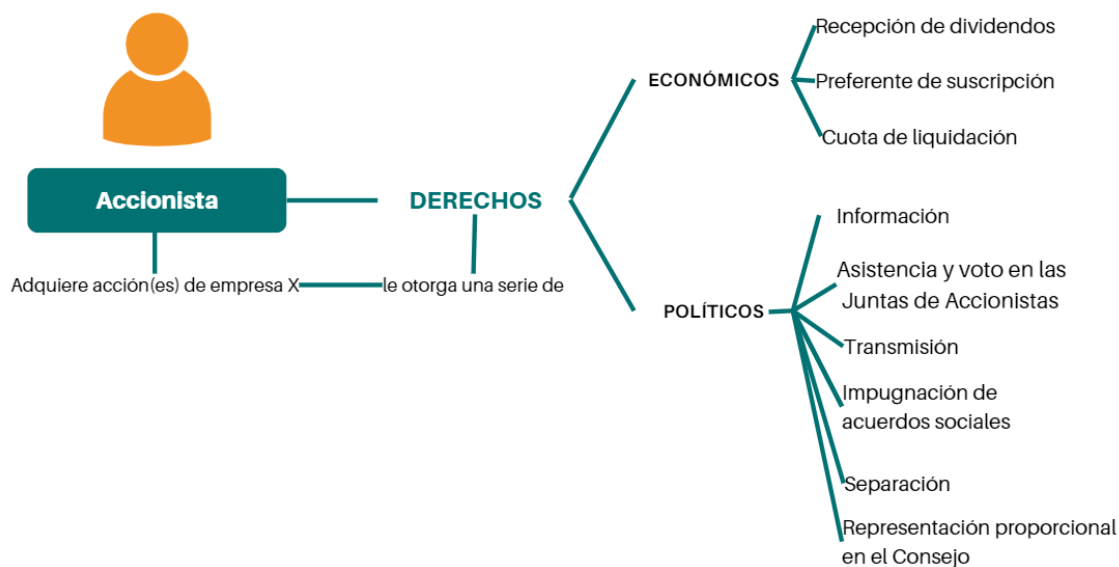
En primer lugar, se introduce el producto financiero que se va a analizar, seguido de la contextualización del índice de referencia del mercado en el que cotizan las empresas, el IBEX 35, analizando su comportamiento en el horizonte temporal seleccionado y sus características principales. Posteriormente se describe la importancia del análisis de volatilidad, los tipos que existen y los modelos de predicción que se van a utilizar. A continuación, se definen los comandos de programación utilizados para la obtención de los datos y su modelación, así mismo como la programación de los modelos de predicción. Finalmente se realiza una validación de ambos métodos y se comparan los resultados.

1.- Contextualización del mercado bursátil y análisis econométrico.

El producto financiero que se va a analizar en este Trabajo de Fin de Grado son las acciones, negociadas en las Bolsas. Una acción, tal y como la define BBVA (s.f.) es “la menor fracción de una empresa que puede comprar un inversor.” Por otro lado, las Bolsas, según las define la BME (s.f.), son mercados donde se negocian productos y se ponen en contacto compradores (ahorradores) y vendedores (empresas).

La Comisión Nacional del Mercado de Valores (CNMV) clasifica las acciones y sus derechos en las siguientes tipologías: ordinarias, privilegiadas, sin voto y rescatables. La persona o entidad que posee acciones de una empresa se denomina accionista, en otras palabras, pasa a ser propietario parcial de la sociedad, y cuenta con una serie de derechos económicos y políticos sobre la compañía. En la Figura 1, se puede ver un resumen de estos derechos.

Figura 1. Derechos de los accionistas en una empresa.



Fuente: Elaboración propia a partir de CNMV (s.f.)

Según la CNMV, el perfil del inversor se define como la relación que existe entre los riesgos que el inversor está dispuesto a asumir y los rendimientos que espera obtener. Y así los clasifica en perfil conservador, medio y agresivo.

Un inversor conservador trata de preservar su capital y conseguir una rentabilidad superior a la inflación, el mínimo esperado en una inversión. Este perfil admite un riesgo muy bajo, por lo que suelen dedicar un 15% de su cartera a activos de renta variable, a

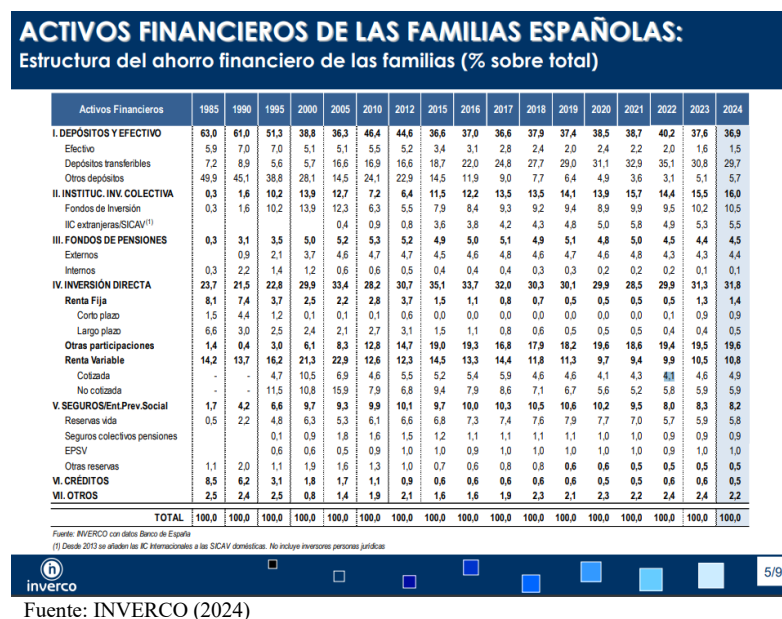
empresas de gran capitalización que sean estables. Como referencia de rendimiento anual marcan los Bonos del Estado a 10 años que se consideran activos libres de riesgo.

Un inversor moderado tiene como objetivo un equilibrio entre la estabilidad y el crecimiento de su patrimonio, admitiendo más tolerancia al riesgo respecto del perfil conservador. Dedicar entorno a un 35% de su cartera a activos de renta variable.

El perfil de inversor agresivo busca la máxima rentabilidad de su patrimonio por lo que su exposición al riesgo será la más alta de todos los perfiles. Al permitir niveles de volatilidad mayores, dedica la mayor parte del capital a activos de renta variable o activos de riesgo similar. En este caso es muy importante la diversificación de activos ya que soporta niveles mayores de volatilidad.

Según Micappital, asociado de la Asociación Europea de Asesoría y Planificación Financiera en España (EFPA), el inversor español tiene un perfil conservador y no suele arriesgar. Por ello, “un 40% de los ahorradores no se deciden siquiera a dar el paso a convertirse en inversores, limitándose a almacenar su capital en cuentas corrientes y depósitos que apenas les generan rentabilidad.”. El Informe de Ahorro Financiero de familias españolas realizado por la Asociación de Instituciones de Inversión Colectiva y Fondos de Pensiones (INVERCO) estima que las familias españolas dedicaron un 4,1% de su cartera a Renta Variable Cotizada en el primer trimestre de 2024 (Figura 2).

Figura 2. Estructura del ahorro financiero de las familias.



IBEX35: Contextualización

Dado que las empresas que se analizan en este trabajo forman parte del IBEX35, se pasa a contextualizar este índice.

El IBEX35 es “el índice bursátil de referencia de la bolsa española” (Banco Santander, s.f.), y está conformado por 35 empresas españolas seleccionadas por el comité asesor técnico (CAT) según su adecuación a los criterios de capitalización, liquidez y volumen negociado.

El IBEX 35 nació el 14 de enero de 1992 para “servir de referencia al recién creado mercado de opciones y futuros.” (BME, 2022). Hasta ese momento, solamente existía en la Bolsa Española el Índice General de la Bolsa de Madrid (IGBM), que no podría ser subyacente de productos derivados debido a que, de los 75 valores que lo formaban, algunos carecían de liquidez y frecuencia de contratación, por lo que la formación de precios no era eficiente (Castellanos, 2022). Esta carencia generó la necesidad de crear un nuevo índice, formado por un número reducido de empresas, que representara la bolsa española de forma ponderada y sectorialmente. Cabe destacar que la característica diferencial del Ibex35 con respecto a índices anteriores es su replicabilidad. Esto permite al inversor adquirir, de manera simultánea y proporcional, los valores que conforman el índice; un hecho sin precedentes en España hasta ese momento. En la Figura 3 se puede observar su evolución desde su creación con los eventos que más impacto han tenido en el índice.

Figura 3. Evolución histórica de la cotización del IBEX 35.

EVOLUCIÓN HISTÓRICA DE LA COTIZACIÓN DEL IBEX 35



Fuente: BME (2017)

El CAT, formado por un grupo de entre 5 y 9 miembros, es el encargado de la selección de los valores que están dentro del Ibex 35. Este se reúne entre dos y tres veces al año y desempeña dos funciones principales (Banco Santander, s.f.):

1. Analizar y valorar la ponderación de las compañías que forman parte del índice, teniendo en cuenta factores como el precio unitario de cada acción, su capitalización, el PER o la rentabilidad por dividendo, entre otras.
2. Evaluar la entrada de nuevos miembros al índice siguiendo los criterios técnicos establecidos.

Una empresa puede ser incluida en el Ibex35 si cumple los siguientes parámetros de capitalización, liquidez y volumen negociado:

1. La capitalización media del candidato “debe ser superior al 0,30% de la capitalización media del Ibex 35 durante el periodo de control (los seis meses que van de una reunión a otra)” (Banco Santander, s.f.).
2. El valor debe haber sido negociado al menos en un tercio de las sesiones.

Sin embargo, si una empresa no cumple el segundo requisito, podría ser elegida al encontrarse entre las 20 empresas con mayor capitalización del mercado bursátil español.

Cálculo del IBEX35 y determinación del capital flotante

El cálculo del valor del Ibex 35 se realiza mediante una fórmula matemática que “se basa en la capitalización de cada uno de los valores que lo componen, así como en un coeficiente de ajuste, que se aplica a efectos de evitar que posibles operaciones financieras (como ampliaciones de capital, reducciones...) puedan afectar a su cotización” (Banco Santander, s.f.).

Por otro lado, el peso de cada una de las empresas que conforman el índice se calcula según la capitalización de cada una de ellas y se ajusta por su nivel de capital flotante (Gómez Yubero & Palomero Aguilar, 2024). Esto provoca que la variación en los precios de las compañías más ponderadas influya en mayor medida en el precio del índice. Hay que tener en cuenta que la ponderación máxima que una compañía puede tener dentro del índice es de un 20%. En la Figura 4 aparece un resumen de las diez empresas más influyentes del Ibex35 a 21 de junio de 2024 y su ponderación en el mismo.

Figura 4. Top 10 Componentes IBEX35 a 21 de junio de 2024.


NOMBRE VALOR	CÓDIGO	POND %
INDITEX	ITX	15,48
IBERDROLA	IBE	13,83
SANTANDER	SAN	12,13
BBVA	BBVA	9,36
CAIXABANK	CABK	5,15
AMADEUS IT	AMS	5,08
FERROVIAL SE	FER	4,75
TELEFONICA	TEF	4,10
AENA	AENA	3,98
CELLNEX	CLNX	3,86

Fuente: Bolsas y Mercados Españoles, (2024)

Evolución del Ibex 35 desde su creación

Desde la creación del Ibex en 1992, la evolución del valor del índice “ha sido influenciada por una serie de factores económicos, políticos y financieros a nivel nacional e internacional” (Gómez Yubero & Palomero Aguilar, 2024, p.8). Comprender la evolución del valor del índice a lo largo de su historia no es posible sin contextualizar y analizar la situación socioeconómica del país en cada momento. Los autores anteriores diferencian cinco etapas desde 1995 hasta la actualidad. En la Figura 5 quedan reflejadas estas cinco etapas y la evolución del valor del Índice y la variación interanual del PIB entre los años 1995 y 2024.

Figura 5. Evolución histórica del Ibex35 y variación interanual del PIB.



Fuente: Elaboración propia en base a datos de Gómez Yubero y Palomero Aguilar (2024).

Etapas temporales

Etapa 1. Años 90 (1992-2000).

Los primeros años del Ibex35 estuvieron marcados por una gran volatilidad, debido a la inestabilidad económica y política que se vivía en España. La crisis del Sistema Monetario Europeo (SME), que tuvo lugar durante la segunda mitad de 1992 y la primera de 1993 (Vázquez Vicente, 2007), generó una recesión de la economía española, devaluando la peseta en un 5%. Esto generó que, el índice, habiendo surgido en enero de 1992 con un valor base de 3.000 puntos alcanzara, tan sólo 10 meses después, su mínimo histórico de 1.873,58 puntos.

Sin embargo, fue recuperando su valor a lo largo de la década gracias al “desarrollo económico en España y la integración en la Unión Europea”.

Etapa 2. Boom económico y crisis financiera (2000-2010).

A principios de la primera década de los 2000 el Ibex 35 alcanzó máximos históricos superando los 15000 puntos en noviembre de 2007. Este evento es el “preludio” a la crisis financiera global en 2008, que afectó gravemente a todos los mercados, y que hizo que el Ibex35 sufriera también pérdidas importantes, sufriendo su mayor descenso hasta la fecha (cayendo su valor un 9% en tan solo un día) por la quiebra del banco *Lehman Brothers*.

