

Trabajo Fin de Grado  
Ingeniería en Tecnologías Industriales

Implementación de SVR-GARCH en la gestión del  
riesgo en pequeñas y medianas empresas

Autor: Ernesto Millán Conejero

Tutor: José Miguel León Blanco

Dpto. de Organización Industrial y Gestión de Empresas I  
Escuela Técnica Superior de Ingeniería  
Universidad de Sevilla

Sevilla, 2023





Trabajo Fin de Grado  
Ingeniería en Tecnologías Industriales

# **Implementación de SVR-GARCH en la gestión del riesgo en pequeñas y medianas empresas**

Autor:

Ernesto Millán Conejero

Tutor:

José Miguel León Blanco

Profesor Contratado Doctor

Dpto. de Organización Industrial y Gestión de Empresas I

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2023



Trabajo Fin de Grado: Implementación de SVR-GARCH en la gestión del riesgo en pequeñas y medianas empresas

Autor: Ernesto Millán Conejero

Tutor: José Miguel León Blanco

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2023

El Secretario del Tribunal

*A mi familia*

*A mis maestros*





# Agradecimientos

---

Estos agradecimientos se van a dejar a muchas personas, pero quiero comenzar con mis padres, Ernesto y Carmina y mis hermanos Jaime y Miguel, que han sido los que han confiado en mí desde que empecé y pese a todos estos años, nunca dudaron de mi capacidad, dándome todas las herramientas necesarias para nunca rendirme.

Gracias también a mis abuelas Teresa y Manuela que me apoyaron en el inicio de mi carrera y me han acompañado en este camino, y aunque una de ellas no pueda leer hoy estas palabras, ha sido indispensable para mi formación tanto académica como personal.

Y gracias a ti, Claudia. Estos últimos años me has estado apoyando y nunca me has dejado caer ni rendirme, sin ti no estaría hoy escribiendo estos agradecimientos.

También quiero expresar toda mi gratitud a mi tutor José Miguel, que pese a haber sido un año difícil, siempre ha estado comprometido y me ha guiado y aconsejado durante todo este trabajo.

Esta carrera ha sido larga y dura, pero nunca he dejado de pedalear.

*Ernesto Millán Conejero*

*Sevilla, 2023*



# Resumen

---

La gestión de riesgos financieros es esencial para todas las empresas. Una de las variables fundamentales para la gestión del riesgo es la volatilidad, que tradicionalmente se ha modelado mediante los modelos ARCH (Modelos Autorregresivos de Heteroscedasticidad Condicionada) y GARCH (Modelos Generalizados de Heteroscedasticidad Condicionada). Sin embargo, estos métodos presentan limitaciones debido a ciertos aspectos y se necesitan nuevos métodos para el modelaje. Por tanto, en este estudio se introduce el uso del modelo SVR-GARCH (Maquinas de Soporte Vectorial con Generalización de Modelos Autorregresivos de Heteroscedasticidad Condicionada) como una alternativa para modelar la volatilidad de los mercados.

Se integra entonces el modelo SVR-GARCH en la teoría de Black-Scholes descrita por Black et al. (1973) para la cobertura de riesgos y valoración de opciones, mediante la predicción de la volatilidad. De la misma manera se incorporará esta misma predicción gracias al modelo SVR-GARCH en la Teoría de la Cartera moderna de Elton (1995), que mejora la Teoría de Markowitz descrita por Markowitz (1952). Con esto se busca mejorar significativamente la efectividad y eficiencia en la gestión del riesgo mediante la predicción de la volatilidad futura de activos financieros que en este estudio serán ETF (Exchange Traded Funds) debido a que son herramientas financieras que hacen un seguimiento a una amplia variedad de mercados, monedas, sectores...

Estos hallazgos podrán servir de ayuda para los responsables de la toma de decisiones de pequeñas y medianas empresas (PYMES), proporcionándoles una metodología más precisa y fiable para la valoración de riesgos y la optimización de una cartera con activos que sigan en mercado al que pertenece la empresa que se quiera gestionar.

**Palabras Clave:** machine learning, cobertura de riesgo, pymes, volatilidad, SVR-GARCH, GARCH, ARCH, Markowitz, teoría de cartera moderna, Black-Scholes, riesgo, ETF-



# Abstract

---

Financial risk management is essential for all companies. One of the key variables for risk management is volatility, which has traditionally been modelled using ARCH (Autoregressive Conditional Heteroscedasticity Models) and GARCH (Generalised Conditional Heteroscedasticity Models) models. However, these methods have limitations due to certain aspects and new methods for modelling are needed. Therefore, in this study, the use of the SVR-GARCH (Support Vector Machines with Generalisation of Conditional Heteroscedasticity Autoregressive Models) model is introduced as an alternative for modelling market volatility.

The SVR-GARCH model is then integrated into the Black-Scholes theory described by Black et al. (1973) for risk hedging and option pricing, by predicting volatility. In the same way, this same prediction will be incorporated thanks to the SVR-GARCH model in the modern Portfolio Theory of Elton (1995), which improves the Markowitz Theory described by Markowitz (1952). This seeks to significantly improve the effectiveness and efficiency of risk management by predicting the future volatility of financial assets, which in this study will be ETFs (Exchange Traded Funds) because they are financial tools that track a wide variety of markets, currencies, sectors, etc....

These findings may help decision-makers of small and medium-sized enterprises (SMEs), providing them with a more accurate and reliable methodology for risk assessment and the optimisation of a portfolio with assets that follow the market to which the company to be managed belongs.

**Keywords:** machine learning, risk hedging, SMEs, volatility, SVR-GARCH, GARCH, ARCH, Markowitz, modern portfolio theory, Black-Scholes, risk, ETFs.

# Índice

---

<b>Agradecimientos</b>	<b>ix</b>
<b>Resumen</b>	<b>xi</b>
<b>Abstract</b>	<b>xiii</b>
<b>Índice</b>	<b>xiv</b>
<b>Índice de Tablas</b>	<b>xvi</b>
<b>Índice de Figuras</b>	<b>xviii</b>
<b>Notación</b>	<b>xix</b>
<b>1 Introducción</b>	<b>1</b>
1.1 <i>Objetivos Generales</i>	2
1.2 <i>Objetivos Específicos</i>	3
<b>2 Marco Teórico</b>	<b>4</b>
2.1 <i>La inflación: causas y cómo se gestionan</i>	4
2.2 <i>Riesgo y su cobertura</i>	5
2.3 <i>Mecanismos tradicionales de cobertura ante la inflación</i>	6
2.4 <i>La volatilidad</i>	6
2.5 <i>Modelos de volatilidad</i>	7
2.5.1 Modelos ARCH	7
2.5.2 Modelos GARCH	8
2.6 <i>Introducción al Machine Learning</i>	9
2.6.1 Aplicaciones en Finanzas	9
2.6.2 Support Vector Regression (SVR): conceptos y aplicaciones en la gestión del riesgo	10
2.7 <i>Opciones y el modelo de Black-Scholes</i>	12
2.8 <i>Teoría de la cartera moderna (MTP) para la cobertura</i>	13
<b>3 Metodología</b>	<b>15</b>
3.1 <i>Recopilación de datos</i>	15
3.1.1 Fuentes de datos	15
3.1.2 Selección de los datos	16
3.1.3 Preprocesamiento	20
3.1.4 Bibliotecas utilizadas	20
3.2 <i>Modelado de volatilidad con ARCH y GARCH</i>	21
3.2.1 Modelo ARCH	21
3.2.2 Modelo GARCH	23
3.3 <i>Modelado de la volatilidad con SVR</i>	25
3.3.1 Preparación de Datos y Configuración de Modelos SVR	25
3.3.2 Modelo SVR-GARCH (Lineal)	26
3.3.3 Modelo SVR-GARCH (RBF)	26

3.3.4	Modelo SVR-GARCH (Polinomial)	27
3.4	<i>Aplicación en cobertura de riesgo usando Black-Scholes</i>	27
3.4.1	Importación de módulos y bibliotecas	28
3.4.2	Implementación modelo Black-Scholes	28
3.4.3	Implementación función predicción tipo de opción	28
3.4.4	Introducción de datos y pago por cobertura	29
3.5	<i>Cálculo de la volatilidad mejorado cartera eficiente con Montecarlo</i>	29
3.5.1	Importación de bibliotecas	29
3.5.2	Descarga y preparación de datos	30
3.5.3	Cálculo de matrices de covarianza mensuales	30
3.5.4	Simulación Monte Carlo y visualización	30
3.5.5	Función para mostrar información de una cartera	30
3.5.6	Visualización de la eficiencia de las carteras y puntos especiales	30
3.5.7	Función estimación con SVR de la volatilidad esperada	30
<b>4</b>	<b>Resultados</b>	<b>33</b>
4.1	<i>Desempeño SVR en mejora de ARCH y GARCH</i>	33
4.1.1	Empresa A	33
4.1.2	Empresa B	38
4.2	<i>Resultados de SVR en la cobertura con opciones y Black-Scholes</i>	43
4.2.1	Empresa A	44
4.2.2	Empresa B	44
4.2.3	Conclusiones	45
4.3	<i>Resultado introducción de la volatilidad predicha en la teoría de cartera moderna</i>	45
4.3.1	Empresa A	45
4.3.2	Empresa B	47
<b>5</b>	<b>Discusión</b>	<b>49</b>
5.1	<i>Conclusiones</i>	49
5.2	<i>Limitaciones del enfoque propuesto</i>	49
<b>6</b>	<b>Líneas futuras de investigación y ampliación</b>	<b>50</b>
	<b>Referencias</b>	<b>51</b>

# ÍNDICE DE TABLAS

---

Tabla 4-1: Resultados ARCH(1), empresa A	34
Tabla 4-2: Resultados ARCH óptimo, empresa A	34
Tabla 4-3: Resultados GARCH(1), empresa A	35
Tabla 4-4: Resultados ARCH(1), empresa B	39
Tabla 4-5: Resultados ARCH óptimo, empresa B	39
Tabla 4-6: Resultados GARCH óptimo, empresa B	41
Tabla 4-7: Datos introducidos Black-Scholes, empresa A	44
Tabla 4-8: Resultados obtenidos Black-Scholes, empresa A	44
Tabla 4-9: Datos introducidos Black-Scholes, empresa B	45
Tabla 4-10: Resultados obtenidos Black-Scholes, empresa B	45
Tabla 4-11: Datos para incorporar a TCM, empresa A	46





# ÍNDICE DE FIGURAS

---

Ilustración 1-1: Tasa inflación (EUROSTAT)	1
Ilustración 1-2: Mapa inflación Europa (EUROSTAT)	2
Ilustración 3-1: Rentabilidad acumulada ETFs A	16
Ilustración 3-2: % Activos en ETF (DBA)	17
Ilustración 3-3: % Activos en ETF (TAGS)	17
Ilustración 3-4: Rentabilidad TOP 3 ETFs IA	18
Ilustración 3-5: % Activos en ETF (BOTZ)	18
Ilustración 3-6: % Activos en ETF (THNQ)	19
Ilustración 3-7: % Activos en ETF (AIQ)	19
Ilustración 3-8: Estructura ARCH	21
Ilustración 3-9: Estructura GARCH	23
Ilustración 3-10: Estructura SVR	25
Ilustración 3-11: Estructura Black-Scholes	28
Ilustración 3-12: Estructura Cartera Eficiente con Montecarlo	29
Gráfica 2-1: Número de sociedades cerradas en los últimos 5 años	5
Gráfica 4-1: Visualización resultados ARCH óptimo, empresa A	35
Gráfica 4-2: Visualización resultados GARCH óptimo, empresa A	36
Gráfica 4-3: Visualización resultados SRV-GARCH lineal, empresa A	37
Gráfica 4-4: Visualización resultados SRV-GARCH rbf, empresa A	37
Gráfica 4-5: Visualización resultados SRV-GARCH polinomial, empresa A	38
Gráfica 4-6: Visualización ARCH óptimo, empresa B	40
Gráfica 4-7: Visualización GARCH óptimo, empresa B	41
Gráfica 4-8: Visualización resultados SRV-GARCH lineal, empresa B	42
Gráfica 4-9: Visualización resultados SRV-GARCH rbf, empresa B	42
Gráfica 4-10: Visualización resultados SRV-GARCH polinomial, empresa B	43
Gráfica 4-11: Montecarlo empresa A	46
Gráfica 4-12: Montecarlo empresa B	47
Gráfica 4-13: Datos a introducir en Markowitz, empresa B	47

# Notación

---

$r_t$	Rentabilidad de t
$\sigma_t^2$	Varianza de t
$w$	Vector de pesos
$C$	Parámetro de regularización
$x_i$ y $y_i$	Características y etiquetas de los datos
$\epsilon$	Margen de tolerancia para el error
$\zeta_i$	Variable de holgura
$b$	Término de sesgo
$C$	Precio de opción de compra
$P$	Precio de opción de venta
$r$	Tasa de interés libre de riesgo
$N()$	Función de distribución acumulada a la distribución normal
$X$	Valor actual de ejercicio de la opción
$e$	Número e
$\ln$	Logaritmo neperiano
$\rho_{ij}$	Coefficiente correlación entre activos i y j
$\Sigma$	Sumatorio
$\mu$	Vector de rendimientos esperados
$\lambda$	Parámetro aversión al riesgo del inversor



# 1 INTRODUCCIÓN

“Si no te gustan los riesgos, deberías salir corriendo de los negocios”

-Ray Kroc -

Para muchas empresas existen riesgos en la actividad diaria que les hacen enfrentarse a diversos desafíos diarios en su día a día de los que a veces es complicado escapar. Los riesgos asociados a cambios en precios de activos, inflación, tasas de interés y volatilidad del mercado pueden tener un impacto significativo en las PYMES, especialmente cuando no se cuenta con recursos ni la experiencia suficiente para implementar estrategias de cobertura que permitan mitigar los efectos adversos de los posibles riesgos a los que se enfrenta una empresa en su vida operativa.

El presente proyecto busca proponer un enfoque innovador para ayudar a pequeñas y medianas empresas a gestionar y mitigar su riesgo financiero mediante la mejora de métodos tradicionales de cobertura de riesgos mediante modelos de *Machine Learning*, se van a usar versiones tanto de cartera eficiente como de Black-Scholes basadas en esta tecnología. Esta cobertura se producirá mediante ETFs, lo que ayudará a tener un amplio abanico de posibilidades y opciones de cobertura.

En España y en general en todo el mundo se está atravesando por una crisis inflacionaria común que afecta de manera similar a personas y empresas, esto es debido en parte a la inestabilidad global tanto en salud pública como en conflictos bélicos, que producen una falta de ciertos suministros que desencadena la subida de la mayoría de los bienes.

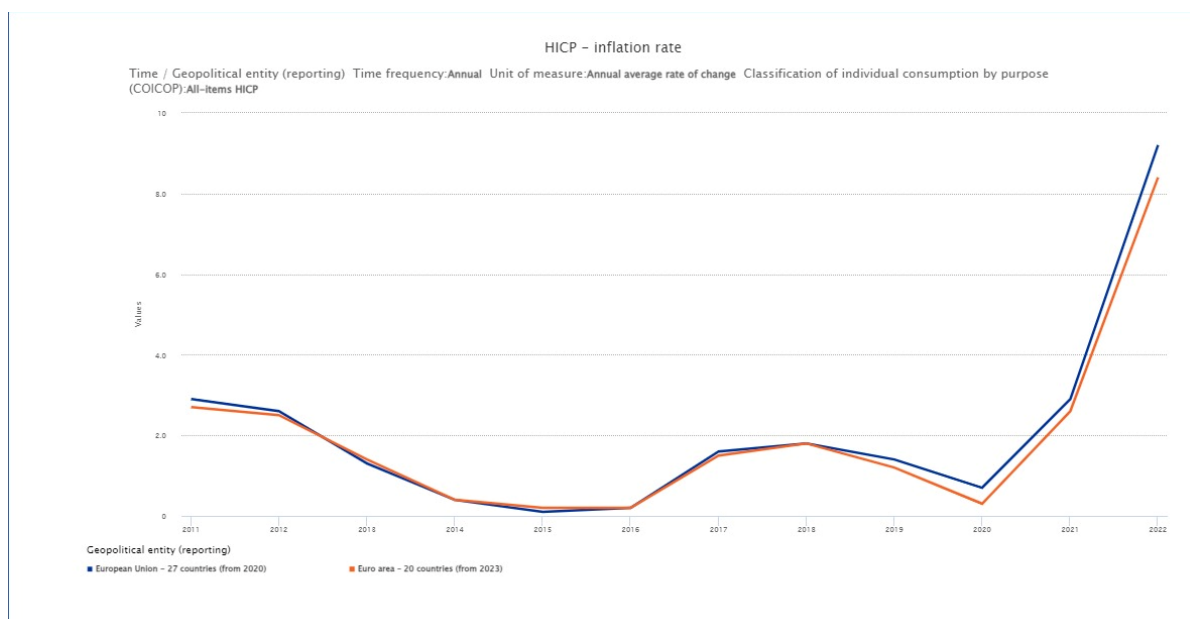


Ilustración 1-1: Tasa inflación (EUROSTAT)

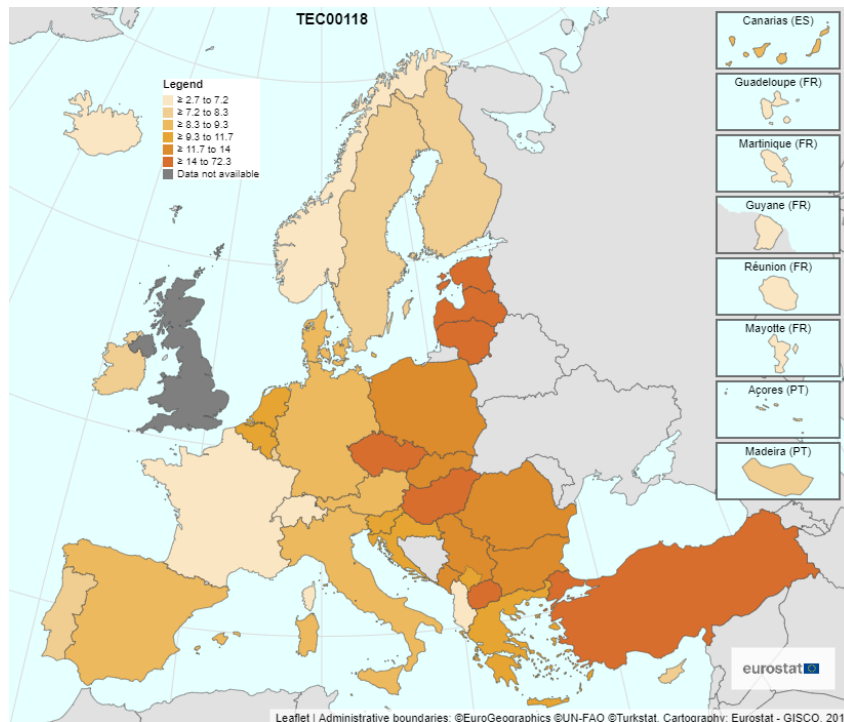


Ilustración 1-2: Mapa inflación Europa (EUROSTAT)

De esta manera en este proyecto se tratará de mitigar los riesgos que llevan consigo este tipo de problemas, que podrían causar en muchos casos incluso el cierre de muchos negocios, para ellos se utilizará la tecnología *Machine Learning*, que valdrá de herramienta fundamental a la hora de tomar decisiones operacionales o financieras.

