

Trabajo Fin de Grado en Finanzas y Contabilidad

Cartera óptima con índices energéticos: ¿el mercado incentiva el uso de energías renovables?

Autor

Guillermo Montserrat Sarto

Directores

Jesús Ángel Miguel Álvarez y Pilar Gargallo Valero

Facultad de Economía y Empresa

Universidad de Zaragoza

Enero de 2024

RESUMEN INICIAL

En el contexto actual, la transición hacia fuentes de energía más sostenibles y respetuosas con el medio ambiente es un objetivo primordial, respaldado por la urgencia de enfrentar los desafíos climáticos globales. Desde una perspectiva financiera, conviene garantizar que apoyar la transición energética, además de cumplir con los objetivos medioambientales, también se traducen en incentivos efectivos económicos. En los mercados financieros, resulta crucial verificar hasta qué punto se potencia e incentiva la inversión en energías verdes, ofreciendo oportunidades significativas para inversores y empresas que buscan alinear sus estrategias financieras con criterios de impacto positivo.

En este trabajo se han considerado dos índices bursátiles energéticos como componentes fundamentales para la construcción de una cartera óptima. Para ello, es necesario tener un conocimiento preciso de las volatilidades de cada serie individual y las correlaciones entre ellas. Dado que dichos índices muestran comportamientos heterocedásticos para abordar esta tarea se recurre a modelos de la familia GARCH multivariantes. En concreto, se emplearán modelos VAR-DCC (vector autorregresivo con correlación condicional dinámica) que permiten una adaptación dinámica a las cambiantes condiciones del mercado. En un entorno financiero dinámico y volátil, la disponibilidad de pesos diarios otorga a los gestores de carteras una herramienta necesaria para tomar decisiones informadas y mantener una alineación estratégica con los objetivos financieros a medida que evolucionan las condiciones del mercado.

Los resultados revelan una asignación de pesos significativamente elevada al índice de energías limpias, en comparación con la asignación más modesta al índice de Oil-Gas. Este patrón sugiere un fuerte respaldo a las iniciativas sostenibles y destaca el alineamiento estratégico con la transición energética. Esta distribución de pesos no solo refleja un compromiso con la responsabilidad ambiental, sino que también sugiere un respaldo hacia prácticas más sostenibles y resilientes.

Palabras clave: Cartera óptima, Cambio Climático, Modelos VAR-DCC, Series financieras

ABSTRACT

In the current context, the transition towards more sustainable and environmentally friendly energy sources is a primary objective, supported by the urgency of facing global climate challenges. From a financial perspective, it is important to ensure that supporting the energy transition, in addition to meeting environmental objectives, also translates into effective economic incentives. In financial markets, it is crucial to verify to what extent investment in green energy is promoted and incentivized, offering significant opportunities for investors and companies seeking to align their financial strategies with positive impact criteria.

In this work, two energy stock indices have been considered as fundamental components for the construction of an optimal portfolio. To do this, it is necessary to have precise knowledge of the volatilities of each individual series and the correlations between them. Given that these indices show heteroscedastic behavior, multivariate GARCH family models are used to address this task. Specifically, VAR-DCC (vector autoregressive with dynamic conditional correlation) models will be used that allow dynamic adaptation to changing market conditions. In a dynamic and volatile financial environment, the availability of daily pesos provides portfolio managers with a necessary tool to make informed decisions and maintain strategic alignment with financial objectives as market conditions evolve.

The results reveal a significantly high allocation of weights to the clean energy index, compared to the more modest allocation to the Oil-Gas index. This pattern suggests strong support for sustainable initiatives and highlights strategic alignment with the energy transition. This distribution of weights not only reflects a commitment to environmental responsibility, but also suggests support for more sustainable and resilient practices.