Etapa 3. Años de recuperación (2010-2017).

Tras mínimos históricos originados por la crisis financiera de 2008, el Ibex 35 experimentó un periodo de recuperación lento y gradual, aunque todavía marcado por la inestabilidad generada tanto por “la incertidumbre económica en la zona euro y los problemas financieros en España, como la crisis de la deuda soberana”.

Etapa 4. Turbulencias políticas y económicas (2017-2021).

Después de un periodo marcado por la recuperación paulatina del Ibex y del PIB, la incertidumbre económica, provocada por problemas políticos y socioeconómicos, como fue la pandemia de la COVID-19, que provocó una caída histórica del PIB (ver en figura X) en 2020, no permitió al Ibex 35 recuperar el valor pre -crisis 2008. El 12 de marzo de 2020, día en el que se declaró el estado de alarma en España, “el Ibex 35 se

desplomó un 14,06%, alcanzando los 6.390 puntos” (Gómez Yubero & Palomero Aguilar, 2024).

En la Figura 6, puede apreciarse un gráfico de velas de periodicidad semanal, que muestra el comportamiento del índice entre 2017 y 2021. Inicialmente dibuja un periodo de estabilidad relativa, con fluctuaciones moderadas debido a la recuperación económica tras la crisis. Este comportamiento se ve interrumpido por la caída abrupta provocada por la pandemia de COVID-19. Finalmente observamos un intento de recuperación hasta el final del periodo.

Figura 6. Evolución del precio del IBEX 35 entre 2017 y 2021.



Fuente: Elaboración propia en base a datos de *TradingView*..

Etapa 5. Recuperación post COVID (2021-2023).

La crisis económica provocada por la pandemia resultó en una caída del PIB sin precedentes en nuestra historia económica dentro de la UE (Torres y Fernández, 2022). Sin embargo, gracias a “la implementación de programas de estímulo económico” (Gómez Yubero & Palomero Aguilar, 2024, p. 9), como los 750 millones de euros inyectados en la economía europea durante 2021 – 2027 con los fondos *Next Generation EU*, sumados a los 390.000 millones de euros que Von der Leyen anunció que donaría a modo de “inversiones comunes en nuestro futuro” (Dirección General de Comunicación del Parlamento Europeo, 2020), una política monetaria expansiva y la recuperación paulatina de la actividad económica, el Ibex 35 comenzó a recuperarse a partir de 2021. A pesar de ello, el escenario económico en términos de inflación, políticas monetarias y

riesgo geopolítico en diversas zonas geográficas, mantienen la incertidumbre económica en la actualidad.

En la Figura 7 se observa como a finales de 2023 se produce un ascenso del valor del índice alcanzando los 10.102 puntos, un repunte acumulado en 2023 del 23,6%, comparable únicamente al repunte del 30% producido en 2009.

Figura 7. Evolución del precio del IBEX 35 en 2023.



Fuente: Elaboración propia en base a datos de *TradingView*.

Volatilidad y modelos econométricos

La volatilidad según la web Estrategias de Inversión (s.f.) “es un indicador que mide la variación de los precios que tiene un activo respecto a su media”. En otras palabras, se define como la desviación estándar de los rendimientos anualizados de una acción durante un periodo concreto, lo que manifiesta si la rentabilidad es estable o tiene un amplio rango de movimiento. La volatilidad es un indicador de riesgo en los mercados bursátiles, a mayor volatilidad mayor riesgo, ya que las posibilidades de que el valor suba o baje son mayores. Se calcula comparando la rentabilidad media en un horizonte temporal a la rentabilidad obtenida en cada sesión. Cuanto mayor sea el horizonte temporal, mayor solidez tendrá el indicador.

Los métodos utilizados para estimar la volatilidad en este Trabajo de Fin de Grado están comprendidos en disciplina de la econometría financiera. Según Maddala (1996) “La econometría es la aplicación de métodos estadísticos y matemáticos al análisis de datos económicos con el propósito de dar contenido empírico a las teorías económicas y

verificarlas o refutarlas.” La econometría financiera se diferencia del resto de ramas econométricas por el hecho de que su base de estudio es el análisis de precios de activos financieros, ya que estos, según la teoría de los mercados eficientes propuesta por Fama (1970) reflejan toda la información disponible sobre ese activo. Sus herramientas son usadas principalmente en el sector financiero para la gestión y análisis del riesgo, lo que permite optimizar la gestión de carteras.

Los modelos econométricos son muy importantes en el análisis bursátil porque, tal y como explica Burton G. Malkiel en “Un Paseo Aleatorio Por Wall Street” (1973), los movimientos de precios en los mercados financieros son “ajustes generados por los inversores debido a la entrada de nueva información al mercado”. Con esta definición, el autor da a entender que los movimientos del mercado son aleatorios y que, por tanto, intentar predecir tendencias futuras basándose en patrones y tendencias sobre precios pasados es imposible. En este sentido, esta teoría sugiere que la volatilidad y otros fenómenos del mercado son difícilmente predecibles.

Por otro lado, los modelos econométricos cobran especial valor debido a la gran variedad de mercados que existen, lo que impide crear un único modelo que explique el comportamiento de los mismos. Sin embargo, los modelos econométricos eliminan posibles errores y se adaptan a las características de cada mercado, teniendo en cuenta las particularidades y contexto de cada uno.

En definitiva, pese a que las teorías mencionadas sugieren que la volatilidad es un fenómeno altamente impredecible, los modelos econométricos han demostrado la presencia de agrupaciones de volatilidad, lo que indica que la volatilidad no es constante, sino que fluctúa con el tiempo. Mediante la aplicación de los modelos econométricos, como el *Generalized AutoRegressive Conditional Heteroscedasticity* (GARCH) que “captura las agrupaciones de volatilidad de las rentabilidades a través de la varianza condicional” (Sevilla, 2019), es posible realizar predicciones de volatilidad a corto y medio plazo.

La teoría en la que se basan los modelos utilizados en este Trabajo de Fin de Grado está definida en el artículo *Empirical properties of asset returns: stylized facts and statistical issues* (Cont, 2001). En él, el autor presenta una serie de hechos estilizados basados en el análisis estadístico de las variaciones de precios en diversos tipos de mercados e instrumentos financieros. Los hechos estilizados (*stylized facts*) son “Un

conjunto de propiedades, comunes en diversos instrumentos, mercados y series temporales que han sido observadas por estudios independientes y clasificadas como hechos estilizados”. Entre ellos, los que se consideran imprescindibles para comprender el análisis de volatilidad que se realiza en el apartado X se definen a continuación.

1. **Ausencia de autocorrelación lineal:** Habitualmente la autocorrelación lineal de las rentabilidades de un activo es insignificante.
2. ***Heavy Tails*:** Muestra que la distribución de las rentabilidades tiene colas más pesadas que la distribución normal, por lo tanto, la probabilidad de grandes variaciones en las rentabilidades es mayor de lo que predice la distribución normal.
3. **Asimetría en ganancias y pérdidas:** se observan grandes caídas en los precios de los activos, pero no movimientos de la misma magnitud al alza.
4. ***Aggregational Gaussianity*:** A medida que aumentamos la escala temporal sobre la que calculamos las rentabilidades, la distribución de las mismas tiende a la distribución normal. Dependiendo de la escala temporal la distribución de las rentabilidades será distinta.
5. **Intermitencia:** Las rentabilidades muestran, en cualquier escala temporal, una gran variabilidad. Esto se ha cuantificado mediante la presencia de ráfagas irregulares en series temporales de una gran variedad de estimadores de volatilidad
6. ***Volatility Clustering*:** Diversas mediciones de volatilidad muestran una autocorrelación positiva en días consecutivos, lo que demuestra que periodos de alta volatilidad tienden a agruparse en el tiempo.
7. **Disminución progresiva de la autocorrelación en valor absoluto:** la autocorrelación de las rentabilidades en valor absoluto disminuye lentamente a medida que aumenta el intervalo de tiempo observado.
8. **Efecto apalancamiento:** La mayoría de las medidas de volatilidad de un activo están negativamente correlacionadas con las rentabilidades del mismo. Por lo que, si el precio de un activo cae, mostrando rentabilidad negativa, la volatilidad probablemente aumentará.

2.- Análisis del Nivel de Volatilidad de las Compañías bursátiles.

Hull (2015) indica que “la volatilidad es una medida estadística de la dispersión de los rendimientos de un activo financiero”. Además, es un dato independiente a la tendencia del valor de un activo y varía notablemente dependiendo del activo que se estudie y sector que se tome de referencia. En los estudios financieros, el nivel de riesgo que incorpora un activo es un factor decisivo a la hora de tomar una decisión óptima de inversión, a la vez de ser uno de los más complicados de medir. En finanzas, el riesgo se mide mediante la varianza de las variaciones en las rentabilidades observadas con una determinada frecuencia (hora, día, semana, mes). En otras ocasiones se mide calculando el umbral máximo de pérdidas, definido como Valor en Riesgo (Value at Risk) que cuantifica la pérdida máxima de una cartera.

Existen varios tipos de volatilidad, aunque para el propósito que nos ocupa nos interesa definir únicamente dos: la volatilidad histórica y la implícita. Por un lado, la volatilidad histórica se refiere a “cómo el precio de un activo ha variado en el pasado. Esta se mide analizando los cambios del activo en un periodo específico. Se utiliza un enfoque estadístico para calcular la magnitud de estos cambios y la frecuencia con la que han ocurrido” Coll (2024). Este tipo de volatilidad es esencial como indicador de riesgo, ya que un activo con alta volatilidad histórica muestra que ha tenido precios que han cambiado drástica y rápidamente en el pasado, lo que sería un indicador de riesgo, independientemente de lo que pueda pasar en el futuro.

Por otro lado, la volatilidad implícita, a diferencia de la volatilidad histórica, refleja las expectativas del mercado sobre la volatilidad futura de un activo. Para calcularla, se debe observar cuánto varían los precios de las opciones de futuros. Al estar basada en las expectativas del mercado, la volatilidad implícita puede interpretarse como un indicador de la percepción de riesgo entre los inversores (Black y Scholes, 1973).

Ambos tipos de volatilidad son fundamentales para analizar el mercado y tomar decisiones de inversión, ya que proporcionan información sobre el comportamiento pasado y las expectativas futuras de riesgo asociadas a un activo financiero.

Un indicador ampliamente utilizado para medir esta volatilidad implícita es el índice VIX, creado por el Chicago Board Options Exchange (CBOE). Este índice cuantifica la volatilidad implícita de las opciones del índice estadounidense S&P 500 a 30 días. Un VIX alto sugiere que los inversores anticipan un mercado volátil, lo que

refleja una mayor percepción de riesgo en el corto plazo. De esta manera, tanto la volatilidad histórica como la implícita proporcionan información crítica para los análisis de mercado y la toma de decisiones de inversión, al ofrecer una visión integrada del comportamiento pasado y de las expectativas futuras de riesgo asociadas a un activo financiero.

Otro de los indicadores utilizados para cuantificar el riesgo es el valor en riesgo o Value at Risk (VaR), que mide la pérdida máxima que un valor puede alcanzar, con un porcentaje de fiabilidad dada y en un periodo dado. En el contexto de este trabajo se analizará el VaR paramétrico, que utiliza datos de rentabilidad estimados y asume que esta sigue una distribución normal. El VaR paramétrico se calcula de la siguiente forma:

$$VaR = Z \times \sigma \times \sqrt{t}$$

La estructura de la fórmula del VaR es la siguiente: Z es el valor de la distribución normal para el 95% de confianza; sigma (σ) es la desviación estándar de los rendimientos, y \sqrt{t} es un ajuste para el horizonte temporal, donde t es el número de días. El ajuste realizado para esta fórmula, al utilizar los rendimientos diarios, se hace sobre 250 días.

Así mismo, el modelo GARCH se utiliza para predecir la volatilidad a corto y medio plazo, esta vez bajo el supuesto de que la varianza (volatilidad) cambia a través del tiempo. Debido a su complejidad, su cálculo se realiza utilizando software estadístico. En este trabajo, se ha optado por utilizar RStudio, donde el modelo GARCH será calculado a través de la función `ugarchfit` del paquete `rugarch`. Esta herramienta ajusta automáticamente el modelo a la serie temporal seleccionada, facilitando así su aplicación.

3.- Datos.

Para el análisis realizado se ha seleccionado un amplio horizonte temporal que abarca desde el 1 de enero de 2007 hasta el 16 de agosto de 2024. Seleccionando este periodo es posible observar el impacto que han tenido dos crisis financieras mundiales, cuando estalló la burbuja inmobiliaria y la pandemia del COVID-19 en los mercados bursátiles. Las tres compañías seleccionadas para este análisis fueron elegidas por ser las de mayor ponderación en el IBEX 35 y sobre sus sectores, según los *factsheet* que realiza BME. Por ello se ha concluido que son las más representativas de cada sector, y, además, presentan valores de volatilidad superiores al índice de referencia IBEX 35, lo que las hace específicamente interesantes para el análisis. Las empresas seleccionadas son:

- Iberdrola (IBE): Perteneciente al sector Energía, representa un 40,32% del mismo, y el 13,83% del IBEX35.
- Santander (SAN): Perteneciente al sector Bancos, donde tiene una ponderación de 39,66%, y un 12,13% del IBEX35.
- Inditex (ITX): Es la compañía con mayor peso en el índice, con un 15,48%.