Las pequeñas y medianas empresas en España constituyen el 99,8% del tejido empresarial del país. Este tipo de empresas en su mayoría no pueden asumir gastos que las grandes empresas contra las que compiten sí se pueden permitir, como un departamento financiero que tenga en cuenta los riesgos a los que se exponen en el día a día.

## 1.1 Objetivos Generales

Como objetivo central de esta investigación se tendrá el obtener un respaldo sólido sobre la relación entre el riesgo y las operaciones financieras de las pequeñas y medianas empresas (pymes), explorando así la utilidad de nuevas técnicas avanzadas como el *Machine Learning* a la hora de afrontar esta correlación y que pueda servir de herramienta esencial para predecir y cubrir los riesgos que puedan surgir de las fluctuaciones de tipo inflacionaria u otra clase. Las pymes no siempre pueden optar a tener recursos suficientes para llevar a cabo coberturas de este tipo, al igual que la mayoría carecen de la misma forma de un colchón financiero que sí pueden tener las grandes corporaciones con las que compiten en muchos sectores empresariales. Por lo tanto, es importante adquirir las herramientas necesarias y hacer estrategias que permitan anticipar y reaccionar de forma adecuada a este problema.

Según el BCE (Banco Central Europeo), en una economía de mercado los precios tanto de bienes como de servicios están sujetos a posibles cambios, de los cuales algunos de ellos subirán y otros bajarán, y existe inflación cuando se produce un aumento general de los precios, no solo de los artículos aislados, que da como resultado que por cada euro que se tiene puedan adquirirse hoy en día menos bienes que ayer. Es decir, la inflación reduce el valor de la moneda en el tiempo. Con esto se observa que la pérdida de valor de la moneda puede llevar a grandes repercusiones en las finanzas de una empresa, en especial en las pymes, Mbah (2023).

Por lo tanto, un mal tratamiento o gestión de la inflación puede llevarlas a situaciones financieras complejas.

Debido a la necesidad de tener que lidiar con este problema surgen diversas tecnologías, entre ellas el *Machine Learning*. Como explica Cárdenas (2018), el *Machine Learning* se convirtió desde su inicio en un pilar fundamental a la hora de tratar datos y ha sido sumamente importante en campos como el informático, de la salud, corporativo, de transporte y recientemente en la progresión indiscutible de tecnologías muy sofisticadas como la inteligencia artificial. Estos modelos se pueden entrenar para hacer predicciones más fiables sobre el comportamiento de datos en el futuro basándose en datos históricos que se usan de referencia para entrenar el modelo.

Así, como propósito general evaluaremos la precisión obtenida y la aplicación de diferentes técnicas de *Machine Learning* en la predicción de variables útiles para ayudar a las empresas a tener mecanismos de cobertura. Con esto se buscará proporcionar una herramienta y también ofrecer a las pymes una comprensión amplia de la cobertura del riesgo y el problema que puede suponer factores como la inflación en las finanzas de las pymes.

La meta por tanto será dar a las empresas un marco de trabajo basado en *Machine Learning* que les permita anticipar, entender y reaccionar promoviendo un crecimiento estable a través de las posibles variaciones inevitables de la economía.

## 1.2 Objetivos Específicos

En esta investigación se tienen varios ejes directores que llevarán a una resolución personalizada dependiendo del sector de la empresa estudiada. El cálculo de la volatilidad prevista y herramientas financieras consolidadas como la teoría de la cartera moderna y la ecuación de Black-Scholes serán imprescindibles a la hora de llevar a cabo este trabajo.

Los propietarios querrán cubrir el riesgo de inflación que recae sobre su empresa, y se le intentarán dar las herramientas necesarias para la mejora de esta cobertura mediante tecnología *Machine Learning*.

La investigación se centrará en construir modelos lo más robustos posibles de *Machine Learning*. Estos modelos, alimentados por datos pasados, buscarán prever con precisión la volatilidad de activos financieros, en esta investigación se utilizarán ETFs. Estos ETFs hacen un seguimiento de ciertos mercados, por lo que se utilizarán para hacer un seguimiento preciso del mercado sobre el que se está trabajando. Cada uno de los modelos propuestos será evaluado y se buscará maximizar la fiabilidad de los resultados para su futura utilización en la cobertura de riesgos. Tras conseguir estas predicciones, se realizará un proceso de integración en la teoría de Markowitz (1952) o más bien con la base de esta cartera intentaremos aplicar nuevas teorías mejoradas con las técnicas actuales. Como objetivo de esta cartera se intentará ajustar y recalibrar las inversiones para obtener una combinación óptima de activos que minimicen el riesgo y potencien los retornos.

A continuación, se aprovecharán estos resultados para incorporarlos a la ecuación de Black-Scholes propuesta por Black et al. (1973). Esto permitirá a las pequeñas y medianas empresas determinar con un menor margen de error el valor de estas opciones, dando así una herramienta valiosa para las decisiones en cuestión a la cobertura. Con todo esto se diseñarán estrategias específicas de cobertura. Con estas estrategias culminará el trabajo, dando así a las pymes una guía práctica y tangible para protegerse contra fluctuaciones inflacionarias.

## 2 MARCO TEÓRICO

---

*La única ventaja de jugar con fuego es que aprende uno a no quemarse.*

*-Oscar Wilde-*

### 2.1 La inflación: causas y cómo se gestionan

**T**ras la definición del Banco Central Europeo, en una economía de mercado los precios tanto de bienes como de servicios están sujetos a posibles cambios, de los cuales algunos de ellos subirán y otros bajarán. Existe inflación cuando se produce un aumento general de los precios, no solo de los artículos aislados, que da como resultado que por cada euro que se tiene puedan adquirirse hoy en día menos bienes que ayer. Es decir, la inflación reduce el valor de la moneda en el tiempo. Para medir esta inflación la mayoría de los países utilizan un índice común, el Índice de Precios al Consumidor (IPC). Este índice evalúa el aumento de precios de una cesta básica de bienes que suele ser representativa del consumo medio de los hogares.

La inflación no es algo nuevo, a lo largo de los siglos se han vivido procesos inflacionarios, como cuenta Harl (1996) sobre la antigua Roma, la cual experimentó una inflación significativa, debido en parte a la disminución del contenido de plata en las monedas, además del ingente gasto en conflictos bélicos. Más adelante, en la edad media como cuenta Hamilton (1934) volvió a ocurrir, en este caso con los precios de los productos importados de América por el Reino de España. adentrándonos más en casos más próximos a la actualidad, en el siglo XX tras la Primera Guerra Mundial Alemania experimentó una crisis inflacionaria sin precedentes en el país, cuya causa fue de forma general la sobreimpresión de dinero para pagar las reparaciones de las guerras tras el tratado de Versalles según Ferguson (2000). Ya en el siglo XXI se tienen ejemplos claros de este suceso, como por ejemplo pasó tanto en Venezuela como en Argentina, descritos en las publicaciones de Gregory et al. (2020) y Salas (2015) respectivamente. La historia siempre da pistas de las causas y repercusiones que un problema como este puede tener en la sociedad.


Las causas fundamentales de la inflación están descritas por Mario Alberto et al. (2002) entre otros muchos artículos, páginas web y libros como Blanchard (2017), de entre estas informaciones se van a resumir en las siguientes:

- Inflación por demanda: cuando no hay una demanda excesiva si lo comparamos con la oferta disponible de bienes, las políticas gubernamentales como la impresión de dinero o reducir las tasas de interés puede ir en contra de la rebaja de esta tasa de inflación.
- Inflación por costes: este tipo de inflación surge debido al aumento de los costes de producción. Incrementar salarios sin aumento de productividad, o aumento del coste de las materias primas utilizadas en los procesos de producción. Estos costes acaban repercutiéndose en el consumidor final a través de precios más altos, Gómez (2018).
- Inflación estructurada: algunas veces, los fallos en la estructura económica de un país se pueden transformar en ineficiencias en sectores específicos. Problemas de operatividad de empresas, monopolios o regulaciones son los problemas a los que suelen hacer frente.

Tras esta aproximación al concepto de inflación nos podemos hacer una idea más concreta de los problemas que puede acarrear a la población general y a las empresas en particular, por lo tanto, se entiende que es un problema



que se necesita medir e intentar paliar en la medida de lo posible debido a que las consecuencias que esto puede tener en las empresas, que pueden llevar incluso a su cierre definitivo como comenta G. V. D. (2023) en su artículo en el ABC.



Gráfica 2-1: Número de sociedades cerradas en los últimos 5 años

## 2.2 Riesgo y su cobertura

Según la Norma Técnica ISO 31000:2018, el riesgo es “el efecto de la incertidumbre sobre los objetivos”. Esta definición relaciona el riesgo directamente con la incertidumbre e indica que cualquier situación cuyo resultado sea incierto y afecte unos objetivos previamente establecidos por la organización se considera un riesgo.

La Norma ISO 31000 no establece que las consecuencias de un riesgo sean necesariamente negativas, únicamente relaciona el riesgo con la incertidumbre de que ocurra un evento y los efectos que conlleva, sin embargo, existen definiciones que sí asocian el riesgo con consecuencias negativas.

El Banco Mundial define el riesgo como la "probabilidad de sufrir pérdidas económicas y daños" debido a la exposición a eventos adversos. Esta definición resalta la idea de que el riesgo implica la posibilidad de enfrentar consecuencias negativas o pérdidas, ya sea en términos económicos, sociales o de otro tipo, debido a eventos imprevistos o adversos. El Banco Mundial se centra en la noción de que la incertidumbre y la exposición a eventos negativos son componentes esenciales del riesgo.

Como se puede comprobar la gran diferencia entre ambas definiciones es que en la definición de la ISO 31000, el riesgo puede ser visto tanto como una oportunidad como una amenaza. En este trabajo tomará la definición propuesta por la norma ISO 31000, por la cual se tendrán en cuenta los efectos positivos que se podrán sacar del riesgo.

Lidiar con el riesgo puede ser uno de los mayores problemas a los que se enfrenta una pyme a la hora de afrontar una inversión de cualquier tipo o incluso en el simple hecho de su ejercicio como empresa, en el día a día en aspectos como la inflación, regulaciones estatales y un innumerable conjunto de variables más puede llevar a una empresa a unas pérdidas inasumibles en un medio-largo plazo. Actuar sobre ellas de una forma organizada y proactiva puede llevar a mitigar los efectos de estas variables.

Se define la cobertura de riesgos como una estrategia de inversión que permite minimizar, reemplazar o suprimir un riesgo de naturaleza financiera. La cobertura de riesgos financieros es una herramienta indispensable para cualquier empresa, sirve para mitigar las consecuencias de una acción negativa sobre una empresa, persona o bien. La cobertura de riesgos más tratada en la sociedad actual son los seguros, ya sea de vehículo, casa, vida... Debido a la importancia de esta acción se debe ser cuidadoso a la hora de tratar con ello, teniendo en cuenta los costes y beneficios que esto pueda acarrear. Cubrir riesgos es un movimiento estratégico indispensable en la actualidad, y los métodos más importantes a la hora de llevar a cabo esta cobertura se dividirán en los siguientes:

- Opciones
- Futuros
- Swaps

Nuestro proyecto se centrará en las opciones, ya que permitirán una mayor flexibilidad, control y potencial de rentabilidad en comparación con las otras. Con las opciones tenemos el derecho, que no obligación de comprar o vender el activo. En cambio, en los futuros y los swaps se tendrá la obligación de ejecutar la orden de compra o venta, lo que podría conllevar a unas pérdidas imprevistas. Las opciones también son más sencillas a la hora de personalizar específicamente a un perfil de riesgo lo que en este caso será algo muy a tener en cuenta, y aunque los futuros y los swaps también se pueden ajustar, son menos flexibles a esto. Además, aun teniendo la prima en las opciones, esta puede ser menor al riesgo asumido por parte de los otros dos instrumentos de cobertura, los cuales pueden llegar a tener pérdidas ilimitadas como apunta Fernández (2008).

### 2.3 Mecanismos tradicionales de cobertura ante la inflación

La gestión de la inflación es uno de los puntos clave en las políticas de los estados en los últimos años. Los bancos centrales son los principales promotores de estas medidas, sin embargo, las empresas grandes toman medidas para paliar sus efectos.

Las principales herramientas de las que se dispone hoy en día para la cobertura de los riesgos asumidos por la subida de los precios son:

- Ajustes de los precios frecuentes: las empresas aumentan los precios de los productos para poder mantener sus márgenes. Puede incrementar la inflación de manera más fuerte por la acumulación de subidas sin fin.
- Cobertura en moneda extranjera: si una empresa espera que su moneda local se deprecie debido a la inflación, se podrían tomar posiciones en monedas extranjeras más estables para protegerse contra esa devaluación.
- Contrato de Reajuste: algunas empresas establecen contratos con cláusulas de reajustes basados en índices de inflación, garantizando que los precios de los bienes o servicios que venden aumenten junto a la inflación.
- Inversiones en activos reales: las inversiones en activos tangibles como bienes raíces, maquinaria o *commodities* pueden actuar como refugio contra la inflación, ya que estos activos tienden a apreciarse con la inflación.
- Diversificación Geográfica: afecta en mayor medida a las grandes empresas que tienen la posibilidad de moverse a otros mercados que quizás no sufran de una manera tan acusada el proceso inflacionario.
- Mejora de procesos: ya sea mejorar tanto la estructura de costos o el inventario, ambos nos darían mejoras a la hora de pasar por un proceso inflacionario. Se pueden mejorar las estructuras logísticas, renegociar contratos, automatizar procesos, para contrarrestar el impacto de los costos crecientes.
- Emisión de deuda a tasa fija: en un ambiente inflacionario, el valor real de la deuda tiende a disminuir, lo que beneficia a quienes deben dinero. Al emitir deuda a tasas fijas, las empresas pueden beneficiarse al pagar menos en términos reales en el futuro.

### 2.4 La volatilidad

La volatilidad es una medida de tipo estadística que indica la variabilidad o dispersión de los retornos de un activo financiero durante un periodo determinado, Pérez Rodríguez (2016). Por tanto, representa cuánto fluctúa el precio de un activo en un periodo determinado. Esto se utiliza para indicar el riesgo asociado con un activo o

cartera, ya que una mayor volatilidad implica una mayor incertidumbre en retornos futuros.

Es importante saber diferenciar los distintos tipos de volatilidad para no equivocarnos a la hora de definirlos, y de aquí en adelante se tenga la definición clara.

- **Volatilidad Histórica:** para calcularla se utilizan los datos antiguos que se tengan disponibles y con ella se refleja la variabilidad de los retornos de un activo en el pasado. Este tipo de volatilidad se utiliza para ver cómo ha fluctuado el precio de un activo en el pasado, pero no se puede sacar de ella ningún dato futuro.
- **Volatilidad Implícita:** va a resultar importante en nuestro estudio y se llega con los datos actuales. Es una representación de las expectativas del mercado sobre la futura volatilidad del activo del que se habla. Con la ecuación propuesta por Black-Scholes se puede obtener esta volatilidad Black et al., (1973).
- **Volatilidad Realizada/Observada:** esta volatilidad se refiere a la volatilidad observada durante un tiempo en específico, esta volatilidad no se basa en supuestos, sino en datos reales.
- **Volatilidad Local:** este es un concepto utilizado en la valoración de derivados y se refiere a una estructura de volatilidad que varía respecto al precio del activo subyacente.

La volatilidad es un concepto fundamental en las finanzas en general y en la cobertura del riesgo en particular. Comprender la volatilidad es esencial, como se ha comentado, para poder gestionar los riesgos financieros a los que se puede enfrentar una pyme.

## 2.5 Modelos de volatilidad

Los modelos de volatilidad se han utilizado como herramienta a la hora de hallar la volatilidad de una serie de tiempo financiera. Con los conceptos antes vistos, podemos ver la volatilidad como un indicador del riesgo asociado a un cierto activo. Estos modelos de volatilidad se pueden utilizar en ámbitos tan amplios como la valoración de derivados, la gestión de riesgo y a la hora de construir carteras.