Keywords: Optimal portfolio, Climate Change, VAR-DCC Models, Financial series

INDICE

1. INTRODUCCION	1
2. MARCO TEÓRICO.....	4
3. ESTUDIO EMPÍRICO.....	8
3.1 ANÁLISIS UNIVARIANTE.....	11
3.2 ANÁLISIS BIVARIANTE.....	16
3.3 CÁLCULO DE LOS PESOS DE LA CARTERA FORMADA POR LOS ÍNDICES	21
4. CONCLUSIONES	24
5. BIBLIOGRAFÍA.....	26

INDICE DE TABLAS

Tabla 1. estimación del modelo MA(2)-GARCH(1,1) para el índice CLEAN	12
Tabla 2. Estimación del modelo ARMA(1,1)-GARCH(1,1) para el índice OIL_GAS..	12
Tabla 3. Análisis descriptivo de las series de errores para ambos modelos.....	14
Tabla 4. Test de Kolmogorov-Smirnov para los residuos estandarizados	14
Tabla 5. Test de Ljung-Box para los residuos estandarizados y sus cuadrados.....	15
Tabla 6. Test ARCH para los residuos estandarizados	15
Tabla 7. Estimación del modelo VAR(1).....	18
Tabla 8. Criterio de selección BIC de los modelos.....	19
Tabla 9. Estimación del modelo DCCS-GARCH(1,1)	20
Tabla 10. Rentabilidades trimestrales μ	22

INDICE FIGURAS

Ilustración 1. Índices diarios de las series analizadas.....	9
Ilustración 2. Rentabilidades diarias, en tanto por cien, de las series analizadas.....	11
Ilustración 3. Estudio gráfico de los residuos estandarizados para el índice CLEAN ...	14
Ilustración 4. Estudio gráfico de los residuos estandarizados para el índice OIL_GAS	15
Ilustración 5. Volatilidad estimada de cada índice.....	16
Ilustración 6. Funciones de autocorrelación y de correlación cruzada de ambas series.	17
Ilustración 7. Volatilidad estimada de cada índice y la correlación entre ambas	20
Ilustración 8. Pesos de la cartera óptima	23
Ilustración 9. Volatilidad de la cartera óptima	24

1. INTRODUCCION

El cambio climático, resultante de las emisiones de gases de efecto invernadero originadas de actividades humanas, representa una amenaza urgente. La relación entre el cambio climático y la huella de carbono, que cuantifica las emisiones de gases como el dióxido de carbono, se revela de manera patente. A medida que esta huella experimenta un aumento, se intensifican los impactos negativos en el clima, como el aumento de temperaturas, eventos climáticos extremos y cambios en los patrones meteorológicos. En este contexto, el sector energético adquiere un papel de suma relevancia, al ser tanto factor contribuyente al problema como protagonista en su resolución. La reducción de la huella de carbono se torna esencial para mitigar el cambio climático, demandando la adopción de prácticas más sostenibles y la transición hacia fuentes de energía renovable y tecnologías más limpias en el ámbito energético.

La adopción de tecnologías y prácticas más eficientes en términos energéticos no solo reduce las emisiones de GEI, sino que también puede conducir a ahorros significativos en costes operativos para las empresas. Esto incluye ahorros en energía, materias primas y gestión de residuos, además de permitir a las empresas comerciar con las asignaciones de emisiones, consecuentemente esto crea un incentivo económico para reducir las emisiones, ya que las empresas que logran reducir sus emisiones por debajo de sus asignaciones pueden vender los excedentes a otras empresas lo cual reduce los costes operativos de manera significativa. Además, adoptar prácticas sostenibles y reducir su huella de carbono a menudo experimentan una mejora en su reputación corporativa. Los consumidores valoran cada vez más a las empresas comprometidas con la protección del medio ambiente, lo que puede traducirse en lealtad a la marca y ventajas competitivas.

Dentro de las prácticas sostenibles adoptadas por las empresas, cobra un protagonismo crucial la transición de fuentes de energía sucias o fósiles, como el carbón, petróleo y gas natural, hacia alternativas limpias como la solar, eólica, hidroeléctrica y geotérmica. Esta transición desempeña un papel fundamental en la reducción efectiva de la huella de carbono. La inversión en energías limpias no solo reporta beneficios económicos a los inversores, sino que también genera impactos positivos en la sociedad. Estas fuentes de energía contribuyen significativamente a la mitigación del cambio climático al reducir las emisiones de gases de efecto invernadero. Además, posibilitan la diversificación de la

matriz energética, crean empleo en el sector de energías renovables y reducen la dependencia de los combustibles fósiles.