En la Figura 8 se presenta una comparación de la rentabilidad y volatilidad anual del IBEX35 con relación a dos de los sectores clave: IBEX 35 Bancos e IBEX 35 Energía, de los que se han seleccionado las compañías. Durante un periodo de 5 años, el IBEX 35 Bancos ha superado al índice de referencia en un 35,74% en términos de rentabilidad y ha mostrado una volatilidad 13,91% superior. Por otro lado, el IBEX 35 Energía ha obtenido un 14,6% menos de rentabilidad y una volatilidad 1,76% inferior en comparación al índice de referencia. La variedad sectorial de los activos seleccionados permitirá tener perspectiva sobre elementos comunes del mercado español y las particularidades propias de cada sector.

Figura 8. Comparación de rentabilidad y volatilidad del IBEX35.

Perfil de Riesgo Y Rentabilidad

	Rentabilidades				Volatilidades anuales		
	6 M %	12 M %	3 A %	5 A %	1-Año %	3-Años %	5-Años %
IBEX 35	9,18	16,91	21,88	19,56	12,64	16,44	20,85
IBEX 35 Bancos	18,92	36,13	63,27	55,30	20,06	28,04	34,76
IBEX 35 Energía	0,84	-1,21	7,79	4,69	13,04	15,80	19,09

Fuente: *Factsheet* IBEX 35 ENERGÍA a 21 de junio de 2024.

Para realizar un análisis detallado de los parámetros necesarios para un estudio de volatilidad que se ajuste a los valores seleccionados, es fundamental establecer un entorno de programación en *RStudio*. Esta plataforma ha sido elegida por su robustez y versatilidad, ofreciendo excelentes capacidades para el manejo de datos y análisis estadístico, lo que la hace ideal para gestionar los datos según nuestras necesidades particulares. Mediante funciones programadas en R, podremos acceder a datos históricos reales y acotarlos tanto al horizonte temporal elegido como a los parámetros óptimos para nuestro sistema. En el análisis de datos es recomendable cargar datos directamente de la fuente principal al programa donde se van a tratar, de esta manera se evitan errores de transcripción al manipular los datos manualmente. Los datos se obtienen directamente de Yahoo Finance, una fuente gratuita y de fácil acceso que proporciona precios diarios de la gran mayoría de instrumentos financieros.

Para poder llevar a cabo el análisis de datos, es fundamental disponer de paquetes de funciones que permitan la ejecución de tareas específicas, como implementar modelos GARCH y VaR que optimicen tanto la obtención como la manipulación de datos. Los paquetes de funciones utilizados en este estudio están descritos en la tabla 1.

Tabla 1. Descripción paquetes de funciones.

Nombre del paquete	Descripción de utilidad
quantmod	Permite obtener, manipular, visualizar y analizar datos financieros.
tseries	Permite manipular datos correspondientes a series temporales. Por ejemplo, importando datos de <i>Yahoo Finance</i> con el comando <i>getSymbols</i> .
zoo	Permite manipular y analizar series temporales irregulares.
ggplot2	Proporciona gráficos estáticos de alta calidad.
rugarch	Permite ajustar, evaluar y modelar modelos GARCH.

Fuente: elaboración propia.

Para la instalación de los paquetes que utilizaremos en este trabajo lo haremos con el comando *install.packages()* y el llamado correspondiente de los mismos lo haremos con el comando *library()*, su estructura y codificación se muestra en la Figura 9.

Figura 9. Instalación y carga de paquetes de funciones.

```
install.packages("quantmod") library(quantmod)
install.packages("tseries") library(tseries)
install.packages("zoo") library(zoo)
install.packages("ggplot2") library(ggplot2)
install.packages("rugarch") library(rugarch)
```

Fuente: Elaboración propia

Para el desarrollo de este trabajo se han seleccionado 3 activos financieros que son: Iberdrola, Inditex y Banco Santander. Los identificadores o *tickers* en *Yahoo Finance* son, respectivamente: IBE.MC, ITX.MC y SAN.MC. En la Figura 10 se presenta el comando ‘getSymbols’, perteneciente al paquete ‘tseries’ previamente cargado, el cual ha

sido codificado para permitir la importación de los datos correspondientes a los activos seleccionados.

Figura 10. Obtención de datos de las compañías.

```
getSymbols("IBE.MC", src = "yahoo")
IBE.MC <- C1(IBE.MC)

getSymbols("ITX.MC", src = "yahoo")
ITX.MC <- C1(ITX.MC)

getSymbols("SAN.MC", src = "yahoo")
SAN.MC <- C1(SAN.MC)
```

Fuente: Elaboración propia

Durante el proceso de obtención de datos, se detectaron valores vacíos (“*Missing Values* (NA)”), los cuales generan errores en el análisis e impiden el correcto funcionamiento de las funciones. Con el fin de evitar este problema, se ha llevado a cabo un proceso de importación y limpieza de los datos, el cual se ilustra en la Figura 11. Primero, se establece el 1 de enero de 2007 como la fecha de inicio del periodo de análisis, lo que delimita el horizonte temporal de los datos importados. A continuación, se especifican los *tickers* de las compañías en un mismo vector ‘symbolLst’, para importar los datos de los mismos de *Yahoo Finance* mediante el comando ‘getSymbols’. Este comando permite la importación de información histórica de los activos seleccionados. Por último, se combinan los precios de cierre ajustados de cada compañía en una base de datos “Data”, lo que facilita su manejo y análisis conjunto. Para garantizar que los datos obtenidos están listos para su utilización, se elimina cualquier valor vacío mediante la función ‘na.omit’.

Figura 11. Importación y limpieza de datos.

```
startDate = as.Date("2007-01-01")
symbolLst = c("IBE.MC", "ITX.MC", "SAN.MC")
symbolData <- new.env()
getSymbols(symbolLst, env = symbolData, src = "yahoo", from = startDate)
Data <- do.call(merge, eapply(symbolData,C1))
Data <- na.omit(Data)
```

Fuente: Elaboración propia

4.- Metodología.

Este apartado describe la implementación de técnicas de análisis cuantitativo para examinar la volatilidad de las rentabilidades financieras. El enfoque se centra en la aplicación de dos modelos fundamentales: el modelo GARCH y predicción de volatilidad

en base a volatilidad histórica, utilizados para analizar y predecir la volatilidad con la mayor precisión posible. A continuación, se detalla cada paso del proceso, incluyendo fragmentos ilustrativos del código.

1.- Visualización de los datos

El proceso comienza visualizando los precios de cierre ajustados de los activos seleccionados. Esta visualización inicial es crucial para comprender la evolución temporal de los precios y detectar posibles anomalías o tendencias. Se generan gráficos utilizando las funciones `plot` y `chartSeries`:

- **Gráficos básicos (`plot`):** Proporcionan una vista simple pero efectiva de la tendencia de los precios a lo largo del tiempo, permitiendo identificar anomalías evidentes y evaluar la volatilidad histórica.
- **Gráficos detallados (`chartSeries`):** Ofrecen una representación más completa, permitiendo la inclusión de indicadores técnicos, superponer otros gráficos y elementos analíticos, mejorando así la calidad y profundidad del análisis visual.

2.- Normalización y Comparación de Series Temporales.

Para comparar eficazmente las series temporales de los precios de cierre, se realiza previamente un proceso de normalización. Este proceso ajusta todos los valores en relación con un valor inicial de referencia, permitiendo una comparación directa de las variaciones porcentuales entre los activos, independientemente de sus niveles de precios originales.

La normalización de los datos se ilustra en la Figura 12. En ella, se puede observar cómo se divide cada valor de la serie temporal por el primer valor de esta, transformando todos los valores en una escala donde el primero es igual a 1. Esto facilita la observación de variaciones relativas a lo largo del tiempo. Se han ajustado los ejes del gráfico con el fin de obtener la mejor visualización de este.

Figura 12. Graficación de datos normalizados.

```
chartSeries(Data[, 1] / as.numeric(Data[1, 1]), yrange = c(0,6),
            name = "Comparación Normalizada de IBE.MC, ITX.MC, y SAN.MC",
            col = "green")

addTA(Data[, 2] / as.numeric(Data[1, 2]), on = 1, col = "red")
addTA(Data[, 3] / as.numeric(Data[1, 3]), on = 1, col = "blue")
```

Fuente: Elaboración propia

A continuación, las series normalizadas de Inditex y Banco Santander se añaden a un mismo gráfico mediante la función 'addTA', permitiendo una comparación directa con la serie de Iberdrola.

3.- Cálculo y Visualización de los Rendimientos Logarítmicos.

Posteriormente, se calculan los rendimientos logarítmicos diarios de los activos debido a su propiedad aditiva, lo que facilita la comparación entre diferentes periodos y activos.

Para el cálculo de rendimientos, mostrado en la Figura 13, se utiliza un bucle para recorrer cada columna de la matriz Data, donde cada columna representa los precios de cierre ajustados de un activo. El cálculo de los rendimientos logarítmicos se realiza con la función 'periodReturn'. Los rendimientos calculados se almacenan en el objeto 'Returns', que se estructura en una matriz donde cada columna contiene los rendimientos de un activo específico. Se generan gráficos comparativos utilizando 'plot', superponiendo las series de rendimientos de los tres activos en un solo gráfico, utilizando 'lines'.

Figura 13. Cálculo de los rendimientos logarítmicos.

```
for (j in 1:dim(Data)[2])
{
  if(j==1){Returns = periodReturn(Data[,j], period = 'daily', type = 'log', reading = TRUE)
  }else{Returns = merge(periodReturn(Data[,j], period = 'daily',type = 'log', reading = TRUE),
                        Returns)}
}

colnames>Returns) <- c("IBE.MC", "ITX.MC", "SAN.MC")
plot>Returns[,1], col= "black", type = "l",ylim = c(-0.25, 0.25),
     xlab = "Fecha", ylab = "Rendimiento")

lines>Returns[,2], col = "red")
lines>Returns[,3], col = "blue")
```

Fuente: Elaboración propia

4.- Análisis Específico de los Rendimientos

Una vez ya se tienen los rendimientos, se puede pasar a realizar el análisis detallado de los rendimientos de las compañías. En este apartado solo se muestra el análisis del Banco Santander, y los resultados de Iberdrola se encuentran en el Anexo I y los de Inditex en el Anexo II.

Los rendimientos se calculan siguiendo el método anterior, pero enfocado exclusivamente en SAN.MC (Figura 14). Se genera un gráfico ajustado para visualizar claramente las fluctuaciones y rangos de movimiento, enfocado en identificar periodos de agrupaciones de volatilidad (*Volatility Clusters*).

Figura 14. Cálculo de los rendimientos del Banco Santander.

```
SAN.MC>Returns <- periodReturn(SAN.MC, period = 'daily', type = 'log', reading = TRUE)
plot(SAN.MC>Returns, ylim = c(-0.25, 0.25), col = "black")
```

Fuente: Elaboración propia

5.- Visualización Conjunta de Rendimientos y Precios

Para observar cómo los cambios en el precio de las acciones de SAN.MC se relacionan con sus rendimientos, se unifican ambas series en un mismo gráfico. En la Figura 15 se muestra el código utilizado para graficar la serie de precios de SAN.MC con 'chart_Series', y se superpone la serie de rendimientos utilizando 'add_TA'. Esta visualización es útil para detectar el efecto apalancamiento.

Figura 15. Análisis simultáneo de rendimientos y precios de SAN.MC

```
chart_Series(SAN.MC)
add_TA(SAN.MC>Returns)
```

Fuente: Elaboración propia

6.- Autocorrelación de Precios y Rendimientos

Para entender mejor el comportamiento de los rendimientos y verificar el correcto funcionamiento del código, en la Figura 16, se calcula y grafica la autocorrelación de los precios y rendimientos de SAN.MC. En ambos cálculos se utiliza un 'lag.max' de 250 días, esto establece el número máximo de días o retardos que se analizarán en la serie temporal. Se ha seleccionado esta cifra ya que en los mercados financieros un año típico tiene 252 días, por lo que este análisis de autocorrelación estaría abarcado aproximadamente un año de datos. Esto permite observar cómo los rendimientos o precios de hoy están correlacionados no solo con los días cercanos, sino también con los que ocurrieron hace un año. La selección de un elevado número de lags es importante en la identificación de fenómenos como el *volatility clustering*

- **Autocorrelación de Precios:** Se utiliza la función 'acf' para calcular y graficar la autocorrelación de los precios. Una alta autocorrelación indicaría que los precios

actuales están significativamente influenciados por los precios pasados, lo que permite identificar si existen patrones de dependencia.

- **Autocorrelación de Rendimientos:** Se calcula para los rendimientos originales y en valor absoluto, utilizando un lag.max de 250 días para abarcar aproximadamente un año de datos. Esto ayuda a identificar fenómenos como el clustering de volatilidad.

Figura 16. Autocorrelación de precios, rendimientos y rendimientos (Valor absoluto)

```
acf(Data[, 3], lag.max = 250)
acf(SAN.MC>Returns, lag.max = 250)
acf(abs(SAN.MC>Returns), lag.max = 250)
```

Fuente: Elaboración propia

7.- Análisis de la Distribución de los Rendimientos

En la Figura 17, se analiza la distribución de los rendimientos diarios de SAN.MC para evaluar su ajuste a una distribución normal y compararla con una estimación basada en la densidad de kernel.