Dentro de los modelos de volatilidad se tendrá que optimizar los parámetros del modelo para mejor ajuste para ello se utilizará el método de Nelder-Mead. El método de Nelder-Mead descrito por Nelder & Mead (1965), es un algoritmo de optimización que se usa para encontrar el valor mínimo o máximo de una función objetivo sin restricciones. En el contexto de los modelos ARCH y GARCH, este método se puede utilizar para estimar los parámetros del modelo que minimizan una función objetivo, que generalmente es la función de verosimilitud negativa.

Para la obtención de los parámetros iniciales de estos modelos se usarán las fórmulas (3.1) y (3.2) propuestas por Karasan (2021), tanto para el modelo ARCH como GARCH.

### 2.5.1 Modelos ARCH

Uno de los primeros intentos de modelar la volatilidad fue propuesto por Engle (1982), y esta propuesta se conoce como el modelo de ARCH (Modelos de Heteroscedasticidad Condicional Autoregresiva) y se describe de la siguiente manera:

- Varianza:  $\sigma_t^2 = \omega + \sum_{k=1}^p \alpha_k (r_t - k)^2$  (2.1)
- Media:  $r_t = \sigma_t \epsilon_t$ , donde  $\epsilon_t$  se supone con distribución normal
- Condiciones:  $\omega > 0$   
 $\alpha_k \geq 0$

Este modelo es univariante y no lineal, estimando de manera que la volatilidad se obtiene con el cuadrado de los retornos pasados Karasan (2021). Con este modelo se puede representar un fenómeno descrito por Mandelbrot (1963) en el cual los grandes cambios tienden a ser seguidos por grandes cambios y los pequeños tienden a ser seguidos por pequeños cambios.

Se interpreta así que el modelo de ARCH va a servir como herramienta fundamental para predecir la volatilidad, teniendo en cuenta los cambios históricos en los retornos.

A pesar de estas características favorables, este modelo tiene unas ciertas desventajas:

- Respuesta igual ante cambios positivos y negativos
- Posibles fallos ante cambios bruscos
- Suposiciones estrictas, como restricciones paramétricas

Por tanto, el uso del modelo ARCH a lo largo de la historia ha estado vinculado al pronóstico de la volatilidad, la gestión de riesgos y para calcular la volatilidad implícita en derivados financieros, por lo que pese a las desventajas claras que presenta este modelo, ha sido útil en diversos aspectos como los antes mencionados. Se pretende la mejora de este modelo para obtener unos resultados más cercanos a la realidad y ayudar así a mejorar tanto el pronóstico de la volatilidad como la gestión del riesgo.

## 2.5.2 Modelos GARCH

El modelo de GARCH propuesto por Bollerslev (1986) es una continuidad del modelo de ARCH que incorpora la varianza condicional retrasada. Esta varianza se refiere a la idea de que la varianza de una variable puede depender de valores pasados de esa misma variable, su importancia en la predicción de la volatilidad es manifiesta, ya que permite que el modelo capture una amplia variedad de dinámicas distintas en la volatilidad. Este modelo de GARCH guarda similitudes y diferencias con el anterior modelo, una de las mejoras que se introducen en el modelo de GARCH se encuentran al añadir p número de varianzas condicionales retrasadas, lo que lo convierte en un modelo multivariante, ya que es un modelo autorregresivo de media móvil para la varianza condicional con p número de retornos al cuadrado retrasados y q número de varianza condicional retrasada.

La formulación de GARCH se haría de la siguiente forma:

$$\sigma_t^2 = \omega + \sum_{k=1}^q \alpha_k (r_t - k)^2 + \sum_{k=1}^p \beta_k \sigma_{t-k}^2 \quad (2.2)$$

Donde  $\omega$ ,  $\alpha$  y  $\beta$  serán variables estimadas en el modelo, teniendo en cuenta estas restricciones:

- $\omega > 0$
- $\beta \geq 0$

- $\alpha \geq 0$
- $\beta + \alpha < 1$

Entre los modelos ARCH y GARCH hay ciertas similitudes, se podría decir por ejemplo que el GARCH se podría definir como un ARCH de orden infinito, lo que permite tener una visión histórica mucho más fiable, lo que convierte a este modelo en un modelo más flexible. Esta representación del GARCH a través de un ARCH de orden infinito se puede mostrar analíticamente sustituyendo de la siguiente manera:

$$\sigma_t^2 = \omega + \alpha r_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (2.3)$$

Sustituyendo  $\sigma_{t-1}^2$  por su respectiva expresión:

$$\sigma_t^2 = \omega + \alpha r_{t-1}^2 + \beta(\omega + \alpha r_{t-2}^2 + \beta \sigma_{t-2}^2) \quad (2.4)$$

Simplificando:

$$\sigma_t^2 = \omega(1 + \beta + \beta^2 + \dots) + \alpha \sum_{k=1}^{\infty} \beta^{k-1} r_{t-k}^2 \quad (2.5)$$

Con esto se ve cómo se cumple el enunciado anterior y los pesos disminuyen de forma geométrica.

Existen más modelos GARCH, pero todos basados en este. Modelos como EGARCH, TGARCH, IGARCH, SGARCH, FGARCH... Son modelos de GARCH ampliados y enfocados en diferentes circunstancias. El uso de todos los modelos antes expuestos no se va a acometer en este trabajo.

## 2.6 Introducción al Machine Learning

El aprendizaje automático (*Machine Learning*) es una rama de la llamada inteligencia artificial (IA). Esta técnica toma como eje central de su desarrollo el uso de algoritmos que permiten a los ordenadores aprender e interpretar datos para hacer predicciones o tomar decisiones. La idea central del aprendizaje automático es que las máquinas puedan identificar patrones y adaptarse automáticamente sin intervención humana o con la mínima, Santillán (2022).

Una de las primeras definiciones dadas sobre *Machine Learning* fue realizada por Mitchell (1997) "un programa de computadora que aprende de la experiencia  $E$  con respecto a alguna tarea  $T$  y alguna medida de rendimiento  $P$ , si su rendimiento en  $T$ , medido por  $P$ , mejora con la experiencia  $E$ ."

El aprendizaje automático tiene sus raíces en la década de los 50 con Alan Turing y más tarde Arthur Samuel, los cuales son los principales precursores de esta tecnología.

### 2.6.1 Aplicaciones en Finanzas

El aprendizaje automático (*Machine Learning*) encuentra aplicaciones varias en finanzas, cambiando desde el inicio la forma en que se interacciona con el mercado financiero. La descripción de las aplicaciones de esta en

las finanzas se podría resumir en 4 puntos Dixon (2020).

- Predicción de precios y análisis de mercado: los algoritmos de aprendizaje automático pueden analizar gran cantidad de datos, lo que puede ayudar a predecir movimientos futuros con una mejor cercanía.
- Gestión de riesgos: esta es la rama en la que se centrará este proyecto, en la cual los procesos de aprendizaje automático pueden servir de ayuda para predecir ciertos riesgos, modelarlos y actuar contra ellos.
- Cumplimiento regulatorio: esta tecnología puede ayudar a la hora de cumplir una serie de regulaciones complejas que de otro modo sería complejo de afrontar, analizando grandes volúmenes de datos para detectar anomalías y garantizar el cumplimiento de estas regulaciones que puedan resultar complejas.
- Gestión de cartera: estos algoritmos pueden ayudar a la selección y gestión de inversiones o carteras de inversiones, optimizando las carteras según objetivos o condiciones específicas del inversor Jurczenko (2020).

## 2.6.2 Support Vector Regression (SVR): conceptos y aplicaciones en la gestión del riesgo

La máquina de soporte vectorial (SVM) es una técnica de aprendizaje guiado que se puede emplear en clasificación y regresión Vapnik (1995), para entenderlo de una manera más didáctica vamos a poner un ejemplo. Imagínese que se tienen puntos azules y rojos en un folio y se quiere dibujar una línea que separe los puntos rojos de los azules, pues esa es la tarea de la SVM. La meta de SVM es hallar una línea divisoria entre dos clases distintas. Aunque parece simple, el desafío radica en que hay prácticamente un número ilimitado de líneas que podrían separar las clases. Lo que buscamos es la línea más adecuada que permita una separación completa y precisa entre las clases.

En términos de álgebra lineal, esta línea ideal se denomina hiperplano, y su propósito es ampliar la distancia entre los puntos que están más próximos al hiperplano pero que son de clases opuestas. La separación entre estos dos puntos clave (vectores de soporte) se conoce como margen. Así, en SVM, el objetivo es agrandar el margen entre los vectores de soporte.

La variante de SVM para clasificación se llama clasificación de vectores de soporte (SVC). Conservando las propiedades fundamentales de SVM, esta técnica también puede ser utilizada en regresión. En este contexto, la meta es descubrir el hiperplano que reduzca el error y aumente el margen. Este enfoque se conoce como regresión de vectores de soporte (SVR), y en esta parte, lo aplicaremos al modelo GARCH. La fusión de estos dos modelos resulta en SVR-GARCH.

La Máquina de Soporte Vectorial para Regresión (SVR) es una extensión del concepto de Máquina de Soporte Vectorial (SVM) utilizado para problemas de regresión. Al igual que en la clasificación de vectores de soporte, la idea básica detrás de SVR es encontrar un hiperplano que mejor se ajuste a los datos; sin embargo, en lugar de buscar un hiperplano que mejor separe dos clases de datos, SVR busca un hiperplano que funcione como una función de regresión.

La función básica detrás de este modelo es la siguiente:

$$\begin{aligned} \text{Minimizar: } & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) & (2.6) \\ \text{suje}to \ a: & y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i \end{aligned}$$

$$\begin{aligned} \langle w, x_i \rangle + b - y_i &\leq \epsilon + \xi_i^* \\ \xi_i^*, \xi_i &\geq 0 \end{aligned}$$

- $w$  es el vector de pesos.
- $x_i$  y  $y_i$  son las características y etiquetas de los datos, respectivamente.
- $C$  es el parámetro de regularización.
- $\epsilon$  es el margen de tolerancia para el error.
- $\xi_i$  y  $\xi_i^*$  son variables de holgura que permiten cierto grado de error en la predicción.
- $b$  es el término de sesgo.

Surge una duda inmediatamente a la hora de plantear esto: ¿Y si no se puede separar de forma lineal? Pues existen las funciones de kernel, descritas y estudiadas por Shawe-Taylor (2012) para solucionar este inconveniente, el cual es un método sencillo y útil para modelar datos no lineales. Los pasos que se siguen en SMV con estas funciones son, en primer lugar, llevar los datos a una dimensión superior. Como antes se hizo en la forma de definir el SVM, se va a utilizar el ejemplo de los puntos. Lo que se haría sería levantar algunos puntos fuera del folio, en una especie de tercera dimensión, para que se puedan ver desde diferentes ángulos.

En segundo lugar, se encontrará un hiperplano adecuado. Ahora que se tienen los datos en otra dimensión, buscamos otro “folio” que los separe. Esa es nuestra línea en la tercera dimensión, el hiperplano.

Y por último se vuelve a los datos iniciales, una vez encontrada la forma de separar los datos de esta dimensión nueva, se vuelve a ver cómo estaba originalmente en el papel, pero ahora con una separación clara.

Finalmente, se emplean las funciones de kernel o de núcleo en los procedimientos de optimización. Son estas herramientas las que ayudan a hacer todo este proceso y son esenciales para transformar los datos que no son linealmente separables en un espacio donde sí lo sean.

Las funciones de kernel más famosas son las tres siguientes:

- Kernel polinomial

$$K(x, z) = x^T z + b \quad (2.7)$$

- Kernel de base radial (gaussiano)

$$K(x, z) = \exp\left(-\frac{(x-z)^2}{2\sigma^2}\right) \quad (2.8)$$

- Kernel exponencial

$$K(x, z) = \exp\left(-\frac{x-z}{\sigma}\right) \quad (2.9)$$

En resumen, las funciones de núcleo o kernel desempeñan un papel crucial en la extensión de las capacidades de las Máquinas de Soporte Vectorial (SVM) para manejar datos complejos y no lineales. Desde el kernel polinomial, que captura relaciones polinómicas entre las características, hasta el kernel de base radial o gaussiano, que es capaz de mapear datos en espacios de alta dimensión, estas funciones matemáticas permiten una gran flexibilidad en el modelado de datos. También hemos explorado el kernel exponencial, que ofrece otra forma de capturar la complejidad en la estructura de los datos. El uso de funciones de kernel en procedimientos de optimización permite que usando SVM se adapte a una variedad de problemas, desde la clasificación hasta

la regresión y en ámbitos como las finanzas, que son las que nos conciernen. Por lo tanto, el entendimiento y la selección adecuada de funciones de núcleo son pasos fundamentales para el éxito de cualquier aplicación de SVM.

## 2.7 Opciones y el modelo de Black-Scholes

El modelo de Black-Scholes-Merton Black et al. (1973) es uno de los métodos más conocidos para valorar opciones, y en este trabajo se utilizará como herramienta indispensable a la hora de calcular el valor de estas opciones para la cobertura del riesgo. La ecuación de Black-Scholes se trata de la siguiente:

$$C = S_0 \cdot N(d1) - X \cdot e^{-rT} \cdot N(d2) \quad (2.10)$$

$$P = X \cdot e^{-rT} \cdot N(-d2) - S_0 \cdot N(-d1) \quad (2.11)$$

- $C$ : Precio de una opción de compra (Call)
- $P$ : Precio de una opción de venta (Put)
- $S_0$ : Precio actual del activo subyacente
- $X$ : Valor actual del precio de ejercicio
- $T$ : Tiempo hasta el vencimiento de la opción en años
- $r$ : Tasa de interés libre de riesgo anualizada
- $N(\cdot)$ : Función de distribución acumulada de la distribución normal estándar
- $\sigma$ : Volatilidad del activo subyacente, que es la que se calculará a través del modelo SVR

Estas dos fórmulas se utilizan para el cálculo del precio de una opción de compra y venta respectivamente, a las cuales llamaremos *Call* y *Put*, Fernández (2008). Las opciones de compra le dan al que compra la opción el derecho de comprar un activo subyacente a un precio dentro de un periodo determinados. El vendedor si tendría la obligación de vender este mismo activo subyacente al precio acordado por ambas partes, siempre que el titular decida ejercer su opción. Pongamos un ejemplo para su mejor entendimiento, imagínese que tiene una opción de compra de un activo valorado hoy en día en 100\$, pero adquirimos el derecho mediante un pago de 2\$ de comprarlo en 6 meses por 90\$, y el precio del activo pasado ese tiempo sube a 200\$, entonces ejerciendo esa opción de compra usted podría conseguir unas ganancias de  $(200\$ - 90\$ - 2\$ = 118\$)$ , todo esto sin tener en cuenta la pérdida de valor del dinero con en el paso del tiempo.

De la misma manera se entendería la opción de venta *Put*, con la pequeña diferencia de que la opción de ejecutar el contrato la ejecuta el vendedor el activo subyacente. Del mismo modo se entenderá mejor con un pequeño ejemplo. Si usted tiene una opción de venta de un activo que está hoy valorado en 100\$, pero se tiene el derecho de venderlo en 3 meses a 110\$, y pasado ese tiempo el precio cae a los 90\$, usted podría hacer una ganancia superior ejecutando su opción, por lo que el beneficio sería de  $(110\$ - 90\$ - 2\$ = 8\$)$ .

Estas dos opciones se utilizan para varias cosas, entre ellas la cobertura del riesgo contra cambios adversos que es lo que se centra este trabajo.

En la formulación de estas opciones se encuentran 2 variables que han de ser calculadas de forma independiente, como son  $d1$  y  $d2$ , las cuales se calculan de la siguiente manera:

$$d1 = \frac{\ln\left(\frac{S_0}{X}\right) + \left(r + \frac{\sigma^2}{2}\right) \cdot T}{\sigma \sqrt{T}} \quad (2.12)$$



$$d2 = d1 - \sigma\sqrt{T} \quad (2.13)$$

Los activos seleccionados para esta estrategia de cobertura son los Fondos Cotizados en Bolsa (Exchange-Traded Funds o ETFs), que han sido ampliamente discutidos por expertos como Abner (2016). Los ETFs son especialmente atractivos para la cobertura de riesgos debido a varias características clave. Primero, ofrecen una diversificación inmediata, ya que muchos ETFs son fondos indexados que rastrean un índice subyacente compuesto por múltiples activos. Esto permite a los inversores exponerse a un rango más amplio de activos con una sola compra, lo que reduce el riesgo específico del activo.

Segundo, los ETFs son conocidos por su alta liquidez. A diferencia de los fondos mutuos, que sólo pueden comprarse o venderse al final del día de negociación, los ETFs se negocian en bolsa como acciones individuales. Esto proporciona una gran flexibilidad a los inversores para entrar y salir de posiciones rápidamente, lo que es crucial en escenarios de alta volatilidad.

Tercero, los ETFs son versátiles y ofrecen una amplia gama de opciones para cubrir diferentes tipos de riesgos. Por ejemplo, hay ETFs que se centran en diferentes sectores de la economía, como tecnología o salud, así como ETFs que rastrean activos específicos como bonos del gobierno, materias primas o divisas. Esto hace que los ETFs sean herramientas excepcionalmente útiles para gestionar riesgos específicos, como el riesgo de inflación.

Por último, los ETFs también permiten la exposición a mercados y geografías variadas, lo que facilita la diversificación no solo a nivel de activo sino también a nivel geográfico. Esto es especialmente útil en un entorno globalizado donde los eventos en un país pueden tener implicaciones en los mercados de todo el mundo.

En resumen, la naturaleza diversificada, líquida y flexible de los ETFs los convierte en una opción ideal para implementar estrategias de cobertura de riesgos, permitiendo a los inversores adaptar sus carteras a una variedad de condiciones económicas y escenarios de riesgo como los propuestos en este trabajo

Se utilizará [www.justetf.com](http://www.justetf.com) para la búsqueda de los ETF y en ella así se encontrará cualquier información que se estime oportuna para el procesamiento de estos datos.