Es importante destacar que las energías limpias son renovables y sostenibles a largo plazo, ofreciendo una opción viable y segura para el futuro. Este enfoque no solo proporciona beneficios ambientales, sino que también se traduce en estabilidad y seguridad energética. Vale la pena mencionar que la reducción de la dependencia de combustibles fósiles puede contribuir a prevenir conflictos relacionados con recursos energéticos, añadiendo un componente adicional de paz y estabilidad a la ecuación. En este sentido, la inversión en energías limpias no solo se presenta como una opción ambientalmente responsable, sino también como un paso estratégico hacia un futuro más sostenible y pacífico.

Como resumen la inversión en energías limpias radica en varios aspectos clave, que se enumeran a continuación:

Reducción de la huella de carbono: Las energías limpias, como la solar, eólica, hidroeléctrica y geotérmica, emiten menos gases de efecto invernadero en comparación con las fuentes de energía sucia, como los combustibles fósiles. Al invertir en energías limpias, se contribuye a la reducción de la huella de carbono y se mitiga el cambio climático.

Sostenibilidad y disponibilidad a largo plazo: Las fuentes de energía renovable son inagotables y se renuevan naturalmente, lo que las hace más sostenibles a largo plazo. A diferencia de los combustibles fósiles, que son finitos y se agotarán en algún momento, las energías limpias ofrecen una fuente de energía continua y confiable.

Beneficios ambientales: Las energías limpias tienen un impacto ambiental mucho menor en comparación con las fuentes de energía sucia. No solo reduce las emisiones de gases de efecto invernadero, sino que también disminuyen la contaminación del aire y del agua, protegiendo así la salud humana y el medio ambiente en general.

Innovación y crecimiento económico: La transición hacia las energías limpias impulsa la innovación tecnológica y crea oportunidades económicas. El sector de las energías renovables está experimentando un crecimiento exponencial a nivel mundial, lo que genera inversiones significativas y oportunidades de empleo en este campo.

Acceso a la energía: Invertir en energías limpias también es importante para garantizar el acceso a la energía en todo el mundo. Actualmente, millones de personas carecen de

acceso a la electricidad, y las energías limpias pueden desempeñar un papel crucial en la electrificación de áreas rurales y remotas, proporcionando energía asequible y sostenible.

En resumen, invertir en energías limpias es esencial para reducir la huella de carbono, promover la sostenibilidad, proteger el medio ambiente, impulsar la innovación y el crecimiento económico, y garantizar el acceso a la energía para todos. Es una forma clave de abordar los desafíos del cambio climático y construir un futuro más sostenible y habitable para las generaciones futuras.

Todos estos aspectos están impulsando avances sustanciales en la eficiencia y rentabilidad de las energías limpias. Este progreso continuo posiciona a estas fuentes de energía como opciones cada vez más atractivas también desde una perspectiva económica. La innovación tecnológica y la optimización de procesos están contribuyendo a que las energías renovables se vuelvan competitivas en el mercado, lo que refuerza aún más la viabilidad y sostenibilidad económica de estas soluciones. Este aumento en la eficiencia y rentabilidad no solo fortalece el argumento para la inversión en energías limpias, sino que también subraya la importancia de la participación activa del sector financiero en respaldar esta transición hacia un modelo energético más sostenible.

En definitiva, el sector financiero tiene una responsabilidad clave en impulsar esta transición hacia prácticas más sostenibles. La transición energética requiere un flujo continuo de capital hacia tecnologías limpias, y los mercados financieros emergen como actores fundamentales en este proceso, delineando así una ruta hacia un futuro más respetuoso con el medio ambiente.

En cuanto a la importancia de detectar si los mercados apoyan o incentivan a los inversores para apostar por energías limpias es fundamental analizar si los mercados actuales apoyan o incentivan a los inversores a apostar por energías limpias. Si los mercados ofrecen incentivos y oportunidades favorables para invertir en energías limpias, esto puede promover un cambio significativo hacia una economía más sostenible y respetuosa con el medio ambiente. Por otro lado, si los mercados no brindan suficiente apoyo a las energías limpias, es posible que los inversores se inclinen hacia opciones más contaminantes y menos sostenibles. En este sentido, es necesario promover políticas y regulaciones que fomenten la inversión en energías limpias y desincentiven el uso de energías sucias.