- **Distribución Normal:** Se calculan los parámetros de la distribución normal (media y desviación estándar) basados en los rendimientos históricos, y se genera una distribución teórica con 'dnorm'.
- **Estimación de Densidad de Kernel:** Se utiliza la función 'density' para modelar la distribución real de los rendimientos sin asumir una forma específica, permitiendo capturar características como colas pesadas.

Ambas distribuciones se comparan visualmente, superponiendo la densidad estimada a la distribución normal en un gráfico. La secuencia está acotada entre el -0,1 y 0,1 con incrementos de 0,001. Esta acotación se ha ajustado de forma que los datos sean expuestos de forma óptima, cubriendo todos los valores.

Figura 17. Distribución de rendimientos de SAN.MC

```
muSAN = mean(SAN.MC>Returns)
sigmaSAN = sd(SAN.MC>Returns)

x = seq (-0.1,0.1,0.001)
Gaussian_densitySAN = dnorm(x,muSAN, sigmaSAN)
plot(Gaussian_densitySAN, type = "l")

kernel_densitySAN = density(SAN.MC>Returns)
plot(kernel_densitySAN)
lines(x, Gaussian_densitySAN, col = "red")
```

Fuente: Elaboración propia

8.- Predicción de la Volatilidad con Volatilidad Muestral y Validación mediante *Backtesting*.

Este bloque de código combina la predicción de volatilidad futura a partir de la volatilidad muestral con su validación mediante *backtesting*.

Para el cálculo de la volatilidad muestral, se define una ventana móvil de 120 días, y se calcula la volatilidad como la desviación estándar de los rendimientos dentro de esta ventana. Este tamaño es una elección común en finanzas, ya que representa aproximadamente la mitad de un año de operaciones bursátiles. La volatilidad se anualiza para hacerla comparable con otras medidas financieras. Seguidamente, se crea un objeto para almacenar los valores de volatilidad que se van a calcular. Para ello, se genera un vector llamado 'Sample_VolatilitySAN', del mismo tamaño que el vector 'SAN.MC>Returns', pero inicializado con ceros en lugar de contener los datos de rendimientos, el resultado se observa en la Figura 18. Este paso asegura que ambos objetos tienen la misma longitud. El vector 'Sample_VolatilitySAN' actuará como un "almacén" donde se registrarán los valores de volatilidad calculados para cada día.

Figura 18. Vector generado 'Sample_VolatilitySAN'

> SAN.MC>Returns		> Sample_VolatilitySAN	
	daily.returns		daily.returns
2007-01-01	0.0000000000	2007-01-01	0
2007-01-02	0.0244510770	2007-01-02	0
2007-01-03	0.0006898600	2007-01-03	0
2007-01-04	0.0055021163	2007-01-04	0
2007-01-05	-0.0061919764	2007-01-05	0
2007-01-08	-0.0041494131	2007-01-08	0
2007-01-09	0.0000000000	2007-01-09	0
2007-01-10	-0.0217171024	2007-01-10	0
2007-01-11	0.0126673175	2007-01-11	0
2007-01-12	-0.0006995888	2007-01-12	0
...		...	
2024-08-14	-0.0031657184	2024-08-14	0
2024-08-15	0.0299140026	2024-08-15	0
2024-08-16	0.0008281538	2024-08-16	0
2024-08-19	0.0133914096	2024-08-19	0
2024-08-20	-0.0105573012	2024-08-20	0
2024-08-21	0.0036490110	2024-08-21	0
2024-08-22	0.0049227444	2024-08-22	0
2024-08-23	0.0173856505	2024-08-23	0
2024-08-26	-0.0056461273	2024-08-26	0
2024-08-27	0.0249912998	2024-08-27	0

Fuente: Elaboración propia

En la figura 19, se predice la volatilidad utilizando la volatilidad histórica mediante la ejecución de un bucle 'for' que comienza en el día 121, dado que la ventana móvil abarca 120 días. En cada iteración, se seleccionan los rendimientos de los últimos 120 días, utilizando el rango de 'i-rw_size+1' a 'i', donde 'i' representa el día actual. La volatilidad se calcula mediante la desviación estándar con la función 'sd', que mide la variabilidad de los rendimientos en relación con la media de ese periodo. Para hacer la volatilidad comparable con otras medidas financieras, se anualiza multiplicándola por la raíz cuadrada de 250 (días laborables en un año). La anualización proporciona la volatilidad anual esperada si la volatilidad diaria permaneciera constante. Finalmente, la volatilidad calculada se superpone en un gráfico junto a los rendimientos de SAN.MC, permitiendo visualizar cómo ha fluctuado la volatilidad a lo largo del tiempo.

Figura 19. Predicción de volatilidad con volatilidad histórica.

```
rw_size = 120
Sample_VolatilitySAN = SAN.MC>Returns*0
for (i in rw_size:length(SAN.MC>Returns)){
  Sample_ReturnsSAN = SAN.MC>Returns[(i-rw_size+1):i]
  Sample_VolatilitySAN[i] = sd(Sample_ReturnsSAN)*sqrt(250)
}
add_TA(Sample_VolatilitySAN)
```

Fuente: Elaboración propia

9.- Cálculo y Visualización de la Predicción de Volatilidad Cálculo y Visualización de la Predicción de Volatilidad y Validación mediante *Backtesting*.

Utilizando la volatilidad muestral calculada, se predice el VaR (figura 20) y se compara con los rendimientos reales para evaluar la precisión del modelo, observando así el número de ocasiones en los que el modelo no ha podido predecir el VaR, por ende, no ha predicho bien la volatilidad.

Se inicia el vector 'VaR_PrediccionSAN' para almacenar los valores de VaR predichos, posteriormente se calcula el VaR en cada punto del tiempo utilizando la media 'muSAN' y desviación estándar 'sigmaSAN' de los rendimientos. Los resultados se almacenan y visualizan junto a los rendimientos reales. Esta predicción se almacena en el vector 'VaR_PrediccionSAN'), y se superpone al gráfico de los rendimientos para compararlo visualmente con la realidad.

Figura 20. Predicción VaR y graficación sobre los rendimientos reales

```
VaR_PrediccionSAN = SAN.MC>Returns*0
for (i in rw_size : (length(SAN.MC>Returns)-1)) {
  Sample>ReturnsSAN = SAN.MC>Returns[(i-rw_size+1):i]
  muSAN = mean(Sample>ReturnsSAN)
  sigmaSAN = sd(Sample>ReturnsSAN)
  VaR_PrediccionSAN[1+i] = muSAN - 1.645*sigmaSAN
}
add_TA(VaR_PrediccionSAN, on = 1)
```

Fuente: Elaboración propia

En la figura 21 se ha evaluado la precisión del modelo VaR. Se evalúa contando cuántas veces las pérdidas reales han superado las predicciones del VaR, lo que indicaría un fallo en la predicción del riesgo. Se inicializa un contador de 'errores' en cero, que se incrementa cada vez que el modelo falla en su predicción, es decir, cada vez que las pérdidas reales son mayores que el VaR predicho. Este recuento se realiza mediante un bucle que recorre los días desde el 121 hasta el final del periodo analizado. Dentro del bucle, se compara el VaR predicho para cada día con el rendimiento real de ese día. Si el rendimiento real es inferior al VaR predicho, se considera un error y se incrementa el contador. Finalmente, se calcula la proporción de errores dividiendo el número de errores entre el total de observaciones. Un menor porcentaje de errores indica un modelo de VaR más preciso y fiable.

Figura 21. Recuento de errores de predicción

```
# Recuento errores
errores = 0
for (i in rw_size : (length(SAN.MC>Returns)-1)) {
  errores = errores + (as.numeric(VaR_PrediccionSAN[1+i])>as.numeric(SAN.MC>Returns[i]))
}

totales = (length(SAN.MC>Returns)-1) - rw_size + 1

errores / totales

errores
totales
```

Fuente: Elaboración propia

10.- Predicción de Volatilidad con Modelo GARCH y Validación mediante Cálculo del VaR

Finalmente, en la figura 22, se utiliza un modelo GARCH para predecir la volatilidad y calcular el VaR, validando el ajuste del modelo mediante la comparación del VaR predicho con las pérdidas reales.

Se genera un vector para almacenar los valores de VaR calculados mediante GARCH, y se utiliza un bucle para calcular el VaR en cada iteración. El modelo GARCH se configura con un "código modelo" y el VaR se calcula aplicando su fórmula, donde la media y la desviación estándar se determinan en función de la volatilidad predicha. La predicción resultante se almacena en el vector 'VaR_GARCH_Prediccion_SAN' y se superpone al gráfico de los rendimientos para facilitar la comparación visual con la realidad.

El modelo se valida de manera similar al proceso anterior, comparando los cálculos del VaR con las pérdidas reales observadas. Si las pérdidas reales superan las predicciones del modelo, el contador de errores se incrementa en una unidad.

Figura 22. Predicción de la volatilidad y el VaR con modelo GARCH.

```

VaR_GARCH_Prediccion_SAN = SAN.MC>Returns*0
for (i in rw_size : (length(SAN.MC>Returns)-1)) {
  Muestra_returnsSAN = SAN.MC>Returns[(i-rw_size+1):i]
  garch.setup = ugarchspec(mean.model = list(armaOrder=c(0,0), include.mean = TRUE)
                           ,variance.model = list(model="sGARCH", garchOrder=c(1,1)), distribution.model = "norm")
  tryCatch({fit=ugarchfit(garch.setup, data = Muestra_returnsSAN, solver = "hybrid")}, error=function(e)
    e, warning = function(w) w)
  sim_returns_SAN = fitted(ugarchsim(fit, n.sim = 1, n.start = 0, m.sim = 1000, startMethod = "sample"))
  muSAN = mean(sim_returns_SAN)
  sigmaSAN = sd(sim_returns_SAN)
  VaR_GARCH_Prediccion_SAN[i+1] = muSAN - 1.645*sigmaSAN
  print(i)
}
add_TA(VaR_GARCH_Prediccion_SAN, on = 1)

errores = 0
for (i in rw_size : (length(SAN.MC>Returns)-1)) {
  errores = errores + (as.numeric(VaR_GARCH_Prediccion_SAN[i+1])>as.numeric(SAN.MC>Returns[i]))
}
totales = (length(SAN.MC>Returns)-1) - rw_size + 1

errores / totales
errores

```

Fuente: Elaboración propia

5.- Resultados.

El apartado resultados se divide en diferentes subapartados en los que se muestran los resultados de las diferentes partes del proceso descritas en el apartado anterior de metodología.

1.- Visualización de los Datos

En este apartado se presenta la visualización inicial de los precios de cierre ajustados de los activos seleccionados. Los gráficos obtenidos permiten analizar la evolución temporal de los precios y detectar posibles tendencias y anomalías que podrían influir en el análisis posterior.

El gráfico 1 (visualización básica con ‘plot’) muestra la tendencia general de los precios de SAN.MC desde el 1 de enero de 2007 hasta el 27 de agosto de 2024. Se obtiene una vista simplificada, pero efectiva, que resalta claramente los cambios significativos en el precio a lo largo del tiempo. Se pueden observar picos importantes, que coinciden con eventos económicos clave, como la crisis financiera de 2008 y la pandemia de COVID-19 en 2020. Esta visualización inicial es crucial para evaluar la volatilidad histórica y cualquier comportamiento anómalo que pueda requerir un análisis más profundo.

2.- Normalización y Comparación de Series Temporales

Este análisis permite comparar directamente las variaciones porcentuales de los activos a lo largo del tiempo, independientemente de sus niveles de precios originales.

- **Gráfico de Comparación Normalizada:** El Gráfico 2 muestra la evolución de los precios de cierre de IBE.MC, ITX.MC, y SAN.MC, todos normalizados respecto a su valor inicial en enero de 2007.
- **Rendimiento Comparativo:**
 - **Inditex (ITX.MC)** (línea roja): Muestra un rendimiento notablemente superior al de los otros dos activos, alcanzando casi seis veces su valor inicial hacia finales de 2024. Este comportamiento destaca su capacidad de crecimiento sostenido a lo largo del tiempo, incluso en periodos de alta volatilidad.
 - **Iberdrola (IBE.MC)** (línea verde): Mantiene un crecimiento estable, doblando su valor inicial hacia el final del período analizado. Su tendencia refleja una volatilidad más controlada en comparación con Inditex, pero con un crecimiento constante.
 - **Banco Santander (SAN.MC)** (línea azul): Exhibe un rendimiento más moderado, con una tendencia más volátil y menos crecimiento relativo. Su precio normalizado se mantiene alrededor de su valor inicial, reflejando una menor capacidad de recuperación tras las crisis financieras y eventos adversos.

Mientras que Inditex se destaca por su fuerte rendimiento, Iberdrola muestra un crecimiento estable, y Banco Santander revela una mayor exposición a la volatilidad del mercado.

Gráfico 1. Precios de Banco Santander en el periodo 01-01-2007 a 27-08-2024.



Fuente: Elaboración propia

3.- Cálculo y Visualización de los Rendimientos Logarítmicos

El Gráfico 3 muestra las fluctuaciones diarias de los rendimientos logarítmicos para IBE.MC (Rojo), ITX.MC (Azul), y SAN.MC (negro), superpuestos en un solo gráfico.