## 2.8 Teoría de la cartera moderna (MTP) para la cobertura

La teoría de la cartera moderna Elton (1995) utiliza como uno de los pilares fundamentales en su teoría la teoría de cartera de Markowitz descrita por Markowitz (1952), pero en esta teoría se implementa una de las herramientas fundamentales hoy en día para la cobertura del riesgo, los derivados financieros. Ambas carteras tienen como objetivo la optimización de una cartera de inversión teniendo en cuenta el perfil de inversión.

En la teoría de cartera de Markowitz, desarrollada en 1952 se introdujo el concepto de diversificación para optimizar el riesgo-rendimiento. Mientras tanto en 1995 se desarrolla una nueva manera de optimización de carteras que sirve como extensión y generalización de la teoría de Markowitz, incorporando nuevas investigaciones que se desarrollaron en esos años intermedios, introduciendo esa cartera también el ratio de Sharpe y el coeficiente de Treynor, Sharpe (1964) que evalúan el rendimiento ajustando al riesgo.

En resumen, la teoría de la cartera de Markowitz se podría considerar una especie de subconjunto de la Teoría Moderna de la Cartera. La MPT amplía y mejora las ideas originales de Markowitz para adaptarlas a la época moderna de tanta variedad de activos financieros y perfiles de riesgo.

Para utilizar esta cartera se deben resolver una serie de problemas que nos resuelvan tanto el rendimiento esperado de una cartera como la volatilidad histórica de los activos. Esta última variable es la que se estimará con modelos de *Machine Learning*, probando así la posible mejora de la cartera implementando esta tecnología, pero el rendimiento esperado se obtendrá con la siguiente fórmula.

$$E(R_p) = \sum_{i=1}^n w_i \cdot E(R_i) \quad (2.14)$$

Para el cálculo de la varianza de la cartera, utilizando la volatilidad esperada resuelta mediante el modelo SVR, se utilizará lo siguiente:

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n w_i \cdot w_j \cdot \sigma_i \cdot \sigma_j \cdot \rho_{ij} \quad (2.15)$$

- $\rho_{ij}$  es el coeficiente de correlación entre los activos  $i$  y  $j$  ya calculados con SVR

Para optimizar la cartera, por tanto, se hace de forma común resolviendo el problema de optimización propuesto por Markowitz.

$$\max_w \left( w^T \mu - \frac{\lambda}{2} w^T \Sigma w \right) \quad (2.16)$$

- $w$  es un vector de ponderaciones de los activos en la cartera
- $\mu$  es el vector de rendimientos esperados.
- $\Sigma$  es la matriz de covarianza entre los rendimientos de los activos.
- $\lambda$  es un parámetro que indica la aversión al riesgo del inversor.

Comentando algunas de las variables se puede comprobar que algunas de estas como por ejemplo  $\lambda$  son variables que se adaptaran al perfil de la empresa que ejecute esta fórmula. Este perfil de riesgo se puede averiguar mediante entrevistas preestablecidas que dé una información del rendimiento-riesgo que se está dispuesto a asumir.

Esta fórmula congrega la base matemática de la MTP y es fundamental para la construcción y evaluación de carteras de inversión optimizadas.

Por tanto, en este trabajo se va a proponer una mejora de los métodos tradicionales de predicción de la volatilidad determinados activos financieros, en este caso ETFs, implementando tecnología de *Machine Learning* y utilizando esta volatilidad predicha para su aplicación en herramientas financieras como la teoría de Black-Scholes o la teoría de la cartera moderna (MTP), para obtener unos mejores resultados debido a la mejora de la predicción.

# 3 METODOLOGÍA

---

*Debes perder una mosca para pescar una trucha.*

*-George Herbert -*

En esta sección se tendrá como objetivo principal detallar la metodología y su correspondiente diseño que guía el trabajo para sacar unas conclusiones relevantes. Se describirán así las fases y técnicas que son utilizadas para resolver los problemas que se plantean durante todo el trabajo a la hora de modelizar y evaluar la volatilidad del mercado financiero mientras se usan modelos como el ARCH y GARCH y en el modelo de *Machine Learning* mediante las Máquinas de Soporte Vectorial para Regresión (SVR). Adicionalmente, se incorporarán las soluciones obtenidas en los modelos anteriores para que se incorporen en la valoración de opciones financieras a través del modelo de Black-Scholes y en la optimización de cartera obtenida mediante la Teoría Moderna de la Cartera (MPT).

Cada subsección proporcionará un análisis lo más detallado posible de los procedimientos y métricas que se emplean, con el fin último de garantizar la replicabilidad del estudio si así se dispusiera y aportar rigor científico al mismo.

Dentro de cada uno de los apartados de esta sección se introducirá un esquema para la mejor comprensión de los pasos que se siguen.

## 3.1 Recopilación de datos

### 3.1.1 Fuentes de datos

La mayoría de los datos se obtendrán de manera automática mediante Yahoo Finance, que cuenta con una librería en Python que permite la descarga automática de la mayoría de los activos mediante una API pública. Yahoo Finance cuenta con una gran experiencia en el ámbito de la recopilación de datos financieros, está bien establecida en el mercado y es una de las webs más utilizadas tanto por profesionales del sector como de manera académica. En Yahoo Finance la mayor parte de los datos que se van a obtener son en relación con los cierres ajustados de las acciones que se vayan a estudiar, con lo que se estudiará la volatilidad futura mediante el uso de estos datos históricos. Los datos que se van a utilizar irán desde 2015 hasta la actualidad, ya que con eso se tendrán datos suficientes que permitan un análisis robusto.

Se dispondrá de los datos de los ETF y otros datos necesarios, y la elección de esos ETF dependerá de las necesidades y del mercado en el que la empresa estudiada haga sus operaciones. Para el acceso y descarga de estos datos, como hemos dicho antes se utilizará la biblioteca 'yfinance' para hacer solicitudes a la API de Yahoo Finance, dichos datos se descargarán en formato CSV para su posterior preprocesamiento y análisis posterior.

Es importante tener en cuenta las limitaciones que se asocian a los datos recabados con Yahoo Finance. La principal de sus limitaciones es la posible desactualización de los datos, dando por supuesto de otra manera que los datos descargados sean de buena calidad y no haya problemas en la descarga.

A la hora del estudio del riesgo de inflación se usará la tasa de interés real para tener en cuenta la inflación dentro de la tasa de interés sin riesgo utilizada en el modelo de Black-Scholes y la Teoría de la Cartera Moderna. Esto datos se obtendrán de la web del Banco de España.

### 3.1.2 Selección de los datos

A continuación, se van a seleccionar los datos y activos para los dos casos que se van a estudiar en este apartado, una empresa de venta de frutas y verduras que se va a denominar como “Empresa A” y por otro lado una empresa de ingeniería que se dedica a la inteligencia artificial “Empresa B”. A la vista de las características de esta empresa se encuentran 3 ETFs que marcan la dirección general de estos mercados y por tanto servirán como guía en nuestro estudio de la cobertura. El primero de ellos para la empresa A, se elige el *Invesco DB Agriculture Fund (DBA)*, el cual busca según su propia página web brindar exposición a los futuros de productos agrícolas. Está diseñada para rastrear el rendimiento de un índice que está compuesto por futuros contratos en ciertos productos agrícolas. Luego se utilizará el *Teucrium Corn Fund (CORN)* cuya información se encuentra en la propia página web del fondo [teucrium.com/etfs](http://teucrium.com/etfs), esta empresa también tiene otros ETF agrícolas como *Teucrium Agrícola Fund (TAGS)* que se utilizarán en la teoría de la cartera moderna. *Teucrium Corn Fund (CORN)* le da al inversor una manera fácil de seguir el precio de los futuros del maíz mientras que *Teucrium Agrícola Fund (TAGS)* lo hace con el precio tanto del maíz, como del azúcar y otros productos agrícolas.




Ilustración 3-1: Rentabilidad acumulada ETFs A

- *Invesco DB Agriculture Fund (DBA)*

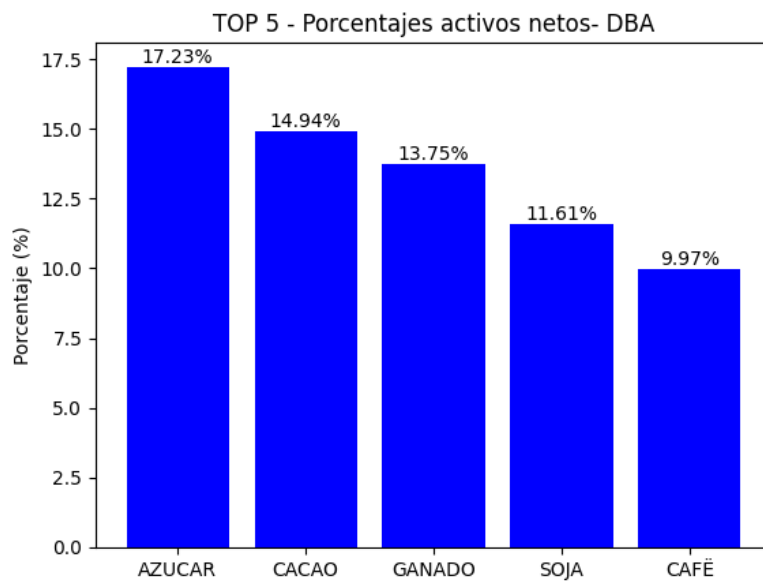


Ilustración 3-2: % Activos en ETF (DBA)

- *Teucrium Corn Fund (CORN)*: se basa solo en el precio del maíz
- *Teucrium Agricultural Fund (TAGS)*




Ilustración 3-3: % Activos en ETF (TAGS)

Por otro lado, en la empresa B se tendría una mayor variedad de opciones que utilizar para replicar el comportamiento del mercado. Los principales serían según Carta Financiera (2023) los que se mostrarán en las siguientes gráficas, cuya composición se detalla también en estas.

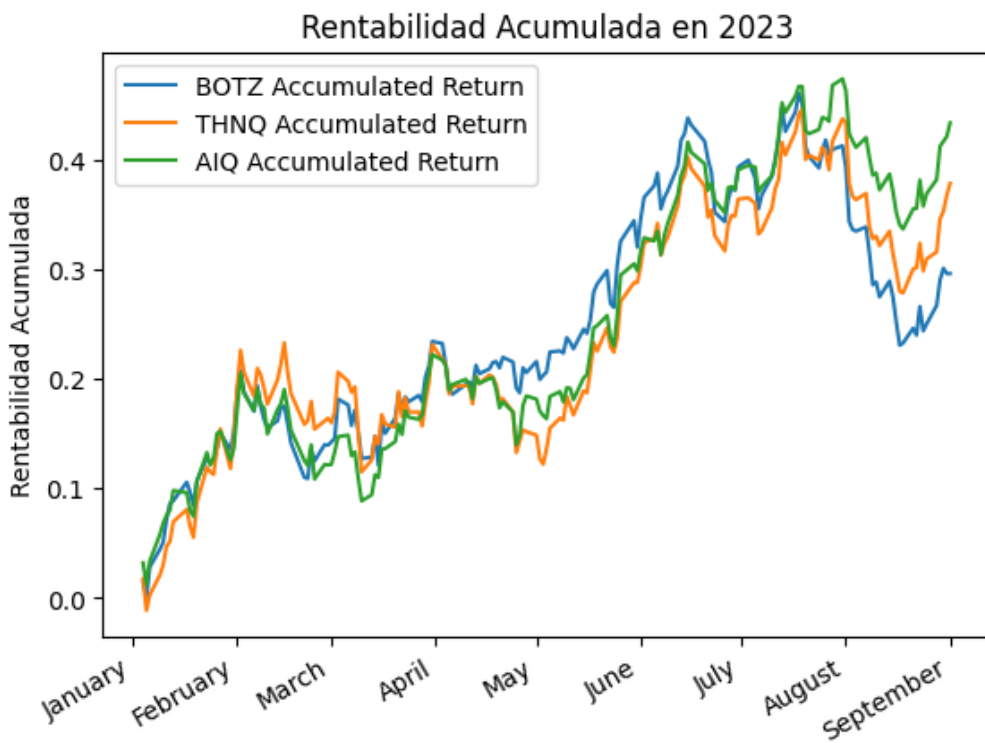


Ilustración 3-4: Rentabilidad TOP 3 ETFs IA

- Global X Robotics & Artificial Intelligence (BOTZ)




Ilustración 3-5: % Activos en ETF (BOTZ)

- Robo Global Artificial Intelligence (THNQ)




Ilustración 3-6: % Activos en ETF (THNQ)

- Global X Artificial Intelligence & Technology (AIQ)




Ilustración 3-7: % Activos en ETF (AIQ)

Todos estos ETF podrían ser un buen estimador del comportamiento del mercado de la inteligencia artificial en general debido a la diversificación y la inversión en empresas punteras en el desarrollo de este tipo de tecnología. Para este caso ficticio se escogerá la que estaría primera en el ranking, que sería la del “ticker” (BOTZ).

Los datos de los retornos de estos ETF que se utilizarán irán desde el 01/01/2015 al 01/01/2022, ya que la mayoría de los activos con los que se trabajarán fueron creados entre estas fechas, por lo que existirían registros de ellos.

### 3.1.3 Preprocesamiento

En este caso particular disponemos de todos los datos que necesitamos para poder inicializar nuestros modelos debido a que los datos que necesitamos son públicos y están al acceso de la mayoría de la población de una manera sencilla.

Pese a esto se utilizará la función de pandas '**dropna ( )**' por si en alguna de las pruebas se cuela alguna casilla vacía que necesite ser eliminada, debido a que la falta de datos suele ser un problema muy común en el análisis de datos y podrían afectar de manera negativa a los resultados que se obtengan. Esta función se utilizará sobre todos los datos para evitar posibles fallos.

### 3.1.4 Bibliotecas utilizadas

Antes de empezar el modelado de la volatilidad, se va a exponer todas las bibliotecas que se utilizarán a la hora de la utilización de funciones y demás.

- **NumPy**: utilizado para operaciones matriciales y cálculos numéricos.
- **SciPy**: empleado para optimización y cálculos estadísticos, en particular la función de distribución normal.
- **yfinance**: usado para extraer datos financieros.
- **Pandas**: para el manejo y manipulación de datos en forma de tablas.
- **datetime** y **time**: para trabajar con fechas y tiempo.
- **arch**: implementa modelos ARCH (Modelos de Heteroscedasticidad Condicional Autoregresiva) para análisis de series temporales.
- **Matplotlib**: para visualización y gráficos.
- **Numba**: para acelerar el código utilizando Just-In-Time compilation.
- **Scikit-learn (mean\_squared\_error)**: para evaluar el rendimiento del modelo mediante el error cuadrado medio.

Además de esto se importará una librería (`warnings`) para evitar la saturación de la salida del programa evitando mensajes de advertencia.



## 3.2 Modelado de volatilidad con ARCH y GARCH

### 3.2.1 Modelo ARCH

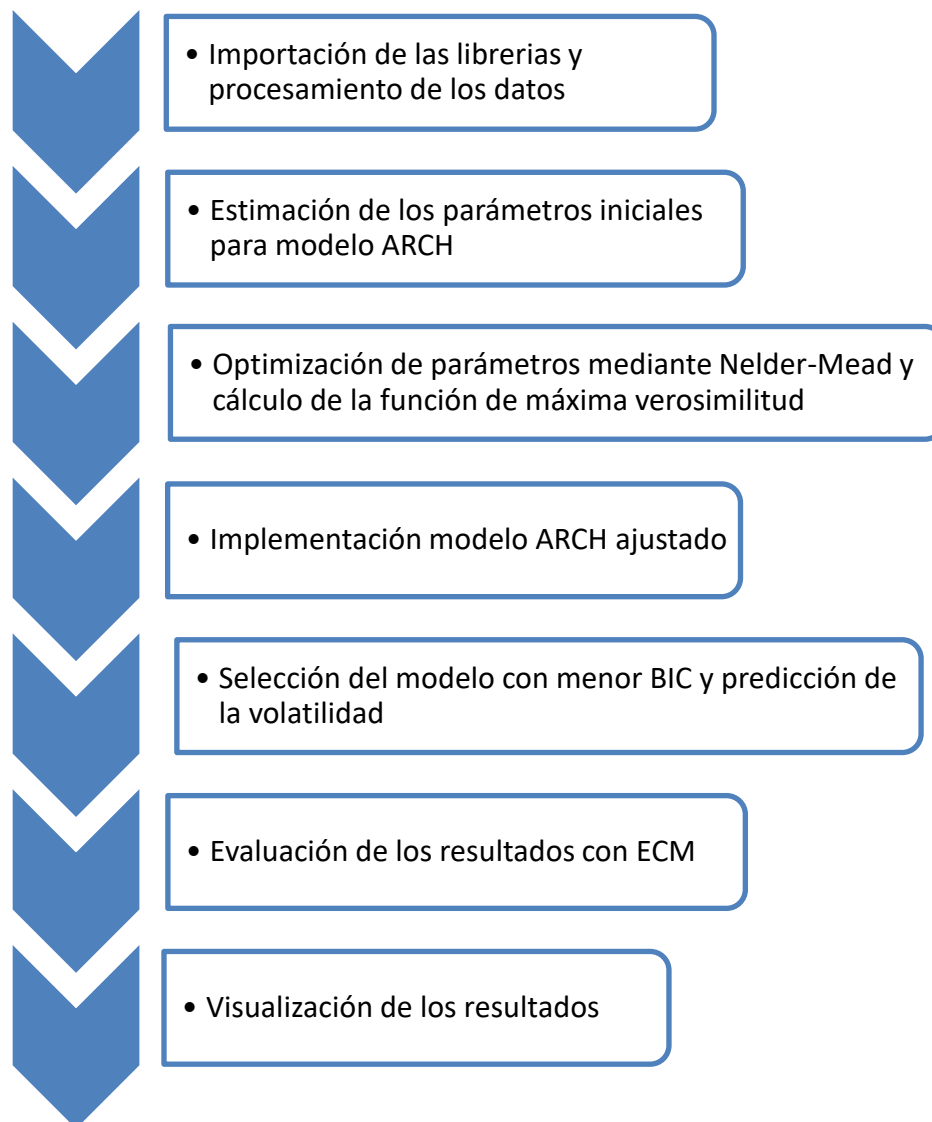


Ilustración 3-8: Estructura ARCH

#### 3.2.1.1 Estimación inicial de parámetros para el Modelo ARCH

Para esta estimación los parámetros iniciales se utilizarán las siguientes fórmulas según Abdullah (2021).

$$\alpha = \frac{-3.0 \times \sigma^2 + \sqrt{9.0 \times \sigma^2 - 12.0 \times (3.0 \times \sigma^2 - K) \times K}}{6 \times K} \quad (3.1)$$

$$\omega = (1 - \alpha) \times \sigma^2 \quad (3.2)$$

Estas se implementarán el código introduciéndolas en una lista para los parámetros iniciales.