En conclusión, la inversión en energías limpias frente a energías sucias juega un papel fundamental en la lucha contra el cambio climático, por tanto, es necesario evaluar si los mercados financieros apoyan o incentivan a los inversores a apostar por energías limpias. Dentro de este contexto, el objetivo fundamental de este trabajo consistirá en construir una cartera óptima dinámica enfrentando un índice de energías limpias y otro de energías sucias. Este enfoque permitirá determinar los pesos óptimos en cada uno de ellos, considerando la evolución dinámica de los mercados y promoviendo así la toma de decisiones financieras alineadas con los acontecimientos actuales.

Para conseguir este objetivo, se comenzará realizando un estudio univariante de los dos índices. Posteriormente, para recoger las relaciones entre ambos se planteará un modelo bivariante que capture las volatilidades y correlaciones dinámicas entre ambos índices. Esta estimación se empleará para aproximar el riesgo de la cartera y así se podrá construir la cartera minimizando dicho riesgo para una rentabilidad dada a priori por el inversor.

En definitiva, la organización de este trabajo es la siguiente. En la Sección 2 se presentan el marco teórico de los modelos empleados, tanto univariantes como bivariantes. En la Sección 3 se realiza el estudio empírico de ambos índices y se presenta la construcción de la cartera de mínimo riesgo, proporcionando los pesos óptimos en cada instante de tiempo analizado. Por último, la Sección 4 contiene las conclusiones más relevantes del trabajo.

2. MARCO TEÓRICO

Desde la perspectiva de que una serie financiera de rentabilidades $\{r_t; t=1, \dots, n\}$ es un proceso estocástico, por lo tanto, se entiende como un conjunto de variables aleatorias relacionadas entre sí y cuya estructura nos permitirá construir adecuadamente las predicciones futuras. En concreto, los modelos autorregresivos de medias móviles, denotados por ARMA(p,q), describen el comportamiento de la rentabilidad media teniendo en cuenta la relación entre las rentabilidades y las noticias no esperadas (errores) ocurridas en el pasado. Su expresión matemática viene dada por:

$$\Phi_p(B)r_t = \mu + \Theta_q(B)\varepsilon_t \quad \text{con} \quad \varepsilon_t \sim N(0, \sigma)$$

siendo $\Phi_p(B) = 1 - \phi_1B - \phi_2B^2 - \dots - \phi_pB^p$ un polinomio de orden p, $\Theta_q(B) = 1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q$ un polinomio de orden q y B es el operador retardo

$(B^j R_t = R_{t-j})$. Por lo tanto, la rentabilidad actual r_t dependerá linealmente de las últimas p rentabilidades ocurridas y de las q últimas noticias no esperadas o errores aleatorios producidos. Estos errores representan un ruido blanco homocedástico (media cero y varianza constante en el tiempo).

Para que el modelo sea estacionario y podamos estimarlo correctamente, tendremos que exigir que las raíces del polinomio $\Phi_p(B)$ de la parte autorregresiva tengan módulo mayor que 1 y, además, que sea invertible, para lo que es necesario que las raíces $\Theta_q(B)$ del polinomio de la parte móvil tengan también un módulo mayor que 1.

La identificación de los posibles modelos ARMA se basa en la construcción de las funciones de autocorrelación (ACF) y de autocorrelación parcial (PACF) de los datos observados, es decir, de las rentabilidades diarias r_t . A continuación, se estimarían dichos modelos analizando la significatividad de los coeficientes o parámetros del modelo, validando los residuos con el objetivo de comprobar que han desaparecido las relaciones lineales y, finalmente, se utilizan criterios de optimización como el criterio de información de Akaike (AIC) y el criterio de información bayesiano (BIC) para seleccionar el modelo óptimo.