El Gráfico 3 muestra una alta volatilidad en los rendimientos, especialmente durante los períodos de crisis financiera (2008-2009) y la pandemia de COVID-19 (2020). Estos periodos se caracterizan por picos extremos (superiores a la franja $[-0.1, 0.1]$), tanto positivos como negativos, que indican grandes fluctuaciones en los precios de los activos. En los periodos posteriores a estas crisis, los rendimientos parecen estabilizarse, pero siguen mostrando variabilidad significativa, lo que sugiere que los mercados permanecen sensibles a diversos factores externos.

- **Comparación entre Activos:**

Banco Santander (SAN.MC) muestra una mayor variabilidad en los rendimientos, con picos más pronunciados en comparación con Iberdrola e Inditex, superando incluso la zona de 0.2 en 2 ocasiones. Esto puede reflejar su mayor exposición al riesgo en el sector financiero.

Inditex (ITX.MC), aunque presenta volatilidad, muestra una tendencia más controlada en comparación con Banco Santander, lo que podría indicar una mayor estabilidad.

Iberdrola (IBE.MC) exhibe la menor volatilidad de los tres, lo cual es consistente con su posición en el sector energético, que tiende a ser menos volátil que los sectores financiero y de consumo.

Gráfico 2. Comparación normalizada de IBE.MC, ITX.MC y SAN.MC



Fuente: Elaboración propia

4.- Análisis Específico de los Rendimientos del Banco Santander

En este apartado se presenta un análisis detallado de los rendimientos logarítmicos diarios de Banco Santander (SAN.MC). Este análisis se enfoca en identificar patrones específicos, como la presencia de agrupaciones de volatilidad (*volatility clusters*), que son de particular interés para comprender la dinámica de los rendimientos de este activo.


El Gráfico 4 permite visualizar las variaciones en los rendimientos de forma clara, destacando los periodos de alta volatilidad, considerándose tales cuando superen los límites de $[-0,1,0.1]$, volatilidad moderada si supera $[-0.05,0.05]$ y baja volatilidad si no llega a $[-0.05,0.05]$.

El Gráfico 4 revela la presencia de *volatility clusters*, especialmente durante las crisis financieras de 2008 y la pandemia de COVID-19 en 2020. Estos clusters se caracterizan por una serie de grandes fluctuaciones seguidas, tanto positivas como negativas, que indican periodos de alta incertidumbre en el mercado. Se marcan en rojo *volatility clusters* de alta volatilidad y en azul *clusters* de volatilidad moderada. Se han destacado 4 clusters de alta volatilidad y 5 de volatilidad moderada. Llama la atención que los clusters de volatilidad moderada son más sostenidos en el tiempo y que a partir de 2010, se observa una reducción en la volatilidad general, aunque persisten picos aislados que reflejan la sensibilidad del activo a eventos económicos significativos.

Durante la crisis financiera de 2008-2009, los rendimientos muestran una alta volatilidad con fluctuaciones extremas, lo que sugiere una gran inestabilidad en el precio de las acciones de Santander en ese período. En contraste, los años posteriores muestran una estabilización relativa, aunque la volatilidad aumenta nuevamente en 2020 con el impacto del COVID-19. Sin embargo, la magnitud de los movimientos es menor en comparación con la crisis anterior, lo que puede indicar una mejor gestión del riesgo o una menor exposición al mismo.

La identificación de estos periodos de alta volatilidad es esencial para el modelado de la misma utilizando herramientas como GARCH. La presencia de *volatility clusters* sugiere que la volatilidad no es constante en el tiempo y tiende a agruparse, lo que es crucial para ajustar correctamente los modelos predictivos.

Gráfico 3. Superposición de variación de los rendimientos de las tres compañías.



Fuente: Elaboración propia

5.- Visualización Conjunta de Rendimientos y Precios de SAN.MC

En este apartado, se presenta una visualización combinada de la serie de precios y la serie de rendimientos logarítmicos de Banco Santander. El Gráfico 5 permite analizar cómo los cambios en los precios se relacionan con los rendimientos, y es particularmente útil para identificar fenómenos como el efecto apalancamiento, donde los movimientos a la baja en los precios están asociados con altos niveles de volatilidad, mientras que movimientos al alza no muestran el mismo comportamiento en la volatilidad.

Durante las crisis de 2008 y 2020, se puede ver claramente cómo las grandes caídas en los precios coinciden con picos en los rendimientos negativos, seguidos de periodos de alta volatilidad.

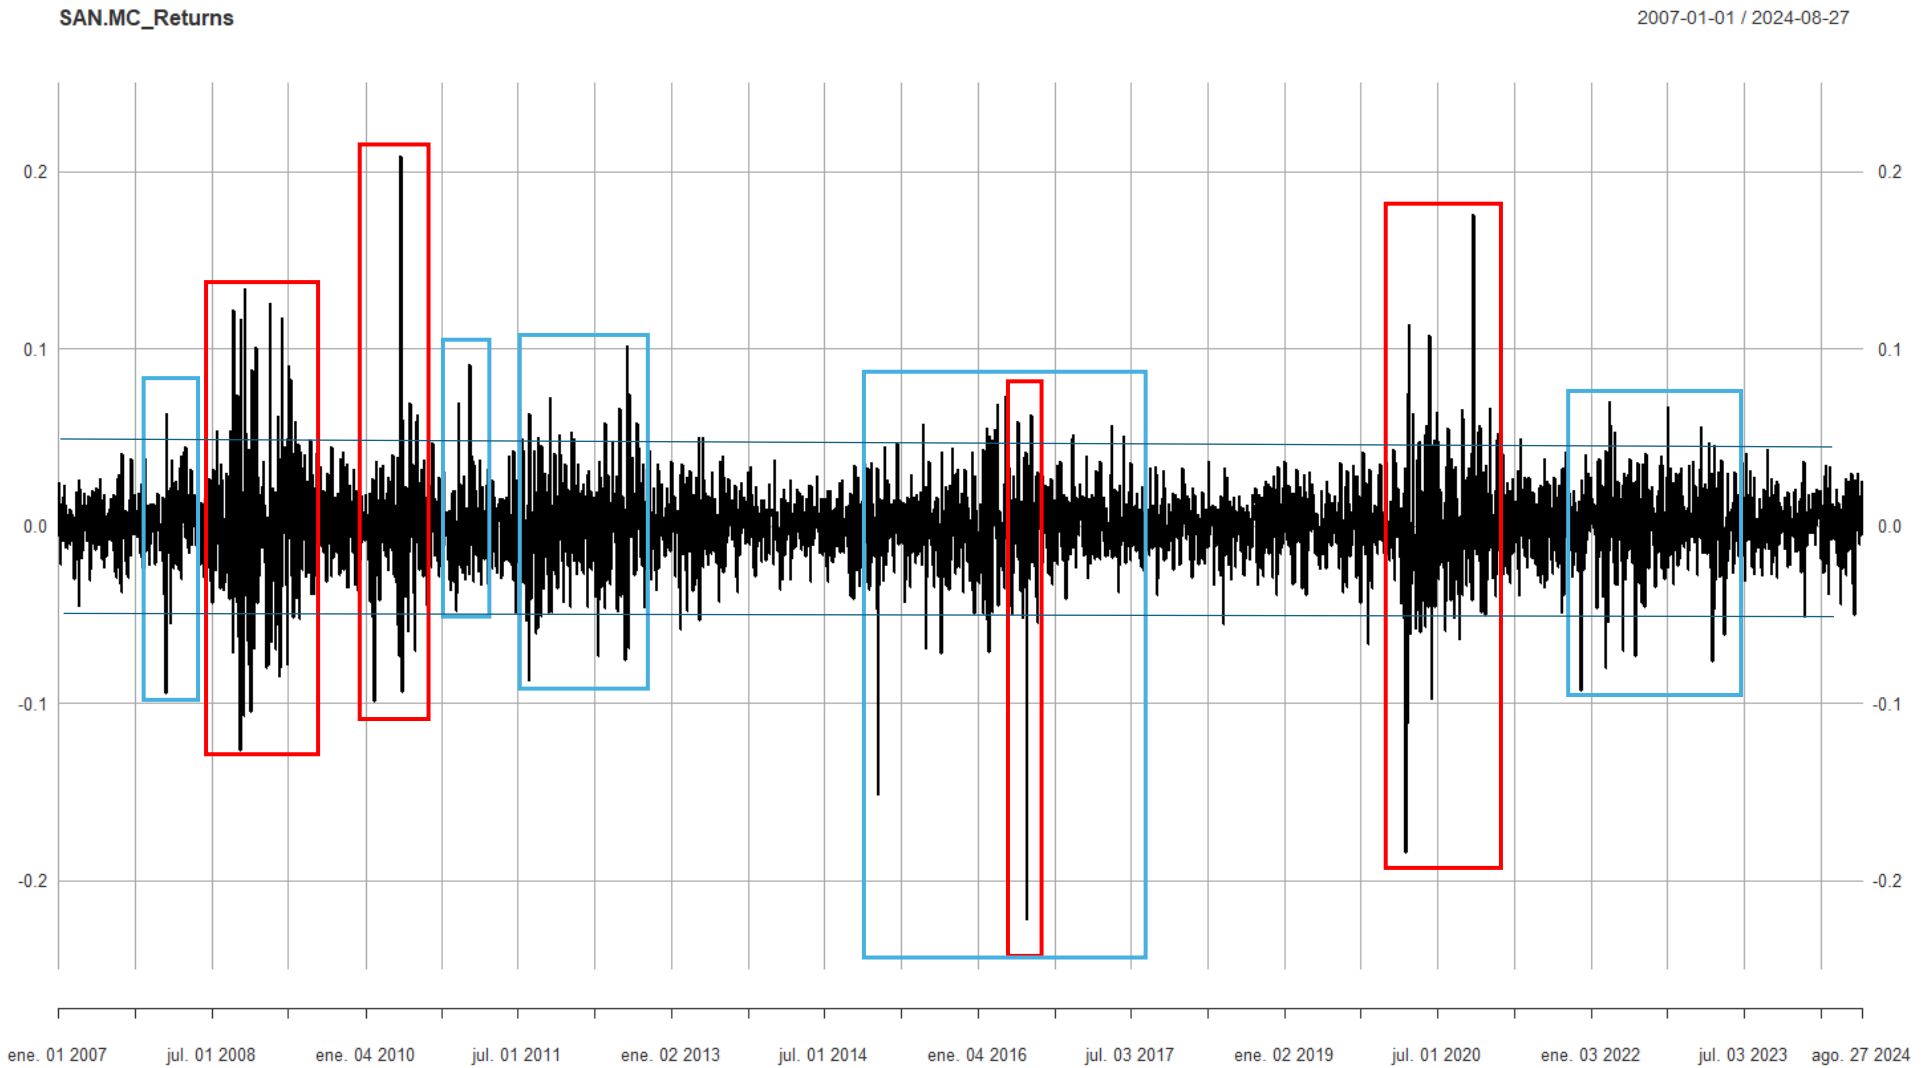
Sin embargo, los movimientos al alza no siempre resultan en una reducción significativa de la volatilidad, lo que sugiere que la respuesta del mercado a las subidas de precios es menos sensible que a las caídas. Este fenómeno puede ser indicativo de la asimetría en la percepción del riesgo, donde las pérdidas se consideran más significativas que las ganancias equivalentes, lo cual es un factor clave en la modelización de la volatilidad.

6.- Autocorrelación de Precios y Rendimientos

En este apartado se presentan los resultados de la autocorrelación de los precios y rendimientos de Banco Santander. Este análisis es crucial para comprender la dependencia temporal en las series de tiempo y para detectar fenómenos como el clustering de volatilidad.

En el gráfico 6 se muestra la autocorrelación de los precios de cierre de las acciones de Banco Santander (SAN.MC) a lo largo del tiempo. La alta autocorrelación observada, especialmente en los primeros *lags*, sugiere que los precios actuales están fuertemente influenciados por los precios pasados. Este patrón es común en las series temporales financieras, donde los precios de un día tienden a estar correlacionados con los días anteriores. La autocorrelación disminuye gradualmente, pero sigue siendo significativa hasta cerca del *lag* 250, lo que indica una persistencia en la relación entre los precios a lo largo del tiempo.

Gráfico 4. Rendimientos de Banco Santander en el periodo de 01-01-07 a 27-08-24



Fuente: Elaboración propia

El gráfico 7 refleja la autocorrelación de los rendimientos logarítmicos de SAN.MC. Aquí, se observa que la autocorrelación es casi nula para la mayoría de los lags, lo que indica que los rendimientos actuales no dependen significativamente de los rendimientos pasados.

El gráfico 8 presenta la autocorrelación de los rendimientos en valor absoluto. En este caso, la autocorrelación disminuye de manera más lenta, lo que indica la presencia de clustering de volatilidad. Esto significa que los periodos de alta volatilidad tienden a agruparse, seguidos por más periodos de alta volatilidad, y lo mismo ocurre con los periodos de baja volatilidad. Este fenómeno es esencial para la modelización de la volatilidad con modelos GARCH, que asumen que la volatilidad no es constante, sino que varía con el tiempo, tendiendo a agruparse en ciertos periodos.