### 3.2.1.2 Optimización de parámetros del Modelo ARCH

Para el ajuste del modelo de ARCH, se utiliza un enfoque de máxima verosimilitud. Creamos entonces la función de máxima verosimilitud para un conjunto de datos iniciales anteriormente calculados.

Para encontrar los parámetros óptimos de  $\alpha$  y  $\omega$  que mejor se van a ajustar al modelo de ARCH de los datos, se realiza una función que lo consiga.

Se utilizará por tanto el método de Nelder-Mead para esta optimización numérica, dando como datos de entrada los parámetros iniciales que se consiguieron antes, el dato de los retornos y el número máximo de iteraciones que se quieren llevar a cabo, que en este caso serán 5000, para tener una muestra suficiente para hallar mínimos locales, hallar una convergencia lenta y no incurrir en un número excesivo de iteraciones que puedan llevar al sobreajuste. Como datos de salida se obtendrán los parámetros óptimos que se tendrán que utilizar a la hora de modelar el ARCH.

### 3.2.1.3 Implementación del Modelo ARCH ajustado

Se define una función que recibe los retornos y calcula la volatilidad condicional utilizando los parámetros optimizados que se han obtenido, calculando así la volatilidad condicional para cada punto del tiempo, según la fórmula del modelo ARCH, dando como salida la serie de volatilidades estimadas.

Se usa después para la validación del modelo la biblioteca 'arch' para realizar el ajuste de manera automática, especificando varias de las variables. En primer caso la  $p$ , que la consideraremos 1 y la media se considerará 0 para la simplificación de la formulación y enfocarse en modelar la volatilidad en lugar de la media del proceso. Usaremos la función 'fit ( )' para realizar el ajuste de los retornos, imprimiendo tras esto un resumen donde aparecerán una serie de datos relevantes.

Este paso se utilizará como comparativa entre el modelo manual y automático. Incluir esta etapa proporciona una capa adicional de validación y robustez al modelo, asegurando así unos resultados más fiables.

### 3.2.1.4 Selección de Modelo y predicción

Para la selección del orden óptimo de  $p$  en el modelo de ARCH, se realiza una búsqueda en el rango de 1 a 4 y se seleccionará el modelo con menor Criterio de Información Bayesiano (BIC). Se ajusta así el modelo ARCH con diferentes valores y se calcula el BIC viendo así cual tiene menor BIC y seleccionándolo para posteriormente ajustar el modelo ARCH con el  $p$  óptimo. Después con el modelo ajustado se realiza una predicción de la volatilidad.

Una vez ajustado el modelo óptimo, se extraerán los parámetros estimados para un análisis aún más detallado extrayendo  $\omega$  y un array con los valores de  $\alpha$ . Con estos valores se podrá interpretar el comportamiento de la volatilidad.

### 3.2.1.5 Evaluación del Rendimiento del Modelo

Para evaluar la eficacia del modelo aplicado se usarán una serie de instrumentos que nos darán una visión más precisa de los resultados obtenidos por las predicciones. Una de las herramientas es el Error Cuadrático Medio (ECM) esto se calcula entre la volatilidad histórica y la volatilidad predicha para medir la precisión de las estimaciones. Se calculará también las volatilidades medias para ver la diferencia que existiría entre una y otra en el último año.

### 3.2.1.6 Visualización de los resultados

Para la visualización y comparación de la eficacia del modelo no hay nada como verlo con los propios ojos. La mejor manera de visualizar la diferencia entre la volatilidad histórica y la volatilidad predicha se considera que sería la superposición de ambas gráficas. Se añadirá cuadrícula, títulos y leyendas y se cambiarán los colores

para facilitar su interpretación.

### 3.2.2 Modelo GARCH

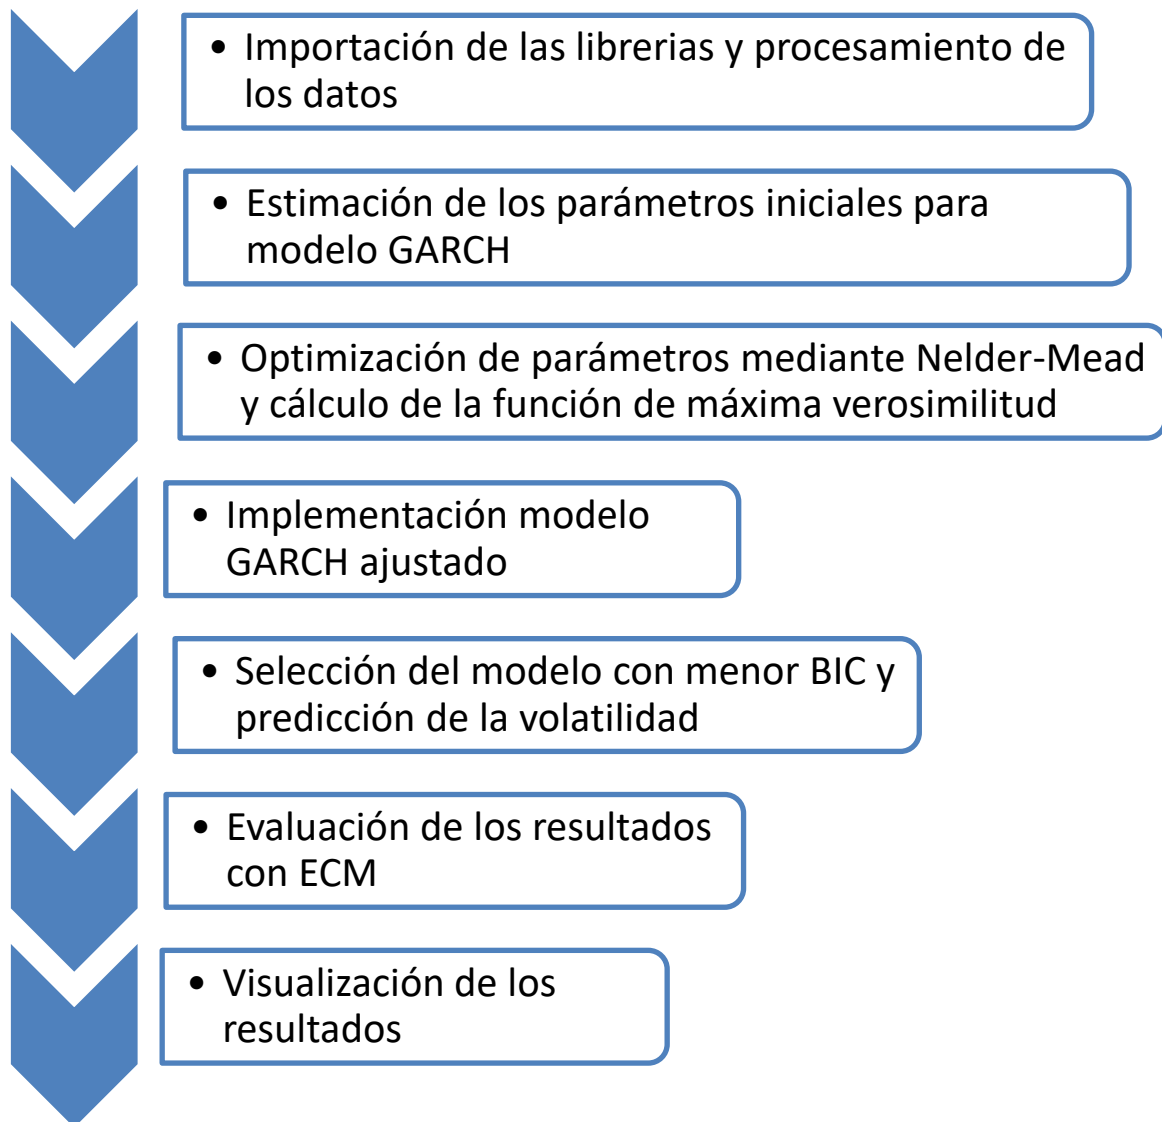


Ilustración 3-9: Estructura GARCH

#### 3.2.2.1 Estimación inicial de parámetros para el Modelo GARCH

Antes del ajuste del modelo GARCH (1,1) a los datos, se realiza una estimación inicial de los parámetros  $\omega$ ,  $\alpha$ , y  $\beta$  utilizando los momentos estadísticos de la serie de retornos. Y fórmulas específicas para estimar estos parámetros en función de la varianza y curtosis.

$$\alpha = \sqrt{\frac{K \times (1 - h^2)}{2.0 \times (K + 3)}} \quad (3.1)$$

$$\beta = |h - \omega| \quad (3.2)$$

$$\omega = (1 - \alpha) \times \sigma^2 \quad (3.3)$$

Estos parámetros iniciales se utilizan para mejorar la convergencia del modelo GARCH durante el proceso de ajuste.

### 3.2.2.2 Optimización de Parámetros del Modelo GARCH

Como en el anterior modelo se utilizará un enfoque de máxima verosimilitud para el ajuste del modelo, calculando la función de verosimilitud para un conjunto de parámetros  $\omega$ ,  $\alpha$ , y  $\beta$ . Los parámetros introducidos en esta función volverán a ser los parámetros iniciales antes hallados, así como los retornos. Dentro de esta función se calcula la suma de las verosimilitudes para todos los puntos de tiempo  $t$ , usando la fórmula específica del modelo GARCH (1, 1).

Para encontrar los parámetros  $\omega$ ,  $\alpha$ , y  $\beta$  que mejor ajusten el modelo GARCH a los datos, se utilizará de nuevo el método Nelder-Mead, que es un algoritmo de optimización numérica. Se añaden restricciones para que la suma de estos parámetros nunca sea mayor que 1 añadiendo una restricción explícita. También entran como argumentos los parámetros iniciales y de nuevo el máximo número de iteraciones y sacando de la función el resultado óptimo de los parámetros.

### 3.2.2.3 Implementación del Modelo GARCH ajustado

Se define una función que recibe los retornos y calcula la volatilidad condicional utilizando los parámetros optimizados que se han obtenido, calculando así la volatilidad condicional para cada punto del tiempo, según la fórmula del modelo GARCH, dando como salida la serie de volatilidades estimadas.

Se usa después para la validación del modelo la biblioteca 'arch' para realizar el ajuste de manera automática, especificando varias de las variables. En primer caso la  $p$ , que la consideraremos 1 con una media de 0. Usaremos la función 'fit()' para realizar el ajuste de los retornos, imprimiendo tras esto un resumen donde aparecerán una serie de datos relevantes.

Este paso se utilizará como comparativa una vez más entre el modelo manual y automático. Incluir esta etapa proporciona una capa adicional de validación y robustez al modelo, asegurando así unos resultados más fiables.

### 3.2.2.4 Selección de Modelo y predicción

Para seleccionar los órdenes óptimos de  $p$  y  $q$  del modelo GARCH, se realiza una búsqueda en el rango  $p = 1, 2, 3, 4$  y  $q = 1, 2, 3, 4$  y se selecciona el modelo con el menor BIC.

A continuación, se ajusta el modelo GARCH con los  $p$  y  $q$  óptimos y se realiza una predicción de la volatilidad figura utilizando el modelo ajustado.

Con esto se obtiene una comprensión clara de cómo se selecciona y valida el modelo más adecuado para el GARCH.

### 3.2.2.5 Evaluación del Rendimiento del Modelo

Para la evaluación de la eficacia del modelo de GARCH ajustado, se realiza el cálculo del error cuadrático medio para usarlo como herramienta de comparación entre la volatilidad histórica y la predicha. Esta métrica ofrece una evaluación cuantitativa del rendimiento del modelo GARCH, lo cual es crucial para validar la utilidad y precisión de este.

### 3.2.2.6 Visualización de los resultados

Para evaluar el rendimiento del modelo, especialmente en comparación con el modelo ARCH, la forma más

efectiva es visualizarlo directamente. Superponer los gráficos de la volatilidad histórica y la volatilidad pronosticada puede ofrecer una visión clara de la eficacia del modelo. Para mejorar la legibilidad, se incluirán elementos como cuadrículas, títulos y leyendas, además de ajustar los colores para una interpretación más sencilla.

### 3.3 Modelado de la volatilidad con SVR

Antes de la aplicación del modelo SVR, es necesario importar algunos módulos específicos utilizados para *Machine Learning*. Se importa la clase 'svr' de la biblioteca 'scikit-learn'. Se importa de igual manera 'RandomizedSearchCV' para realizar una búsqueda aleatoria de hiperparámetros con validación cruzada, y por último 'uniform' que podrá generar valores aleatorios de una distribución uniforme. En el siguiente esquema se expone la manera que se sigue para la modelización y predicción de la volatilidad con el modelo SVR-GARCH.

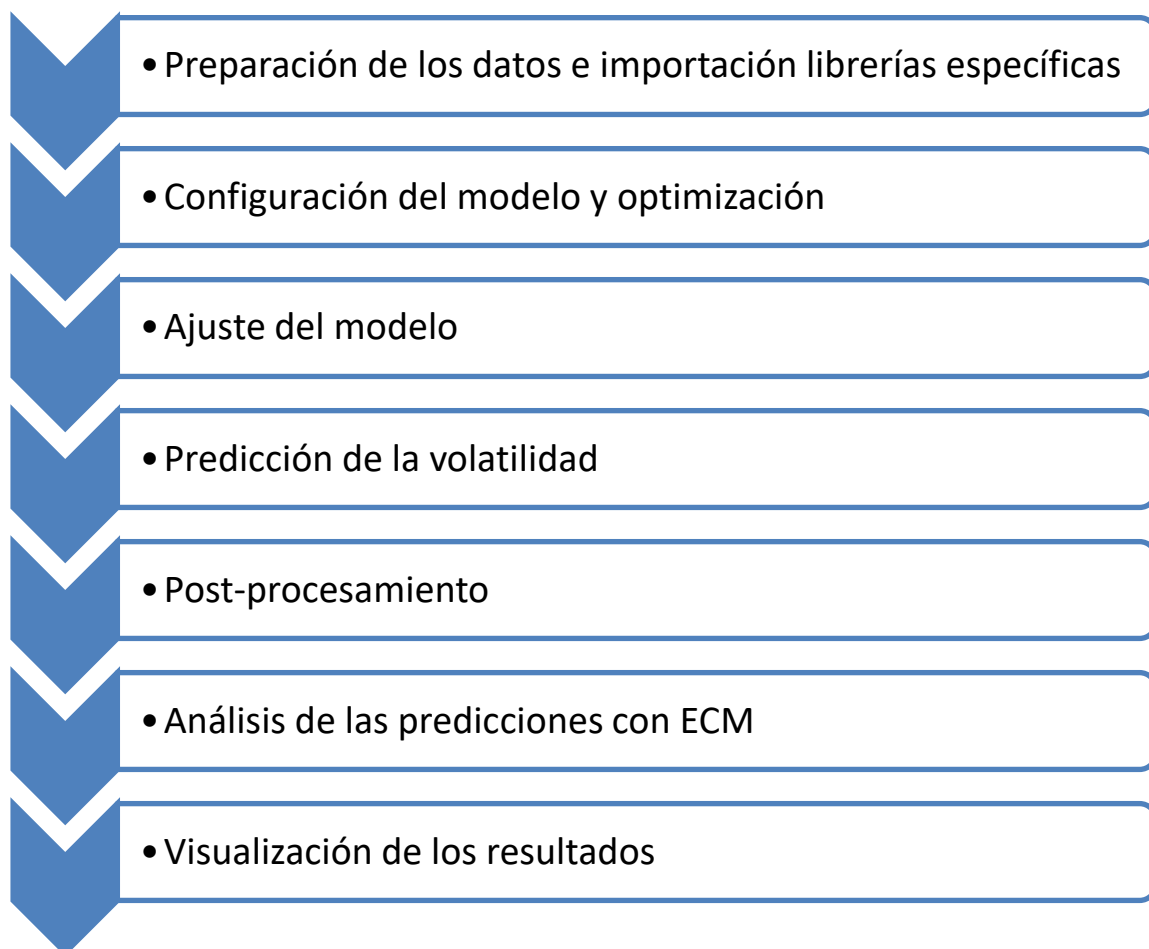


Ilustración 3-10: Estructura SVR

#### 3.3.1 Preparación de Datos y Configuración de Modelos SVR

Para aplicar los modelos SVR, se calcula la volatilidad histórica de los retornos utilizando una ventana móvil de 5 días, luego se concatenan la volatilidad histórica y el cuadrado de los retornos para formar el conjunto de características que serán útiles para el modelo las cuáles serán las variables independientes. Tras esto se borran los datos nulos y se reinician índices para alinear los datos.