En series financieras, como el caso que nos ocupa, un problema fundamental es que la varianza no es constante en el tiempo, por lo tanto, será necesario desarrollar un modelo que explique o intente captar los movimientos temporales en la volatilidad de la serie. En concreto, Engle (1982) fue el pionero en este campo y propuso un proceso autorregresivo para los cuadrados de las series de rentabilidades, llamados modelos ARCH. Sin embargo, se observó que era necesario un gran número de parámetros para una correcta especificación de dicho proceso, dada la persistencia de las noticias no esperadas. Bollerslev (1986) propuso una generalización de los procesos ARCH, llamados modelos GARCH, que permitían introducir un polinomio de los retardos de la varianza condicional similar a la parte de medias móviles de la rentabilidad. Por lo tanto, un modelo GARCH(r,s) para una serie financiera de rentabilidades r_t viene expresado por la ecuación:

$$r_t = \mu + \varepsilon_t \quad \text{con } \varepsilon_t \sim N(0, \sigma_t^2)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^r \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2$$

donde $N(0, \sigma_t^2)$ denota una distribución normal de media cero y varianza σ_t^2 . Para que el proceso esté bien definido se debe cumplir que los coeficientes ω, α_i y β_j sean todos mayores o iguales que cero. Denotando I_{t-1} al conjunto de información disponible hasta el instante $t-1$, es evidente que:

$$E[r_t | I_{t-1}] = \mu$$

$$V[r_t | I_{t-1}] = \sigma_t^2$$

La rentabilidad media condicional es constante en el tiempo, pero la varianza condicional o volatilidad del mercado es variable, dependiendo del instante temporal, y cuyo valor depende el estado anterior de las volatilidades y de las noticias o errores no esperados en el pasado.

Estos modelos se utilizan comúnmente para estimar y pronosticar la volatilidad de los activos financieros, lo cual es crucial para la gestión de riesgos, la fijación de precios de opciones y la optimización de carteras. Así han proliferado una gran cantidad de trabajos científicos ampliando estos modelos, modificando las distribuciones que se emplean para ajustar los errores y las aplicaciones a múltiples series financieras de diferentes mercados. Puede consultarse los artículos de Bollerslev, Chou y Kroner (1992) y Bollerslev, Engle y Nelson (1994) para comprender el auge y la importancia que adquirieron estos modelos.

El modelo GARCH(r,s) anterior se puede formular como un proceso ARMA de los residuos cuadráticos de la serie:

$$\varepsilon_t^2 = \omega + \sum_{i=1}^m (\alpha_i + \beta_i) \varepsilon_{t-i}^2 - \sum_{j=1}^s \beta_j v_{t-j} + v_t \quad \text{con } v_t = \varepsilon_t^2 - \sigma_t^2$$

y denotando $m=\max\{r,s\}$. Por lo tanto, podemos emplear los métodos de identificación, estimación y predicción tradicionales de los modelos ARMA, que han sido ampliamente estudiados, para estudiar la varianza condicional de los mercados financieros. Además, podemos combinar la modelización en media de los modelos ARMA con la explicación de la volatilidad porque ambos procesos son asintóticamente independientes. Esta nueva herramienta permite explicar las características principales de una serie financiera, rentabilidad media y volatilidad, mediante un modelo global llamado ARMA(p,q)-GARCH(r,s) cuya expresión vendría dada por:

$$\Phi_p(B)r_t = \mu + \Theta_q(B)\varepsilon_t \quad \text{con } \varepsilon_t \sim N(0, \sigma_t^2)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^r \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2$$

La identificación del modelo ARMA y del modelo GARCH se puede realizar de forma independiente para determinar los órdenes más recomendables para cada una de las partes con el fin de recoger las dependencias lineales que existan tanto en la media como en la varianza condicional. La estimación se realizará por máxima verosimilitud, estimando puntualmente todos los parámetros necesarios con sus correspondientes errores para contrastar su significatividad. Asimismo, se pueden conseguir criterios de selección de modelos, como el AIC y el BIC, y realizar un análisis residual para validar el modelo propuesto.

El objetivo central de este trabajo es la construcción de una cartera óptima a partir de dos índices de mercado. En este sentido, es necesario conocer no solo las volatilidades asociadas a estos índices, sino también las relaciones de correlación que existen entre ambas, las cuales no son independientes. La evaluación detallada de estas correlaciones resulta esencial, ya que impactan significativamente en la diversificación y, por ende, en el riesgo global de la cartera. La consideración de ambos aspectos, volatilidades y correlaciones, es fundamental para la formulación de una cartera que no solo maximice rendimientos, sino que también minimice de manera eficiente los riesgos derivados de la interacción dinámica entre los índices de mercado. Por todo ello, será necesario plantear un modelo bivariante de series temporales que recoja las fluctuaciones mutuas entre ellas.