La falta de autocorrelación en los rendimientos logarítmicos implica que los movimientos diarios en los precios de SAN.MC son esencialmente independientes entre sí. Este resultado es consistente con la hipótesis del mercado eficiente, donde se espera que los rendimientos no sigan un patrón predecible.

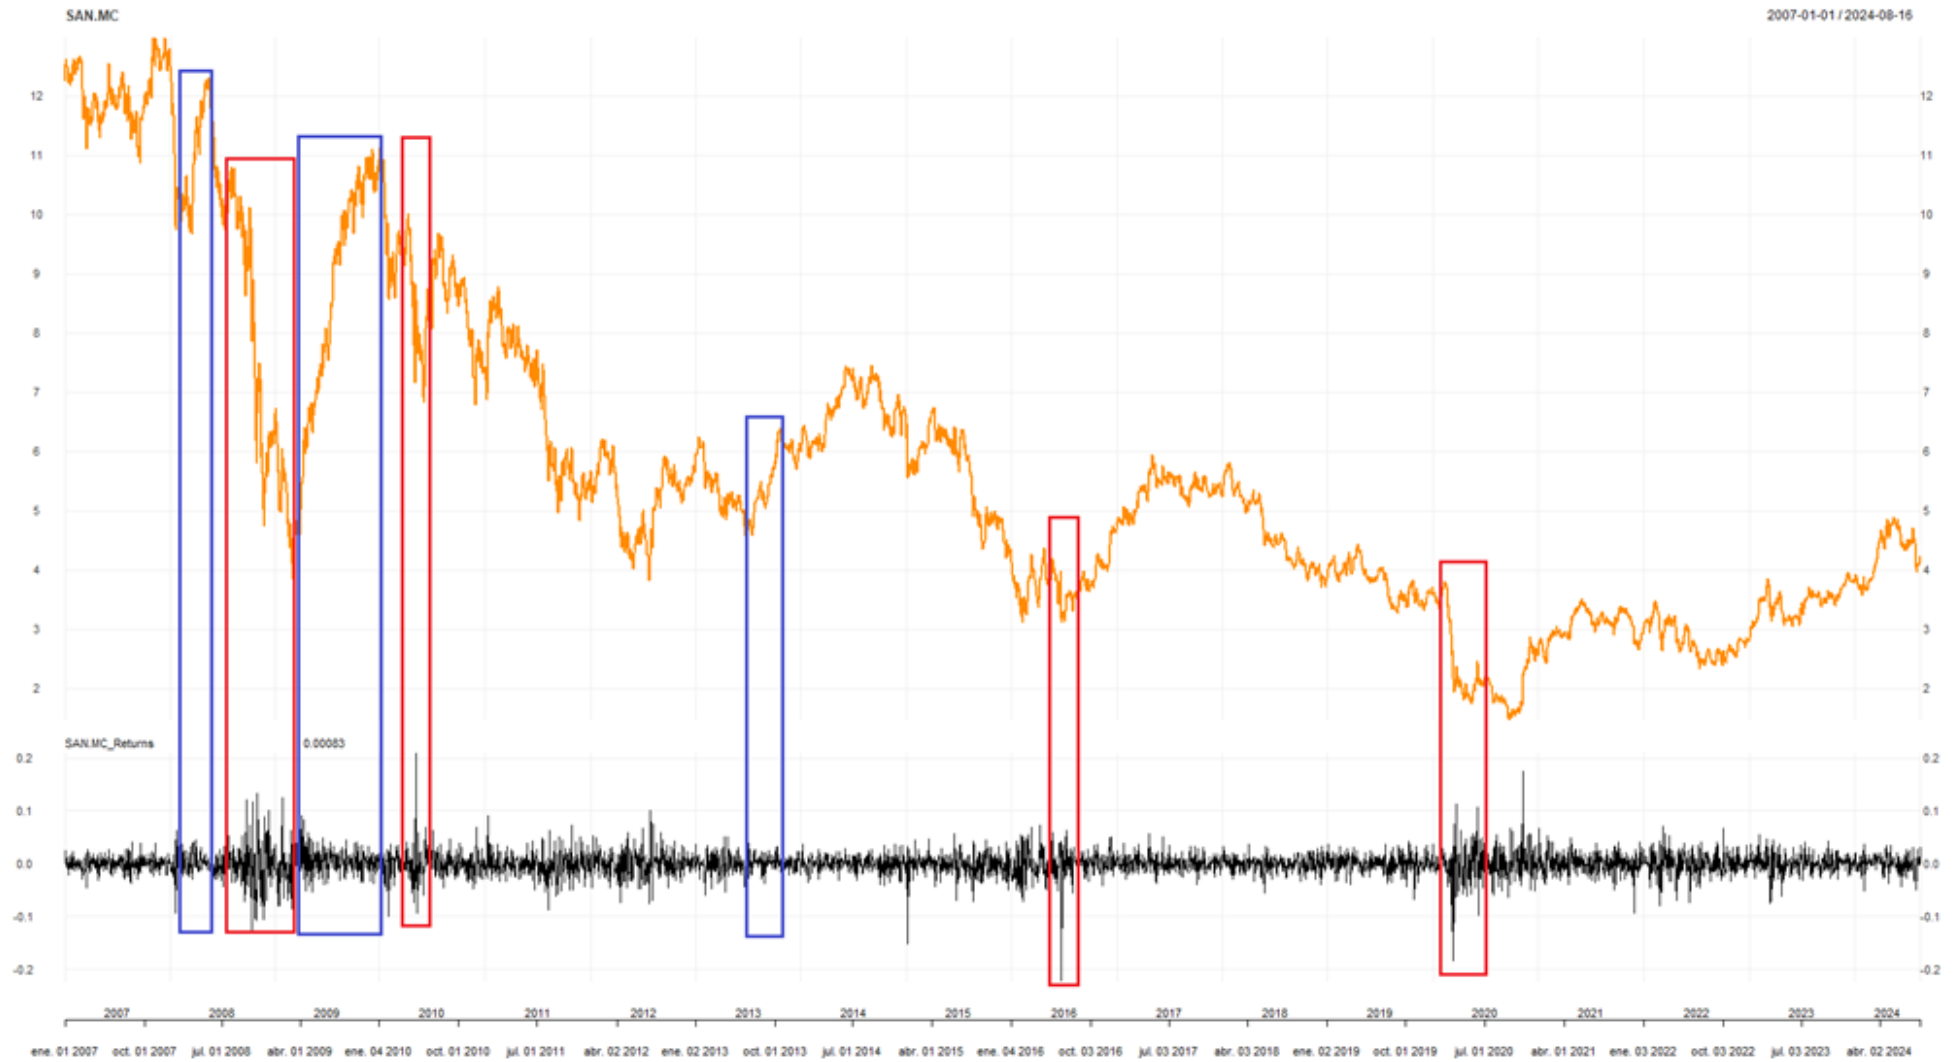
7.- Análisis de la Distribución de los Rendimientos

En este apartado, se examina la distribución de los rendimientos diarios de SAN.MC para evaluar su ajuste a una distribución normal y compararla con una estimación no paramétrica. Esta comparación es esencial para entender si los rendimientos siguen un comportamiento típico de una distribución normal o si presentan características distintivas, como colas pesadas, que son comunes en los datos financieros.

En el Gráfico 9 se muestran dos curvas superpuestas:

- **Curva Roja:** Representa la distribución teórica basada en una distribución normal, calculada a partir de la media y desviación estándar de los rendimientos históricos de SAN.MC.
- **Curva Negra:** Muestra la estimación de densidad de kernel, que es un enfoque no paramétrico para modelar la distribución real de los datos sin asumir una forma predefinida.

Gráfico 5. Precios y rendimientos del Banco Santander.



Fuente: Elaboración propia

Ambas curvas coinciden en gran medida en el centro de la distribución, lo que indica que la mayoría de los rendimientos se concentran alrededor de la media esperada. Sin embargo, la curva de densidad de *kernel* es ligeramente más alta en esta región, sugiriendo que hay más datos cerca de la media de lo que predice la distribución normal.

Las diferencias más notables se observan en las colas de la distribución. La curva de densidad de *kernel* presenta colas más pesadas en comparación con la distribución normal, lo que sugiere la presencia de eventos extremos (tanto positivos como negativos) que ocurren con mayor frecuencia de lo que se esperaría bajo una distribución normal.

Esto es crucial para una gestión de riesgos efectiva, ya que subestimar estos eventos podría llevar a una mala estimación del riesgo.

Por lo tanto, la estimación de densidad de *kernel* proporciona una visión más realista de cómo se distribuyen los rendimientos de SAN.MC. Esto sugiere que, para capturar adecuadamente el riesgo asociado con estos rendimientos, es recomendable utilizar modelos que consideren estas colas pesadas.

8.- Predicción de la Volatilidad con Volatilidad Muestral.

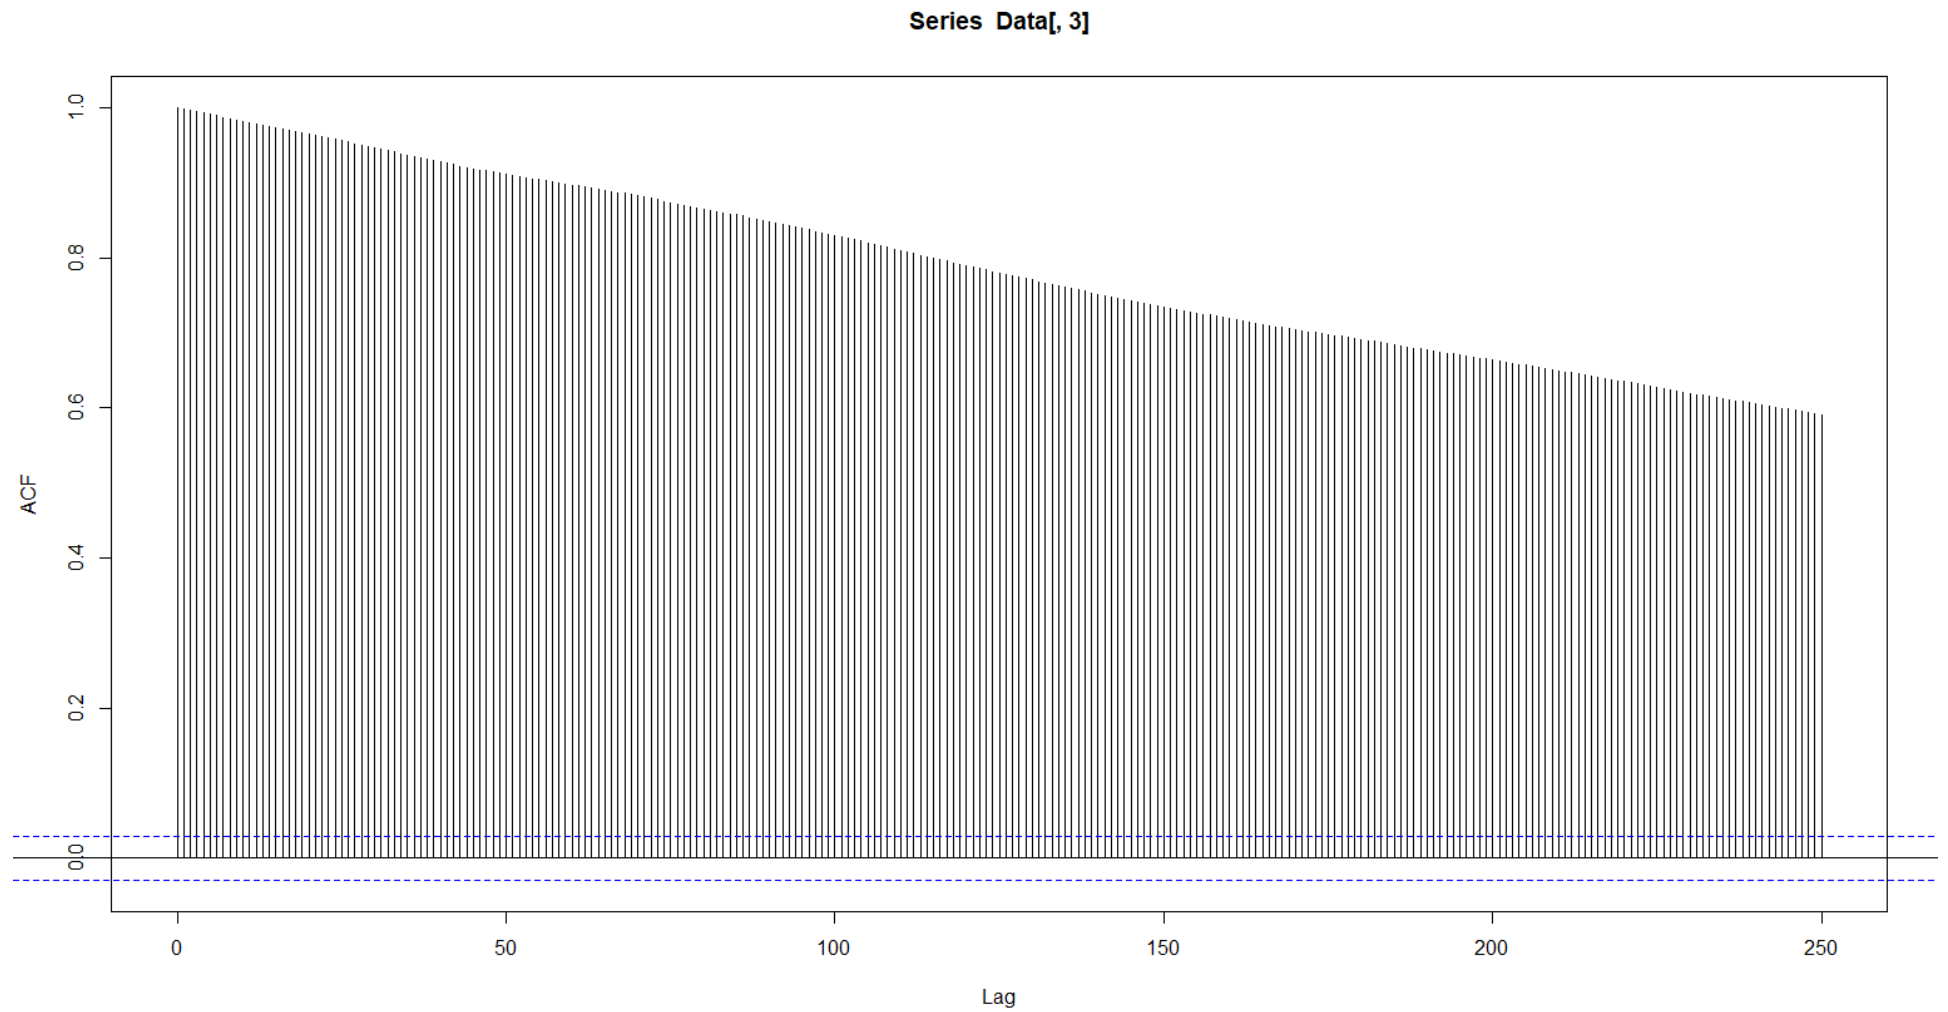
En este apartado se presentan los resultados obtenidos al predecir la volatilidad futura de los rendimientos de SAN.MC utilizando la volatilidad muestral.