Como se habló en el marco teórico hay 3 modelos de kernel y las tres instancias de modelos SVR con diferentes núcleos hay que crearlas

### 3.3.2 Modelo SVR-GARCH (Lineal)

#### 3.3.2.1 Optimización y ajuste del Modelo SVR

Para la optimización de hiperparámetros del modelo SVR con kernel lineal, se lleva a cabo una búsqueda aleatoria de hiperparámetros con validación cruzada.

Se define un grid de hiperparámetros, es decir, un conjunto predefinido de diferentes hiperparámetros que un modelo de *Machine Learning* puede usar, que incluyen entre ellos  $\gamma$ ,  $C$ , y  $\epsilon$  que seguirán una distribución uniforme. Se ajusta después el modelo al conjunto de datos utilizando la búsqueda aleatoria de hiperparámetros y una vez el modelo se haya ajustado, se realiza la predicción de la volatilidad para el último segmento de los datos.

Se utilizan las observaciones excepto las últimas 'n' para el conjunto del entrenamiento del modelo, unos datos buenos en esta parte son parte fundamental del buen rendimiento del modelo.

#### 3.3.2.2 Post-procesamiento y análisis de las predicciones SVR

Una vez se hallan las predicciones de la volatilidad con el modelo SVR optimizado, se procede entonces al post-procesamiento de las predicciones convirtiendo estas en un *dataframe* para un análisis de los datos obtenidos más sencillo, asignando posteriormente los índices de tiempo correspondientes a las predicciones para alinearlas con el conjunto de datos original.

Tras esto, como hicimos en los modelos de ARCH y GARCH, se va a utilizar como herramienta para ver el ajuste que se ha hecho de la predicción el error cuadrático medio (ECM). Para facilitar la comparación de las predicciones SVR con la volatilidad histórica, se alinean los índices de tiempo del *dataframe* de volatilidad histórica con los del conjunto de datos de retornos.

#### 3.3.2.3 Visualización de los resultados

Tras haber obtenido y procesado los datos, se procede a visualizar y comparar estas predicciones con la volatilidad histórica. Para el resto de la visualización se siguen los pasos que ya se han seguido en capítulos anteriores.

### 3.3.3 Modelo SVR-GARCH (RBF)

#### 3.3.3.1 Optimización y ajuste del Modelo SVR

De manera similar al enfoque utilizado en el kernel lineal, se realiza una búsqueda aleatoria de hiperparámetros para optimizar el modelo SVR con kernel RBF (función de base radial). De la misma manera que en el anterior, se usa un grid de hiperparámetros con distribuciones uniformes para  $\gamma$ ,  $C$ , y  $\epsilon$ .

Se aplica 'RandomizedSearchCV' para optimizar los hiperparámetros del modelo SVR con kernel RBF ajustando después el modelo utilizando los datos del entrenamiento de este. Para predecir finalmente la volatilidad, se utilizan los datos para la prueba, utilizando el modelo entrenado.

#### 3.3.3.2 Post-procesamiento y análisis de las predicciones SVR

Tras las predicciones, se sigue un proceso similar al del kernel lineal para el post-procesamiento de las predicciones. Estas predicciones que se han obtenido en el apartado anterior se introducen en un *dataframe* y tras esto se asignan los índices de tiempo correspondiente a las predicciones para una mejor representación de los datos.

Todo esto se usa para que tanto la volatilidad histórica como las predicciones del modelo SVR con kernel RBF tengan índices consistentes, todo ello para una comparación efectiva de ambas gráficas.

Para ver el ajuste que se ha hecho de la predicción, una vez más, se usará el error cuadrático medio (ECM).

### 3.3.3.3 Visualización de los resultados

Con todo lo realizado en este apartado se puede representar de forma efectiva ambas gráficas, dando así una valoración visual de la efectividad de la predicción hallada.

## 3.3.4 Modelo SVR-GARCH (Polinomial)

### 3.3.4.1 Optimización y Ajuste del Modelo SVR

Para la optimización de hiperparámetros del modelo SVR con kernel polinomial, se lleva a cabo una búsqueda aleatoria de hiperparámetros con validación cruzada, que define un rango de posibles valores para cada hiperparámetro que se va a ajustar, selecciona de forma aleatoria un conjunto de combinaciones de hiperparámetros y se selecciona el conjunto de hiperparámetros que produce mejor rendimiento promedio.

Se define un grid de hiperparámetros que incluyen entre ellos  $\gamma$ ,  $C$ , y  $\epsilon$  que seguirán una distribución uniforme. Se ajusta después el modelo al conjunto de datos utilizando la búsqueda aleatoria de hiperparámetros y una vez el modelo se haya ajustado, se realiza la predicción de la volatilidad para el último segmento de los datos.

Se utilizan las observaciones excepto las últimas 'n' para el conjunto del entrenamiento del modelo, unos datos buenos en esta parte son parte fundamental del buen rendimiento del modelo.

### 3.3.4.2 Post-procesamiento y análisis de las predicciones SVR

Tras las predicciones, se sigue un proceso similar al del kernel lineal y RBF para el post-procesamiento de las predicciones. Estas predicciones que se han obtenido en el apartado anterior se introducen en un dataframe y tras esto se asignan los índices de tiempo correspondiente a las predicciones para una mejor representación de los datos tras esto.

Todo esto se usa para que tanto la volatilidad histórica como las predicciones del modelo SVR con kernel polinomial tengan índices consistentes, todo ello para una comparación efectiva de ambas gráficas.

Para ver el ajuste que se ha hecho de la predicción, una vez más, se usará el error cuadrático medio (ECM).

### 3.3.4.3 Visualización de los resultados

Tras haber obtenido y procesado los datos, se procede a visualizar y comparar estas predicciones con la volatilidad histórica. Para el resto de la visualización se siguen los pasos que ya se han seguido en capítulos anteriores.

## 3.4 Aplicación en cobertura de riesgo usando Black-Scholes

Se utilizará la ecuación de Black-Scholes introduciendo la volatilidad calculada de 3 meses que se ha predicho en los capítulos anteriores gracias a SVR. Por tanto, se van a utilizar las fórmulas que ya se introdujeron en el marco teórico que ayudaran a un mejor desarrollo y comprensión de código realizado. La estructura para la implementación sería:

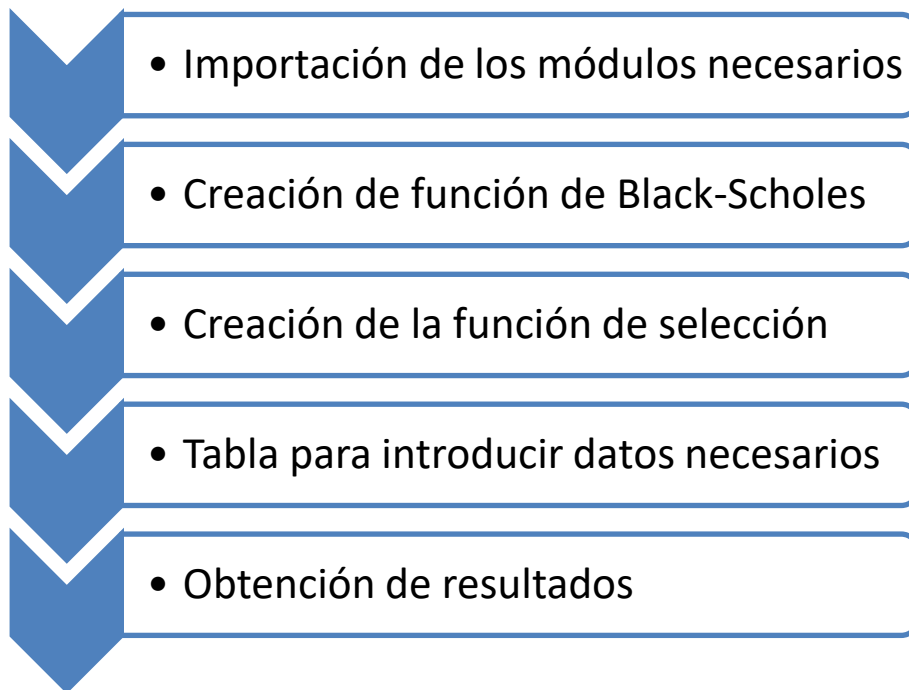


Ilustración 3-11: Estructura Black-Scholes

### 3.4.1 Importación de módulos y bibliotecas

En esta sección, se importarán las bibliotecas necesarias para su uso en *Machine Learning*, cálculo matemático y estadístico.

### 3.4.2 Implementación modelo Black-Scholes

Se va a crear una función que cuando se le introduzcan los parámetros que se describieron en las fórmulas (2.10) y (2.11), devuelva dependiendo del tipo de opción un precio, ya sea para el *call* o el *put*.

Se calcularán entonces en primer momento los valores de  $d_1$  y  $d_2$ , siguiendo la estructura propuesta en la fórmula (2.12) y (2.13), y añadiendo, dependiendo del tipo de opción que se introduzca una resolución mediante la fórmula (2.10) o (2.11), hallando así el valor deseado para sacarlo de la función.

### 3.4.3 Implementación función predicción tipo de opción

Primero se inicializarán los datos sintéticos debido a que no existen datos históricos del precio de las opciones, su duración, tasa sin riesgo...etc. Se fija antes de nada una “semilla”, útil en análisis de datos para la reproducibilidad de los resultados, y estableciendo un número de muestras que se fija previamente a la inicialización del programa. Se utiliza una distribución uniforme para cada uno de los parámetros sintéticos, el objetivo real de este programa sería recopilar datos históricos y que se puedan usar como entrenamiento del modelo.

A continuación, se calculan los precios tanto del *call* como del *put*, con los parámetros sintéticos, creando además un bucle ‘for’ que itera sobre las listas de los parámetros generados de forma aleatoria, añadiendo a las listas ‘p\_call’ y ‘p\_put’. Se preparan después los datos para el entrenamiento del modelo. Una etiqueta de 1 significaría que la opción *call* tiene un precio más alto que la opción *put*, y 0 significaría lo contrario.

En la parte del modelo SVR, se va a usar un kernel lineal, haciendo una búsqueda aleatoria de hiperparámetros de forma óptima, y tras esto se entrena el modelo implementando los datos correspondientes.



Tras entrenar el modelo se comienza a predecir los valores del precio de la opción. Se utiliza el modelo entrenado para predecir si la opción tuviera un precio más alto dado un nuevo conjunto de parámetros, calculando así el precio de la opción usando Black-Scholes y devolviendo el tipo de opción que se debe comprar.

### 3.4.4 Introducción de datos y pago por cobertura

En el código se deja unas variables a rellenar, las cuales se van a rellenar con datos particulares de cada caso que se esté estudiando, aunque hay algunos que por simplificación mantendremos fijos, la tasa libre de riesgo y el tiempo de expedición, la tasa libre de riesgo se consultará en páginas oficiales de los estados en los que se haga el estudio.

Tras esto se introduce el valor que se quiera cubrir y se hace un cálculo del coste que conllevaría la cobertura del riesgo del activo. Gracias a esto se tendrán todas las variables que son importantes para la gestión de la cobertura. Cuando se sabe el número de contratos de opción necesarios para la cobertura, se procede a calcular el costo total asociado con esta estrategia de mitigación de riesgos. Este costo, conocido como la "prima de la opción", es un factor crucial en la toma de decisiones financieras, ya que representa el precio que el inversor debe pagar para obtener protección contra movimientos adversos del mercado. A su vez, la prima de la opción se multiplica por el número de contratos y por el número de acciones que cada contrato cubre, para obtener el costo total de la cobertura.

Además, es esencial tener en cuenta otros costos transaccionales, como comisiones y tasas, que pueden afectar la eficacia de la cobertura, peor en este caso no se van a tener en cuenta. Con todas estas variables en mano, los gestores financieros o inversores individuales pueden evaluar mejor la viabilidad y eficacia de implementar una estrategia de cobertura para proteger sus activos o inversiones. Esta evaluación completa permite una gestión de riesgos más informada y una toma de decisiones más sólida.

## 3.5 Cálculo de la volatilidad mejorado cartera eficiente con Montecarlo

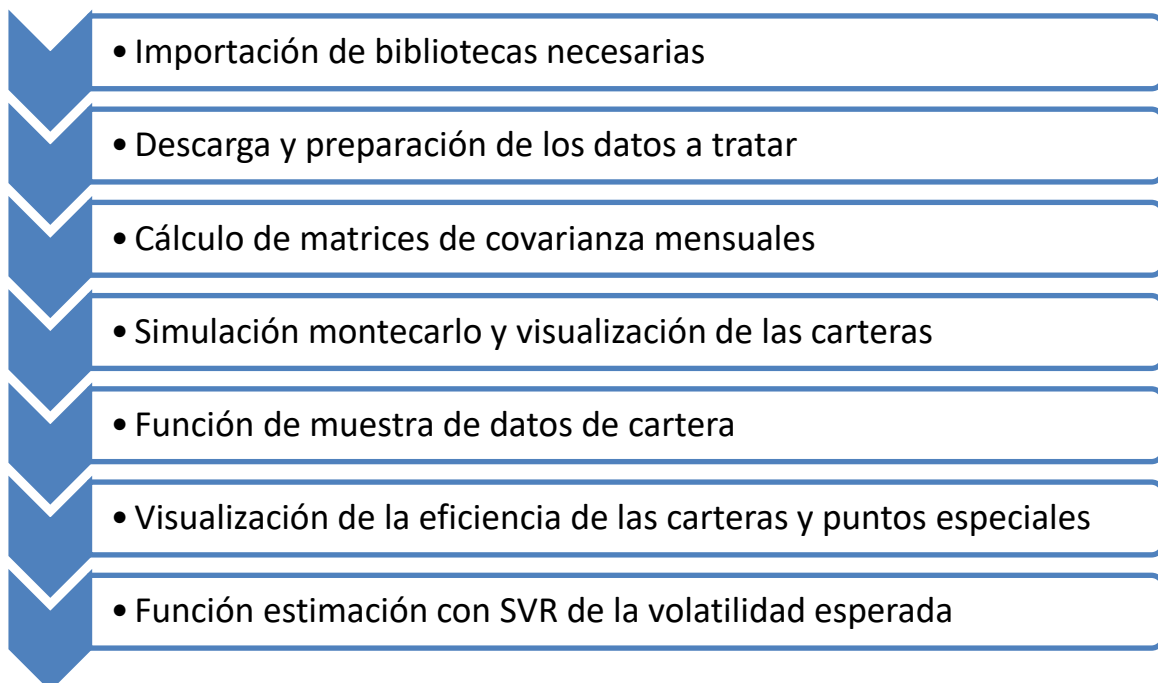


Ilustración 3-12: Estructura Cartera Eficiente con Montecarlo

### 3.5.1 Importación de bibliotecas

En esta sección, se importan varias librerías de Python que se utilizarán a lo largo del código para la realización de distintas tareas, 'pandas', 'numpy', 'matplotlib', 'scipy' y 'yfinance' para la importación y gestión de los datos

necesarios. Cada una de las bibliotecas tienen una labor que contribuirá a distintas fases del proyecto, desde la recolección y el tratamiento de datos hasta el análisis y visualización.

### 3.5.2 Descarga y preparación de datos

En esta sección se comienza con la descarga y el preprocesamiento de los datos financiero para varios activos, comenzando con la selección de estos, descargándolos con 'yfinance' y se usa la columna 'Adj Close' con una fecha por definir.

Los datos descargados se "resamplan" a una frecuencia mensual usando el método 'resample("BMS").first()'. Esto significa que se toma el primer precio de cada mes para cada activo y se calculan los retornos diarios teniendo en cuenta que no haya ningún dato vacío con la función 'dropna ()'.

### 3.5.3 Cálculo de matrices de covarianza mensuales

Se calcula luego las matrices de covarianza mensuales para los retornos diarios de los activos seleccionados.

Para el comienzo de esto se inicializa el diccionario vacío donde se almacenarán las matrices de covarianza para cada mes extrayendo el índice de tiempo de los retornos diarios. A continuación, se realiza un bucle en el cual se crea una máscara booleana, a la vez se calcula la matriz de covarianza para los retornos diarios que cumplen con la máscara temporal y se almacena en el diccionario antes inicializado con la fecha como clave.

### 3.5.4 Simulación Monte Carlo y visualización

Realizaremos una simulación de Monte Carlo para generar diferentes combinaciones de carteras de los activos que se han seleccionado al principio.

Como en el apartado anterior se inicializan tres diccionarios que almacenarán los retornos, volatilidades y pesos de cada simulación de las carteras. Se realiza un bucle 'for' que genere tantas iteraciones como introduzcamos, lo cual requerirá más tiempo generando retornos, volatilidades y pesos que luego habrá que almacenar para representarlo de forma gráfica para ver la distribución de las carteras en ejes de volatilidad y retorno respectivamente.

### 3.5.5 Función para mostrar información de una cartera

Esta función tiene como objetivo mostrar información detallada de una cartera para una fecha determinada.

La estructura se comienza introduciendo dos argumentos, la fecha y el identificador de la cartera, se extraen después los pesos utilizando su respectivo diccionario al igual que se hará con el retorno y la volatilidad.

Finalmente se itera sobre los 'ticker' y los pesos para la posterior impresión en consola el peso a cada cartera.

### 3.5.6 Visualización de la eficiencia de las carteras y puntos especiales

Se vuelve a representar el gráfico de dispersión con todas las carteras, pero esta vez se van a añadir identificadores de puntos especiales como el máximo retorno, mínima volatilidad y máximo ratio de Sharpe, mostrándose luego en la gráfica estos puntos con distintos colores para mejor visualización. Finalmente se escribe por pantalla el porcentaje de importancia que cada activo tendrá en la cartera, incluyendo su volatilidad y rendimiento esperado.

### 3.5.7 Función estimación con SVR de la volatilidad esperada

Para predecir la volatilidad esperada de la cartera según los cálculos de la volatilidad a los que se ha llegado en

el modelo SVR-GARCH se elabora una función que mediante la fórmula (2.14) consiga esta nueva volatilidad de la cartera con los datos futuros predichos.

En esta función se introducirán los valores de los pesos de las acciones dentro de la cartera, las volatilidades predichas por SVR-GARCH y la matriz de covarianza, trasladando así tras la llamada a la función el valor de la volatilidad predicha de la cartera con mayor ratio de Sharpe.

Tras esto se concluye la metodología utilizada para la posterior obtención de los resultados, en ella se ha hecho una estructuración de los procesos que se deben seguir para obtener unos resultados fiables, detallando de manera más exhaustiva el camino que se debe recorrer para obtener la predicción de la volatilidad que se quiere aplicar en la teoría de Black-Scholes y la teoría de cartera eficiente. En el siguiente capítulo se obtendrán los resultados y se hará una valoración de estos, comparando los resultados de los análisis de cada modelo y eligiendo el que mejor se adapta al problema planteado.



# 4 RESULTADOS

---

Encontrar resultados positivos no siempre es el objetivo de un trabajo de investigación, pero siempre es imprescindible que se muestren para tener una visión general de en qué ha resultado toda la metodología que se ha aplicado en la realización de un proyecto. En este caso, los resultados serán de vital importancia debido a que realizamos una previsión de sucesos que o aún no han ocurrido o no se tienen datos de ellos.

Se comenzará la exposición de estos resultados de una manera ordenada y revisando todos los datos que se han aportado en los códigos realizados, para ver si es efectiva la predicción de distintos datos en nuestro proyecto.

## 4.1 Desempeño SVR en mejora de ARCH y GARCH

### 4.1.1 Empresa A

A la hora de desglosar los resultados de los procesos de mejora de ARCH y GARCH, se va a comparar el error cuadrático medio de los resultados obtenidos entre ellos, llegando así a la conclusión de cuál recoge mejor el comportamiento real que tendrá la volatilidad. Estos resultados incluirán cada uno de los ETFs que se pretende estudiar por la empresa A.

Para el caso del ETF de 'ticker' (DBA) se dan los siguientes resultados:

- ARCH: en la ilustración se puede ver como se tienen muchos valores pero en este caso se utilizarán solo algunos de estos datos para ver la efectividad del modelo, en este caso se ve cómo los criterios de información BIC y AIC son de orden similar, y en los parámetros de volatilidad que son en los que se centrará el estudio de estos resultados vemos como  $P > |t|$  es extremadamente bajo para omega, mientras tanto no es así para alpha, lo que lleva a la conclusión que para el ARCH(1) omega sería significativo, mientras que por otro lado el alpha[1] no sería estadísticamente significativo al nivel del 5% que es el que se estudia. Por otro lado en la *tabla 4-2* que es en la que se obtienen los mejores parámetros para el modelo que sería ARCH (3) se obtendrán resultados con conclusiones similares, en los cuales AIC y BIC tienen resultados parecidos y sobre todo omega tiene un  $P > |t|$  muy bajo mientras que alpha[1] no es estadísticamente significativo y el resto de alpha sí lo serían. Dándose así, gracias al modelo de ARCH (3) la *gráfica 4-1*, que no sigue de forma muy favorable la volatilidad histórica pero aun así capta de manera altamente efectiva la subida y bajada del pico de volatilidad a mediados del año 2021, su error cuadrático medio resulta ser 0.0725.

```

Zero Mean - ARCH Model Results
=====
Dep. Variable:      Adj Close   R-squared:          0.000
Mean Model:        Zero Mean   Adj. R-squared:     0.001
Vol Model:         ARCH       Log-Likelihood:    -2030.68
Distribution:      Normal     AIC:               4065.36
Method:           Maximum Likelihood BIC:               4076.30
                                     No. Observations:  1756
Date:             Wed, Aug 30 2023 Df Residuals:      1756
Time:             20:20:38      Df Model:          0
                                     Volatility Model
=====
              coef   std err      t      P>|t|    95.0% Conf. Int.
-----
omega         0.5645  3.183e-02   17.732  2.362e-70  [ 0.502, 0.627]
alpha[1]      0.0490  3.219e-02   1.524   0.128 [-1.404e-02, 0.112]
=====

Covariance estimator: robust

```

Tabla 4-1: Resultados ARCH (1), empresa A


```

Zero Mean - ARCH Model Results
=====
Dep. Variable:      Adj Close   R-squared:          0.000
Mean Model:        Zero Mean   Adj. R-squared:     0.001
Vol Model:         ARCH       Log-Likelihood:    -1998.65
Distribution:      Normal     AIC:               4005.31
Method:           Maximum Likelihood BIC:               4027.19
                                     No. Observations:  1756
Date:             Wed, Aug 30 2023 Df Residuals:      1756
Time:             20:20:39      Df Model:          0
                                     Volatility Model
=====
              coef   std err      t      P>|t|    95.0% Conf. Int.
-----
omega         0.4417  2.830e-02   15.611  6.159e-55  [ 0.386, 0.497]
alpha[1]      0.0318  2.627e-02   1.211   0.226 [-1.967e-02, 8.329e-02]
alpha[2]      0.1386  4.209e-02   3.293   9.925e-04  [5.610e-02, 0.221]
alpha[3]      0.0795  3.454e-02   2.301   2.140e-02  [1.177e-02, 0.147]
=====

Covariance estimator: robust

```

Tabla 4-2: Resultados ARCH óptimo, empresa A



Gráfica 4-1: Visualización resultados ARCH óptimo, empresa A


- GARCH: como antes, primero se va a ver el resumen que muestra el código tras ejecutarse en el caso del GARCH(1,1), cuyos resultados son interesantes de evaluar debido a que, por ejemplo, los resultados de BIC y AIC son menores que los del modelo anterior lo que sugiere un mejor ajuste a los datos cuando se ajusta por este modelo. Luego se puede comprobar como el coeficiente de beta [1] es muy cercano al valor de 1, lo que da a entender que la volatilidad sigue siendo persistente a medida que pasa el tiempo. En este caso todos los coeficientes son significativos, lo que conlleva a una utilidad real estadística de todos ellos. En este caso el GARCH (1,1) es el de parámetros óptimos, por lo tanto, su resumen será idéntico al de la *tabla 4-3*. En la *gráfica 4-2* se puede apreciar el ajuste de la predicción a los datos históricos con un error cuadrático medio de 0.0787.

```

Zero Mean - GARCH Model Results
=====
Dep. Variable:      Adj Close      R-squared:          0.000
Mean Model:        Zero Mean      Adj. R-squared:     0.001
Vol Model:         GARCH          Log-Likelihood:    -1968.24
Distribution:      Normal         AIC:                3942.49
Method:           Maximum Likelihood BIC:                3958.90
                                     No. Observations:  1756
Date:             Wed, Aug 30 2023 Df Residuals:       1756
Time:             20:21:51 Df Model:           0
                                     Volatility Model
=====
              coef   std err      t      P>|t|     95.0% Conf. Int.
-----+-----+-----+-----+-----+-----
omega         0.0141  4.402e-03    3.198  1.385e-03  [5.448e-03, 2.270e-02]
alpha[1]      0.0533  1.038e-02    5.138  2.770e-07  [3.299e-02, 7.368e-02]
beta[1]       0.9229  1.200e-02   76.891  0.000     [ 0.899,  0.946]
=====

Covariance estimator: robust
    
```


Tabla 4-3: Resultados GARCH(1), empresa A




Gráfica 4-2: Visualización resultados GARCH óptimo, empresa A

- SVR-GARCH: la mejora del GARCH gracias al modelo SVR es lo que se va a evaluar a continuación teniendo en cuenta los datos que se obtienen de error cuadrático medio con respecto a los modelos de ARCH y GARCH antes obtenidos. En el caso del uso del kernel lineal se obtiene un error cuadrático medio de 0.001063, que se podría considerar muy bajo con respecto a los antes obtenido y se puede ver como gráficamente queda claro en la gráfica 1. Por otro lado, con el kernel RBF se obtienen resultados un poco peores del error cuadrático medio 0.002099, y por último, con el kernel polinomial, el cual tiene un tiempo de ejecución de unos 3 minutos, mucho más que los anteriores y mejora el error cuadrático medio obtenido con el kernel RBF pero no mejora el obtenido en el lineal.






Gráfica 4-3: Visualización resultados SRV-GARCH lineal, empresa A



Gráfica 4-4: Visualización resultados SRV-GARCH rbf, empresa A



Gráfica 4-5: Visualización resultados SRV-GARCH polinomial, empresa A

#### 4.1.2 Empresa B

Se realizará el mismo estudio, pero ahora con un ETF relacionado con el mercado de la inteligencia artificial que tiene como 'ticker' (BOTZ).

- ARCH: en este caso para el modelo de ARCH (1) se obtienen unos parámetros alpha [1] y omega significativos debido a su  $P > |t|$  extremadamente baja en ambos casos. Debido a esto se puede saber que se está capturando la volatilidad en los datos. Por otro lado, se tienen valores de AIC y BIC similares entre sí, y con valores de 4680.98 y 4690.77 respectivamente, lo que va a servir para comparar estos resultados con los del modelo de GARCH (1,1) para ver el que mejor se ajusta. En el caso de los parámetros óptimos del modelo en este caso  $p=4$ , por lo que el modelo será ARCH (4), y se obtienen resultados para los 4 valores de alpha estadísticamente significativos, al igual que de omega. El error cuadrático medio obtenido en este caso es 0.13 alto en comparación con los resultados anteriores, y se puede ver que no es un dato muy bueno de error en la propia gráfica, que aun siguiendo de forma efectiva subidas y bajadas, los picos toman valores demasiado alejados de la realidad.

```

Zero Mean - ARCH Model Results
=====
Dep. Variable:      Adj Close   R-squared:          0.000
Mean Model:        Zero Mean   Adj. R-squared:     0.001
Vol Model:         ARCH       Log-Likelihood:    -2338.19
Distribution:      Normal     AIC:               4680.38
Method:           Maximum Likelihood BIC:               4690.77
                                     No. Observations:  1335
Date:             Wed, Aug 30 2023 Df Residuals:      1335
Time:            18:44:55      Df Model:          0
                                     Volatility Model

=====
              coef    std err          t      P>|t|    95.0% Conf. Int.
-----
omega         1.3950     0.206     6.768  1.303e-11 [ 0.991,  1.799]
alpha[1]      0.4079    9.444e-02   4.319  1.566e-05 [ 0.223,  0.593]
=====

Covariance estimator: robust

```

Tabla 4-4: Resultados ARCH(1), empresa B

```


Zero Mean - ARCH Model Results
=====
Dep. Variable:      Adj Close   R-squared:          0.000
Mean Model:        Zero Mean   Adj. R-squared:     0.001
Vol Model:         ARCH       Log-Likelihood:    -2215.23
Distribution:      Normal     AIC:               4440.46
Method:           Maximum Likelihood BIC:               4466.45
                                     No. Observations:  1335
Date:             Wed, Aug 30 2023 Df Residuals:      1335
Time:            18:44:55      Df Model:          0
                                     Volatility Model

=====
              coef    std err          t      P>|t|    95.0% Conf. Int.
-----
omega         0.5627    7.135e-02   7.886  3.108e-15 [ 0.423,  0.703]
alpha[1]      0.1589    4.640e-02   3.425  6.154e-04 [6.797e-02,  0.250]
alpha[2]      0.1704    4.747e-02   3.590  3.308e-04 [7.738e-02,  0.263]
alpha[3]      0.1453    3.798e-02   3.827  1.297e-04 [7.091e-02,  0.220]
alpha[4]      0.3336    9.243e-02   3.610  3.065e-04 [ 0.152,  0.515]
=====

Covariance estimator: robust

```

Tabla 4-5: Resultados ARCH óptimo, empresa B



Gráfica 4-6: Visualización ARCH óptimo, empresa B

- GARCH: para el GARCH (1,1) se obtienen 3 parámetros, el omega resulta no ser significativo debido a que  $P > |t|$  para considerar un parámetro estadísticamente significativo debe ser menor de 0.05, después alpha [1] es significativo y beta [1] es altamente significativo ya que el valor obtenido es  $1.419e-90$ . En comparación al modelo de ARCH este tiene los valores de BIC y AIC más bajos por lo que se presupone que el modelo de GARCH tendría mejor ajuste a los datos. El coeficiente de beta [1] cercano a 1 nos sugiere que la volatilidad es bastante persistente a lo largo del tiempo. En este caso los parámetros de p y q óptimos son de 1. En el error cuadrático medio se ve una pequeña mejora con respecto al anterior que se refleja en la gráfica viendo como los picos de volatilidad no son tan pronunciados.

```


Zero Mean - GARCH Model Results
=====
Dep. Variable:      Adj Close    R-squared:          0.000
Mean Model:        Zero Mean     Adj. R-squared:     0.001
Vol Model:         GARCH         Log-Likelihood:    -2183.68
Distribution:      Normal        AIC:                4373.36
Method:           Maximum Likelihood    BIC:                4388.95
                                           No. Observations:  1335
Date:             Wed, Aug 30 2023    Df Residuals:      1335
Time:             18:44:56           Df Model:           0
                                           Volatility Model

=====
              coef    std err          t      P>|t|     95.0% Conf. Int.
-----
omega         0.0363    2.114e-02     1.718   8.575e-02  [-5.109e-03, 7.775e-02]
alpha[1]      0.1247    3.693e-02     3.376   7.364e-04  [5.229e-02, 0.197]
beta[1]       0.8623    4.273e-02    20.182  1.419e-90  [ 0.779, 0.946]
=====

Covariance estimator: robust


```

Tabla 4-6: Resultados GARCH óptimo, empresa B




Gráfica 4-7: Visualización GARCH óptimo, empresa B


- SVR-GARCH: SVR-GARCH: la mejora del GARCH gracias al modelo SVR es lo que se va a evaluar a continuación teniendo en cuenta los datos que se obtienen de error cuadrático medio con respecto a los modelos de ARCH y GARCH antes obtenidos. En el caso del uso del kernel lineal se obtiene un error cuadrático medio de 0.000726, que se podría considerar muy bajo con respecto a los antes obtenido y se puede ver como gráficamente queda claro en la *gráfica 4-8*. Por otro lado, con el kernel RBF se obtienen resultados un poco peores del error cuadrático medio 0.001354, y por último, con el kernel polinomial, el cual tiene un tiempo de ejecución de unos 3 minutos, mucho más que los anteriores y empeora el error cuadrático medio obtenido con el kernel RBF, que da 0.003638 pero no mejora el obtenido en el lineal.



Gráfica 4-8: Visualización resultados SRV-GARCH lineal, empresa B



Gráfica 4-9: Visualización resultados SRV-GARCH rbf, empresa B



Gráfica 4-10: Visualización resultados SRV-GARCH polinomial, empresa B

Tras estos resultados se vuelve a reafirmar el buen entrenamiento del modelo y la predicción precisa del modelo SVR-GARCH, obteniéndose unos resultados fiables y aplicables en el resto de las herramientas para la cobertura del riesgo.

Por tanto, se obtienen unos muy buenos resultados del SVR-GARCH con respecto a los modelos anteriores, obteniéndose para la empresa A errores cuadráticos medios para el ARCH y GARCH de 0.0725 y 0.0787 respectivamente mientras que para el SVR-GARCH con kernel lineal, rbf y polinomial de 0.001063, 0.002099 y 0.00

Por otro lado, para la empresa B se obtienen estos otros para el ARCH y GARCH de 0.1337 y 0.1292 respectivamente mientras que para el SVR-GARCH con kernel lineal, rbf y polinomial de 0.000726, 0.0099 y 0.003668. Estos resultados se obtienen bajo las condiciones ya descritas en la metodología

Con esto la mayor parte del trabajo está acabada, ahora solo queda incorporar la volatilidad predicha del modelo lineal en cada una de las ecuaciones y modelos para mejorar la visión por parte de las empresas del comportamiento del mercado. Gracias al uso de los ETFs se podrá prever desajustes del mercado y picos alto de volatilidad que suelen crear inestabilidad financiera y adoptar las medidas necesarias para así hacer que la empresa tenga un recurso más por el cuál guiarse a la hora de afrontar su día a día.

Tras esto se va a continuar con la incorporación de los datos obtenidos en este apartado a la teoría de Black-Scholes y a la de la cartera moderna. Se extraen así los datos de la predicción de los resultados obtenidos por pantalla en esta parte.

## 4.2 Resultados de SVR en la cobertura con opciones y Black-Scholes

Con Black-Scholes se va a estudiar qué tipo de opción se debe adquirir y dependiendo de la cantidad que se quiera tener cubierta, cuánto se debe pagar para estar protegidos ante el riesgo de inflación, este riesgo se implementará en el modelo gracias a la tasa de interés real, y aplicando los pasos dados en la metodología en el código poder implementar la volatilidad predicha para la mejora del cálculo del precio del tipo de opción y posteriormente ver si es mayor o menor que la ofrecida por el mercado. Como en el apartado anterior se van a estudiar el caso de las dos empresas que se están estudiando con los respectivos ETF.

#### 4.2.1 Empresa A

El resultado de la volatilidad media de los 3 primeros meses de 2023 para el ETF de 'ticker' (DBA) será de 11.20% como se muestra en la *tabla 4-7*. Esta volatilidad se introducirá en el código de Black-Scholes y se pondrán los valores que sean necesarios para completar la ejecución. En este caso se introducen los datos dados en la *tabla 4-8*.