El Gráfico 10 muestra la serie temporal de rendimientos de SAN.MC en la parte superior y la volatilidad muestral anualizada calculada en la parte inferior. Las fases de mayor volatilidad coinciden con periodos de alta inestabilidad en el mercado, como las crisis financieras.

9.- Cálculo y Visualización de la Predicción de Volatilidad y Validación mediante Backtesting.

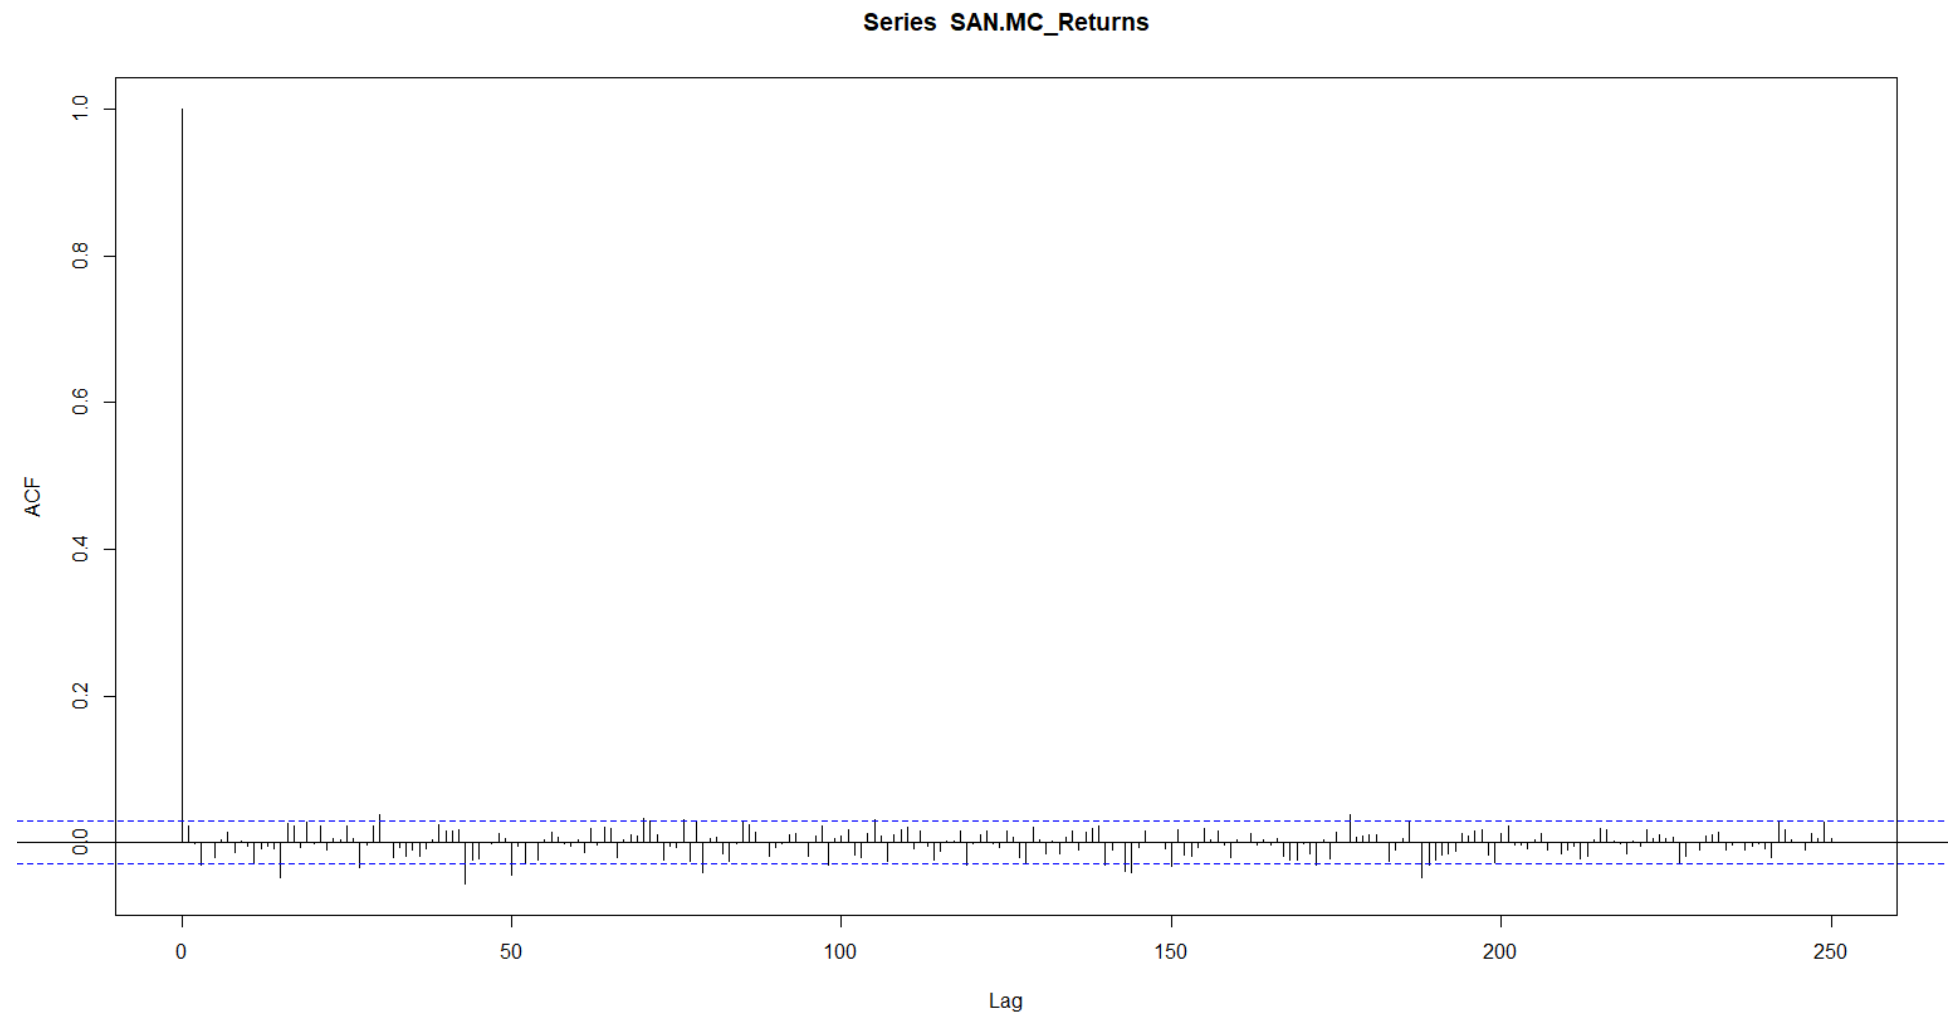
En este apartado, en el gráfico 11, se ha evaluado la capacidad predictiva del modelo de Volatilidad Muestral a través del cálculo y validación del Valor en Riesgo (VaR) para Banco Santander (SAN.MC). Se ha utilizado la volatilidad histórica para estimar el VaR (línea negra) y se compara con la serie temporal de los rendimientos reales (en color naranja), analizando la precisión del modelo en diferentes periodos de tiempo.

Gráfico 6. Autocorrelación de precios de cierre de Banco Santander.



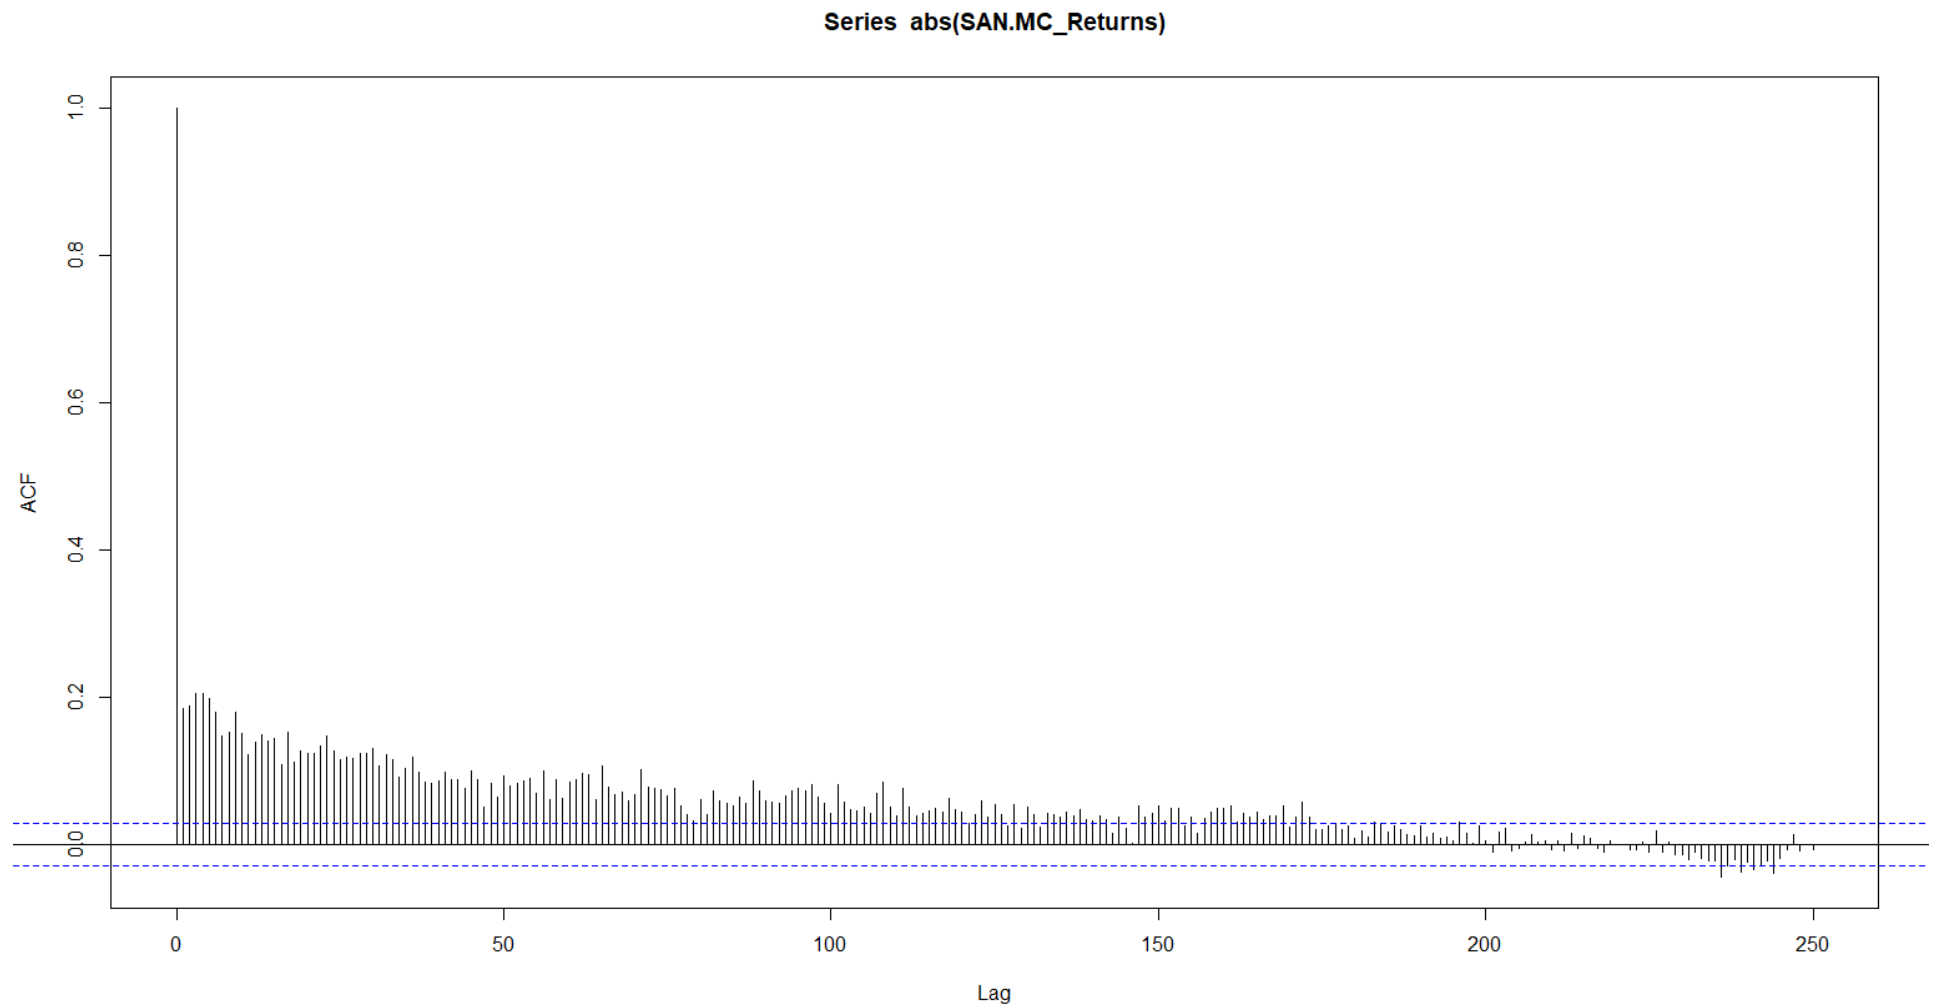
Fuente: Elaboración propia

Gráfico 7. Autocorrelación de los rendimientos de Banco Santander.



Fuente: Elaboración propia

Gráfico 8. Autocorrelación de los rendimientos de SAN.MC en valor absoluto.



Fuente: Elaboración propia

La figura 23 corresponde al proceso de *backtesting*, donde se contabilizó el número de ocasiones en las que el VaR predicho no logró anticipar adecuadamente los rendimientos negativos extremos, es decir, donde los rendimientos reales fueron menores que el VaR predicho. De un total de 4393 observaciones, el modelo falló en 223 ocasiones, lo que representa un 5.07% de error. Esto indica que el modelo tiene una capacidad predictiva moderadamente fiable, con una tasa de error que podría considerarse aceptable dentro de ciertos estándares financieros. El análisis visual muestra que, en periodos de alta volatilidad, como durante la crisis financiera de 2008 y la pandemia de 2020, el modelo predice con menos precisión, lo que se traduce en un mayor número de errores en la predicción del VaR. Esto subraya la importancia de ajustar o complementar el modelo en condiciones de mercado extremas.

Este análisis es un paso fundamental para validar la efectividad del modelo, asegurando que las predicciones de volatilidad se alineen con las realidades del mercado, permitiendo una toma de decisiones más informada y precisa en la gestión de carteras y riesgo.

5.10. Predicción de Volatilidad con Modelo GARCH y Validación mediante backtest


En este apartado, se implementa el modelo GARCH para predecir la volatilidad y calcular el Valor en Riesgo (VaR), seguido de una validación mediante la comparación de las predicciones del VaR con las pérdidas reales observadas.

El gráfico 12 presenta:

- Rendimientos de SAN.MC (en naranja): Estos reflejan las fluctuaciones diarias en los precios de las acciones.
- VaR Predicho con Modelo GARCH (en negro): Este se superpone a los rendimientos, lo que permite identificar visualmente las ocasiones en las que las pérdidas reales han superado las predicciones del VaR.


En el proceso de validación, el modelo GARCH mostró 185 errores sobre un total de 4394 observaciones, lo que resulta en un porcentaje de error del 4,21%. Esto indica que el modelo es bastante preciso, con una mejora marginal respecto al modelo de volatilidad muestral de 0,86%.

Gráfico 9. *Curvas de distribución de rendimientos superpuestas.*



Fuente: Elaboración propia

Gráfico 10. Serie temporal de rendimientos de y la volatilidad muestral anualizada.



Fuente: Elaboración propia

Figura 23. *Backtesting de predicción con volatilidad muestral.*

```
> errores / totales  
[1] 0.05076258  
>  
> errores  
[1] 223  
> totales  
[1] 4393
```


Fuente: Elaboración propia

Figura 24. *Backtesting de predicción con modelo GARCH.*

```
> errores / totales  
[1] 0.04210287  
> errores  
[1] 185  
> totales  
[1] 4394
```


Fuente: Elaboración propia

Gráfico 11. Comparación de rendimientos reales con la predicción del VaR



Fuente: Elaboración propia

Gráfico 12. Rendimientos reales con la predicción VaR a través del GARCH model.



Fuente: Elaboración propia

6.- Conclusiones.

El modelo GARCH parece capturar mejor el comportamiento de la volatilidad, especialmente durante períodos de alta incertidumbre, como los observados en las crisis financieras. Esto se refleja en un menor número de errores y en una mejor alineación entre las predicciones del VaR y las pérdidas reales.

En este trabajo, se han evaluado dos enfoques distintos para predecir la volatilidad y el Valor en Riesgo (VaR) de los rendimientos del Banco Santander: la volatilidad muestral y el modelo GARCH. A lo largo de la metodología y los resultados presentados, se ha realizado un análisis exhaustivo de la precisión y efectividad de ambos métodos, permitiendo extraer conclusiones clave sobre su desempeño y áreas de mejora.

En cuanto a la precisión de las predicciones, el método que se basa en la Volatilidad Muestral, aunque es un método sencillo y ampliamente utilizado, la volatilidad muestral mostró una tasa de error del 5,08% en la predicción del VaR. Este porcentaje de error indica que, si bien es útil para captar la tendencia general de la volatilidad, no siempre logra predecir con precisión los extremos del mercado, especialmente durante períodos de alta volatilidad.

El modelo GARCH, sin embargo, tiene un enfoque que modela la volatilidad de forma dinámica, logró reducir la tasa de error al 4,21%. La capacidad del GARCH para ajustar la volatilidad en función de las condiciones del mercado lo hace más efectivo en la captura de fluctuaciones abruptas y eventos extremos. Además, ha demostrado ser más adaptable a los cambios en las condiciones de mercado. Durante las crisis financieras, por ejemplo, el modelo pudo predecir con mayor precisión los picos en la volatilidad y ajustar el VaR en consecuencia. Esto lo convierte en una herramienta más robusta para la gestión del riesgo en situaciones de alta incertidumbre.

Por otro lado, la volatilidad muestral, al basarse en un enfoque estático, tiende a subestimar la volatilidad futura durante estos períodos críticos, lo que puede llevar a una falsa sensación de seguridad en las estrategias de gestión de riesgos.

Una posible mejora en futuras investigaciones podría consistir en utilizar modelos más sofisticados como EGARCH (GARCH exponencial) o TGARCH (GARCH asimétrico) que permiten capturar mejor las asimetrías y el efecto apalancamiento de la

volatilidad, pudiendo obtener un menor porcentaje de error en la precisión de predicción del VaR.

También se podría realizar un backtesting más riguroso, incluyendo parámetros para poder calcular la magnitud de los errores que se cometen, no solo la cantidad.

Dado que los rendimientos financieros suelen mostrar colas más pesadas de lo que sugiere una distribución normal, se podría explorar el uso de distribuciones alternativas que puedan capturar mejor los datos extremos.

En conclusión, el modelo GARCH ha demostrado ser superior a la volatilidad muestral en la predicción del VaR, especialmente en entornos de mercado volátiles. Sin embargo, la integración de enfoques y la adopción de mejoras técnicas podrían llevar a modelos aún más precisos y efectivos en la gestión del riesgo financiero. La investigación y el desarrollo continuos en esta área son esenciales para enfrentar los desafíos de los mercados financieros en constante evolución.

Bibliografía

- Banco Santander. (s.f.) ¿Qué es el Ibex 35? *Banco Santander*.
<https://www.bancosantander.es/glosario/ibex-35>
- BBVA (s.f.) Qué son las acciones, cómo funcionan y cuál es su origen histórico. *BBVA*.
<https://www.bbva.com/es/salud-financiera/que-son-las-acciones-como-funcionan-y-cual-es-su-origen-historico/>
- Black, F. & Scholes, M. (1973). The Pricing Options and Corporate Liabilities. *The Journal of Political Economy*, 81(3), 637-654.
<http://www.jstor.org/stable/1831029>
- BME (2022). El IBEX35 cumple 30 años y se consolida como marca líder de la economía y las empresas españolas. *BME: Bolsas y Mercados Españoles*. [URL del recurso](#)
- BME (s.f.) ¿Qué es la bolsa? *BME: Bolsas y Mercados Españoles*.
<https://www.bolsasymercados.es/bme-exchange/es/Para-Inversores/Que-es-la-Bolsa>
- Castellanos, E. (2022). El índice IBEX35: Los orígenes y el contexto de la industria. *BME: Bolsas y Mercados Españoles (Newsletter)*.
https://www.meff.es/docs/newsletter/2022/Newsletter_MEFF-Enero2022.pdf
- CMNV (s.f.) Clases de acciones y sus derechos. *Comisión Nacional del Mercado de Valores*. <https://cnmv.es/portal/inversor/acciones.aspx?lang=es>
- Cont, R. (2001). Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative finance*, 1(2), 223.
- Coll, F. (2024). Volatilidad histórica. *Rankia (diccionario)*.
<https://www.rankia.com/diccionario/bolsa/volatilidad-historica>
- Dirección General de Comunicación del Parlamento Europeo. (2020). COVID-19: el plan de la UE para la recuperación económica. *Parlamento europeo*.
<https://www.europarl.europa.eu/topics/es/article/20200513STO79012/covid-19-el-plan-de-la-ue-para-la-recuperacion-economica>
- EFPA (2019) Perfil del inversor español: conservador y localista. *Asesores Financieros EFPA*. <https://www.asesoresfinancierosefpa.es/asesores-opinan/inversor-espanol/>

- Estrategias de Inversión. (s.f.) Volatilidad. *Estrategias de inversión*.
<https://www.estrategiasdeinversion.com/herramientas/diccionario/mercados/volatilidad-t-1522>
- Fama, E. F. (1970). Efficient capital markets. *Journal of finance*, 25(2), 383-417.
- Gómez Yubero, M.J. & Palomero Aguilar, M. (2024). Análisis comparado de la representatividad, metodología de cálculo y transparencia del Ibex35. *Boletín de la CNMV*. Mayo 2024, pp. 123-166. URL del recurso:
https://www.cnmv.es/DocPortal/Benchmark/Art_Ibex35.pdf
- Hull, J. C. (2015). *Options, futures, and other derivatives*. Pearson Education India.
- INVERCO (2024). *Estructura del ahorro financiero de las familias (% sobre total)*.
<https://www.inverco.es/archivosdb/2403-ahorro-financiero-de-las-familias-espanolas.pdf>
- Maddala, G. S. (1996) *Introducción a la econometría*. México: Prentice Hall.
- Malkiel, B. (2016). *Un Paseo Aleatorio por Wall Street*. Alianza.
- Sevilla, A. (2019). Modelo GARCH. *Economipedia*.
<https://economipedia.com/definiciones/modelo-garch.html>
- Torres, R. & Fernández, M.J. (2022). La economía española, de la pandemia a la crisis energética. *Papeles de economía española* (173), 2-15. https://www.funcas.es/wp-content/uploads/2022/11/PEE-173_Torres-Fernandez.pdf
- Vázquez Vicente, G. (2007). La crisis del Sistema Monetario Europeo (1992-1993): ¿crisis financiera o crisis de políticas de cooperación monetaria? *Revista universitaria europea* (6), 33-82. [10.13140/RG.2.2.18763.18723](https://doi.org/10.13140/RG.2.2.18763.18723)

Anexo 1. Resultados de la predicción de volatilidad de Iberdrola.

Figura 25. Backtesting de predicción con modelo GARCH (Iberdrola).

```
> errores / totales  
[1] 0.04276615  
> errores  
[1] 188  
>  
> totales  
[1] 4396
```

Fuente: Elaboración propia

Figura 26. Backtesting de predicción con volatilidad muestral (Iberdrola).

```
> errores / totales  
[1] 0.04913558  
>  
> errores  
[1] 216  
> totales  
[1] 4396
```

Fuente: Elaboración propia

Anexo 2. Resultados de la predicción de volatilidad de Inditex.

Figura 27. Backtesting de predicción con volatilidad muestral (Inditex).

```
> errores / totales  
[1] 0.04595086  
>  
> errores  
[1] 202  
> totales  
[1] 4396
```

Fuente: Elaboración propia

Figura 28. Backtesting de predicción con modelo GARCH (Inditex).

```
> errores / totales  
[1] 0.04026388  
> errores  
[1] 177  
>  
> totales  
[1] 4396
```

Fuente: Elaboración propia