Precio del activo	21.80€
Precio del ejercicio	20€
Tiempo de expiración	3 meses
Tasa de interés real (30-08-23)	4.25%
Volatilidad predicha (DBA) (3 meses)	11.192562%
Cantidad a cubrir	100000
Cobertura por opción	100

Tabla 4-7: Datos introducidos Black-Scholes, empresa A

Tras introducir todos estos datos se obtienen los siguientes resultados:

Tipo de opción	Precio de la opción	Número de opciones	Coste cobertura
Call	4.56€	1000	4564.25€

Tabla 4-8: Resultados obtenidos Black-Scholes, empresa A

Estos son las variables que se deberían tener en cuenta según el modelo ejecutado, lo que daría una visión más realista de la volatilidad futura. Como para estos datos la opción de compra se ofrece a 2.29€ según *Yahoo Finance* se podría considerar que esta opción está subvalorada, por lo que se podría considerar comprarla a este precio más bajo con la expectativa de que su valor real se acerque más al calculado por el modelo con el tiempo.

#### 4.2.2 Empresa B

El resultado de la volatilidad media de los 3 primeros meses de 2023 para el ETF de 'ticker' (BOTZ) será de 12.59% como se muestra en la Ilustración. Esta volatilidad se introducirá en el código de Black-Scholes y se pondrán los valores que sean necesarios para completar la ejecución. En este caso se introducen los datos dados en la tabla.

Precio del activo (30-08-23)	26.77€
Precio del ejercicio	20€
Tiempo de expiración	3 meses



Tasa de interés real (30-08-23)	4.25%
Volatilidad predicha (DBA) (3 meses)	24.3138%
Cantidad a cubrir	100000
Cobertura por opción	100

Tabla 4-9: Datos introducidos Black-Scholes, empresa B

Tras introducir todos estos datos se obtienen los siguientes resultados:

Tipo de opción	Precio de la opción	Número de opciones	Coste cobertura
Call	10.02€	1000	10025.74€

Tabla 4-10: Resultados obtenidos Black-Scholes, empresa B

Estos son las variables que se deberían tener en cuenta según el modelo ejecutado, lo que daría una visión más realista de la volatilidad futura. Como para estos datos la opción de compra se ofrece a 7€ según *Yahoo Finance* se podría considerar que esta opción está subvalorada, por lo que se podría considerar comprarla a este precio más bajo con la expectativa de que su valor real se acerque más al calculado por el modelo con el tiempo.

### 4.2.3 Conclusiones

Al buscar protección contra una potencial disminución en el valor de las acciones de una empresa, el costo de las opciones de compra puede variar significativamente dependiendo de la volatilidad del mercado en el que opera la empresa. En el caso de la empresa B, que se encuentra en un mercado más inestable, las opciones de compra serán más costosas. Esta mayor inestabilidad se cuantifica a través de la volatilidad, una métrica estadística que refleja el grado de variación de un instrumento financiero en un periodo determinado. Por otro lado, la empresa A opera en un mercado más estable, lo que se traduce en un menor costo para las opciones de compra como forma de cobertura. La reducción en el precio de estas opciones se debe a la menor volatilidad del mercado, lo que a su vez indica un riesgo más bajo de fluctuaciones drásticas en el precio de las acciones.


## 4.3 Resultado introducción de la volatilidad predicha en la teoría de cartera moderna

### 4.3.1 Empresa A

Para optimizar la cartera de inversiones en la empresa A, se incorporarán tres ETFs especializados en el sector agrario, tal como se describió en la metodología previamente establecida. Adicionalmente, se añadirá a la cartera el ETF 'ETX', que rastrea el rendimiento del índice S&P 500. El objetivo de esta estrategia es diversificar el portafolio y minimizar el riesgo.

Para determinar la composición óptima de la cartera, se calcularán los pesos de cada activo basándose en el ratio de Sharpe. Este indicador financiero se empleará como criterio principal para seleccionar entre diferentes opciones de inversión, ya que mide el rendimiento ajustado al riesgo. De esta manera, se buscará la combinación de activos que ofrezca el mayor ratio de Sharpe, con el fin de maximizar el rendimiento potencial mientras se controla el nivel de riesgo asociado.

Tras la ejecución del código resulta la siguiente gráfica con los puntos más representativos que se han querido destacar, dependiendo del perfil de riesgo. Los puntos, que representan las carteras, seguirán un código de colores donde el punto de mejor ratio de Sharpe se colorea de azul más fuerte, el de mayor rentabilidad sería el amarillo y el de menor riesgo de rojo.



Gráfica 4-11: Montecarlo empresa A

Se obtienen a continuación los pesos en la siguiente que quedan definidos en la siguiente tabla:

ETX	BOTZ	AIQ	THNQ
1.38%	90.55%	3.33%	4.74%

Volatilidad cartera	13.01%
Retorno de la cartera	0.0241

	ETX	DBA	CORN	TAGS
Volatilidad Predicha SVR	13.62%	12.468%	23.91%	18.224%


Tabla 4-11: Datos para incorporar a TCM, empresa A

Y con esto se obtiene en el programa una volatilidad para la cartera de un 11.35%, por tanto, se corre un menos riesgo de lo que se esperaba en un principio. Conocer unas variables más cercanas a lo que pasará siempre puede ayudar a tomar mejores decisiones en cualquier ámbito, y la ayuda del modelo SVR para la predicción de la volatilidad proporciona herramientas útiles a la empresa A para la mejor diversificación y la obtención de datos más próximos a la realidad.

### 4.3.2 Empresa B

Para la optimización de cartera en la empresa B, se van a introducir los 3 ETF de los que se habló en la metodología que hacen un seguimiento del mercado de la inteligencia artificial y a parte para introducir se va a introducir el ETF que hace el seguimiento del S&P500 'ETX' al igual que en el apartado anterior. Se encuentra entonces los pesos de cada una de las acciones en la que tiene el mejor ratio de Sharpe que será el indicador que se utilizará para escoger una u otra en este caso.

Tras la ejecución del código resulta la siguiente gráfica con los puntos más representativos que se han querido destacar, dependiendo del perfil de riesgo.



Gráfica 4-12: Montecarlo empresa B

Se obtienen a continuación los pesos en la siguiente que quedan definidos en la siguiente tabla:

ETX	BOTZ	AIQ	THNQ
90.04%	1.84%	5.14%	2.98%

Volatilidad cartera	18.1%
Retorno de la cartera	0.0549

	ETX	BOTZ	AIQ	THNQ
Volatilidad Predicha SVR	13.62%	20.478%	18.65%	20.85%

Gráfica 4-13: Datos a introducir en Markowitz, empresa B

Y con esto se obtiene en el programa una volatilidad para la cartera de un 17.27%, por tanto, se corre un mayor riesgo de lo que se esperaba en un principio. Conocer unas variables más cercanas a lo que pasará siempre puede

ayudar a tomar mejores decisiones en cualquier ámbito, y la ayuda del modelo SVR para la predicción de la volatilidad proporciona herramientas útiles a la empresa B para la mejor diversificación y la obtención de datos más próximos a la realidad.

# 5 DISCUSIÓN

---

## 5.1 Conclusiones

El objetivo de la realización de este trabajo ha sido la comparación de la eficacia de los modelos ARCH, GARCH y el modelo híbrido SVR-GARCH en la predicción de la volatilidad de ETF, para hacer una cobertura de riesgo eficiente intentando predecir la volatilidad futura e implementándola a modelos y ecuaciones tradicionales.

Los resultados sugieren que los tres modelos son capaces de predecir la volatilidad con una precisión decente, pero de forma muy destacada se encuentra el modelo SVR-GARCH, que ha mostrado un mejor rendimiento tras ser medido por herramientas de control y evaluación.

Es cierto que el modelo SVR-GARCH, al ser más reciente, deberá superar a los modelos más antiguos como ARCH o GARCH. Sin embargo, la efectividad de estos modelos puede variar dependiendo del contexto y los datos específicos con los que se esté trabajando. El modelo SVR-GARCH es especialmente eficaz cuando se trata con series temporales financieras con estructuras más complejas que no son fáciles de capturar por los modelos antiguos.

Habría quizás casos donde los datos son relativamente estables y muestran una volatilidad constante en el tiempo, ya que en este caso podría ser beneficioso debido a la simplicidad y menor coste computacional. Además, estos modelos tienen mucha más literatura de soporte.

Al implementar en la ecuación de Black-Scholes la volatilidad predicha por este modelo se puede intuir que los resultados de esta ecuación mejorarán ayudando a las empresas en su desempeño financiero e intentando que tomen así la mejor decisión de cobertura ante el riesgo de inflación, que se representa mediante la tasa de interés real.

En la aplicación de esta volatilidad predicha a la teoría de la cartera moderna, se han encontrado resultados mejorados en la predicción futura de la volatilidad que esta presentará, lo que da una mejor visión a la hora de hacer una inversión diversificada con activos que siguen la tendencia del mercado del que la empresa forma parte.

Por tanto, las dos empresas estudiadas deberían mejorar la medición de la volatilidad en el corto plazo, lo que les ayudará a mejorar a la hora de cubrir los riesgos que se toman en el día a día con las distintas operaciones financieras.

## 5.2 Limitaciones del enfoque propuesto

Se han encontrado diferentes limitaciones a la hora de afrontar este trabajo. La bibliografía sobre el tema es escasa, por lo que, a la hora de encontrar una estructura óptima para la resolución de los problemas, ha resultado complejo encontrar una solución fiable, por lo que las horas de prueba y error se han incrementado considerablemente. Otra de las limitaciones fundamentales en este trabajo ha sido la falta de datos históricos en las opciones financieras y la relativa novedad de algunos de los ETFs utilizados.

La falta de datos históricos en las opciones financieras no nos ha permitido la completa validación de los resultados obtenidos en este trabajo, se han consultado diferentes fuentes para intentar lograr encontrar estos datos, pero ha resultado imposible. Además, como se ha comentado antes los ETFs, son activos financieros complejos que la completa incorporación al mercado es relativamente nueva, por lo que no se pueden entrenar los modelos con un cierto margen histórico.

## 6 LÍNEAS FUTURAS DE INVESTIGACIÓN Y AMPLIACIÓN

---

**T**ras la finalización del trabajo surgen ideas y líneas de investigación paralelas con respecto a la implementación de nuevos modelos, utilización de un mayor número de datos y variables...etc. Algunas de estas se enumeran a continuación.

1. Existen múltiples modelos que surgen del ARCH, cada uno con sus respectivas características, puntos fuertes y flaquezas, se podrían implementar en el estudio para obtener un abanico mucho más amplio de las opciones que se tienen para la predicción de la volatilidad futura.
2. A parte del modelo SVM hay múltiples opciones de predicción de series temporales, se podrían implementar y comprobar el grado de aceptación que tendrían en el trabajo desempeñado.
3. El *Machine Learning* es una tecnología más de muchas otras aplicadas al aprendizaje automático que permiten optimizar, planificar y reconocer patrones. Se podrían utilizar también modelos de *Deep Learning* y comprobar si se mejoran los resultados de una forma eficiente.
4. Añadir datos de las opciones financieras sería una de las cosas más interesantes para la futura ampliación de este trabajo. Se podría hacer un seguimiento semanal de estas opciones y hacer una base de datos suficiente para plantear una prueba y ver si se mejoran los resultados.
5. A parte de ETFs existen otros elementos financieros que pueden ayudar a predecir el comportamiento de un determinado mercado, la inversión en divisas, fondos indexados, futuros y demás, podría ser una opción a la hora de afrontar esta cuestión
6. Se podrían implementar un mayor número de estimadores para comprobar la validez de los modelos, aunque en este trabajo se ha trabajado con herramientas sencillas que dan una visión bastante cercana a la realidad.
7. Existiría la opción de trabajar con apalancamientos, pero se entiende que las empresas no querrían correr ese tipo de riesgos, por lo que se optó por activos financieros con menos riesgo, aunque la utilización del apalancamiento podría ser interesante para el estudio.
8. Yahoo Finance tiene un número muy limitado de información sobre ETFs, solo cuenta con los más famosos por lo que ampliar el número de datos obtenidos podría ser interesante para futuras investigaciones de otro tipo de empresas.

## REFERENCIAS

- [1]Alberto, Mario, & Ríos, G. (2002). La inflación: Una discusión sobre sus causas y efectos. *Páginas: Revista Académica e Institucional de La UCPR, ISSN-e 0121-1633, N.º. 63, 2002, 63, 4*. Retrieved from <https://dialnet.unirioja.es/servlet/articulo?codigo=4897938&info=resumen&idioma=SPA>
- [2]Black, F., & Scholes, M. (1973). The Pricing of Options and Corporate Liabilities. *Source: The Journal of Political Economy, 81(3)*, 637–654.
- [3]Blanchard, O. (2017). *Macroeconomía* (J. I. García de Paso, Ed.; 7<sup>ed</sup>) [Book]. Madrid [etc: Pearson Education.
- [4]Bollerslev, T. (1986). GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSKEDASTICITY. *Journal of Econometrics, 31*, 307–327.
- [5]Cárdenas, J. M. (2018). *EL MACHINE LEARNING A TRAVÉS DE LOS TIEMPOS, Y LOS APORTES A LA HUMANIDAD DENNIYE HINESTROZA RAMÍREZ*.
- [6]Carta Financiera. (2023). *Los 3 mejores ETFs de Inteligencia Artificial del año | Investing.com*. Retrieved from <https://mx.investing.com/analysis/los-3-mejores-etfs-de-inteligencia-artificial-del-ano-200466562>
- [7]Dixon, M. F. (2020). *Machine Learning in Finance : From Theory to Practice* (M. F. Dixont, H. Igor, & P. Bilokon, Eds.; 1st edition) [Book]. Switzerland: Springer International Publishing.
- [8]Elton, E. J. (1995a). *Modern portfolio theory and investment analysis* (M. J. Gruber, Ed.; 5th ed.) [Book]. New York [etc: John Wiley and Sons.
- [9]Elton, E. J. (1995b). *Modern portfolio theory and investment analysis* (M. J. Gruber, Ed.; 5th ed.) [Book]. New York [etc: John Wiley and Sons.
- [10]Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, 987-1007.
- [11]Ferguson, N. (2000). *The House of Rothschild: Volume 2: The World's Banker: 1849-1999* (Vol. 2). Penguin.
- [12]Fernández, P. (2008). *Opciones, futuros e instrumentos derivados* / [Book]. Bilbao: Deusto,.
- [13]G. V. D. (2023). *La inflación fuerza el mayor cierre de empresas en España en las últimas tres décadas*. 10/02/2023. Retrieved from <https://www.abc.es/economia/inflacion-fuerza-mayor-cierre-empresas-espana-ultimas-20230210101424-nt.html>
- [14]Gómez J. (2018). *Cuando a las empresas les suben los costes*. Retrieved from [https://blogs.elconfidencial.com/mercados/rumbo-inversor/2018-10-25/empresas-costes-factores-de-produccion\\_1635292/](https://blogs.elconfidencial.com/mercados/rumbo-inversor/2018-10-25/empresas-costes-factores-de-produccion_1635292/)
- [15]Gregory, S., Hmn, R., Roberts, B., & Greene, K. (2020). *Hyperinflation in Venezuela: How to Address the Problem*.
- [16]Harl, K. W. (1996). *Coinage in the Roman Economy, 300 BC to AD 700*. JHU Press.
- [17]Hamilton, E. J. (1934). *American treasure and the price revolution in Spain, 1501-1650*. Harvard University Press.
- [18]Jurczenko, E. (2020). *Machine learning for asset management : new trends and challenges* (E. Jurczenko, Ed.) [Book]. London, England ; ISTE.
- [19]Karasan, A. (2021). *Machine Learning for Financial Risk Management with Python*. " O'Reilly Media, Inc."

- [20]Nelder, J. A., & Mead, R. (1965). A simplex method for function minimization. *The computer journal*, 7(4), 308-313.
- [21]Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77–91.
- [22]Markowitz, H. (2009). Portfolio selection. *Harry Markowitz: Selected Works*, 15–30. doi: 10.2307/2975974
- [23]Mbah, R. E. (2023). Inflation in North America: A Critical Review and Analysis of the Year 2022 Article in *Advances in Social Sciences Research Journal*. doi: 10.14738/assrj.102.14029
- [24]Mitchell, T. M. (1997). *Machine learning*.
- [25]Mun, J. (2012). *Real options analysis: Tools and techniques for valuing strategic investments and decisions* (Vol. 320). John Wiley & Sons.
- [26]Pérez Rodríguez, J. V. (2016). *Introducción a la modelización de la volatilidad financiera* [Book]. Las Palmas de Gran Canaria: Universidad de Las Palmas de Gran Canaria, Servicio de Publicaciones y Difusión Científica.
- [27]Santillán Veliz, C. A. (2022). *El machine Learning como ventaja competitiva en el desarrollo de sistemas predictivos en el área de la inteligencia artificial* (Bachelor's thesis, Babahoyo: UTB-FAFI. 2022).
- [28]Salas, M. T. (2015). *Venezuela: What Everyone Needs to Know®*. Oxford University Press.
- [29]Sharpe, W. F. (1964). CAPITAL ASSET PRICES: A THEORY OF MARKET EQUILIBRIUM UNDER CONDITIONS OF RISK. *The Journal of Finance*, 19(3), 425–442.
- [30]Shawe-Taylor, J. (2012). *Kernel methods for pattern analysis* (N. Cristianini, Ed.; 1st. publ., 6th p...) [Book]. New York: Cambridge University Press.
- [31]Vapnik, V. N. (Vladimir N. (1995). *The nature of statistical learning theory* [Book]. New York: Springer. doi: 10.1007/978-1-4757-2440-0
- [32] Yahoo Finance. (s. f.). Yahoo Finance. Recuperado 4 de septiembre de 2023, de <https://es.finance.yahoo.com/>