En particular, se plantea un modelo VAR para ajustar las rentabilidades de forma conjunta de ambos índices y un modelo de correlación dinámica condicional con modelos GARCH univariantes en cada índice. El modelo en media (para relacionar las rentabilidades de cada índice) que se formula es el VAR(1) (Vector autorregresivo de orden 1):

$$\begin{pmatrix} r_{1,t} \\ r_{2,t} \end{pmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{pmatrix} \begin{pmatrix} r_{1,t-1} \\ r_{2,t-1} \end{pmatrix} + \varepsilon_t$$

Los errores $\varepsilon_t = \begin{pmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \end{pmatrix}$ tienen media 0 ($E[\varepsilon_t] = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$), pero la matriz de varianzas y covarianzas de los errores no puede ser constante porque ambos índices son series heterocedásticas, por lo tanto, dicha matriz H_t es dinámica en el tiempo y emplearemos modelos de correlación dinámica condicional. Para esta parte, se pueden formular varias alternativas que son los modelos CCC (Correlación Condicional Constante), los modelos DCCS (Correlación Condicional Dinámica donde el efecto de los errores es Simétrico) y

los modelos DCCA (Correlación Condicional Dinámica que incorpora asimetrías en la respuesta a los shocks o errores no esperados negativos y positivos).

La formulación de dichos modelos de correlación dinámica es la siguiente:

$$H_t = D_t R_t D_t$$

siendo:

- $D_t = \begin{pmatrix} \sigma_{1,t} & 0 \\ 0 & \sigma_{2,t} \end{pmatrix}$ donde cada elemento es la desviación típica condicional proporcionada por un modelo GARCH(1,1). Por lo tanto, las expresiones son:
 - $\sigma_{1,t}^2 = \omega_1 + \alpha_1 \varepsilon_{1t}^2 + \beta_1 \sigma_{1,t-1}^2$
 - $\sigma_{2,t}^2 = \omega_2 + \alpha_2 \varepsilon_{2t}^2 + \beta_2 \sigma_{2,t-1}^2$
- $R_t = Q_t^{*-1} Q_t Q_t^{*-1}$ con $Q_t^{*-1} = \text{diag}(Q_t)$ es la matriz de correlación dinámica en el tiempo y se expresa como:

$$R_t = \begin{pmatrix} 1 & q_t \\ q_t & 1 \end{pmatrix}$$

- Si el modelo es de correlación constante (CCC) entonces simplemente tenemos un parámetro: $q_t = \text{constante} = q$
- Si el modelo es de correlación dinámica (DCC) entonces, la matriz tiene la siguiente expresión:

$$Q_t = \bar{Q} + a(z_{t-1} z'_{t-1} - \bar{Q}) + b(Q_{t-1} - \bar{Q}) + g z_t^- z_t^-'$$

siendo z_t los residuos estandarizados: $z_t = D_t^{-1} \varepsilon_t$ y con z_t^- solo se consideran los valores negativos. El DCCS impone que $g=0$, es decir, no hay comportamientos diferentes para errores o shocks negativos (pérdidas inesperadas en el mercado) y errores positivos (ganancias inesperadas en el mercado). El DCCA estima el parámetro g y permite que las pérdidas y las ganancias influyan de forma diferente en la volatilidad y correlación condicional.

3. ESTUDIO EMPÍRICO

Las series de datos temporales que se van a analizar para los dos tipos de energías, vulgarmente conocidas como limpias y sucias, son dos índices relacionados con las

energías renovables y con las energías fósiles. Concretamente, dichos índices son S&P Global Clean Energy Index y STOXX Europe 600 Oil & Gas. El periodo analizado va desde el 1 de octubre de 2013 hasta el 30 de octubre de 2023 que suponen 2589 observaciones de la rentabilidad diaria. En el periodo analizado se recogen varios sucesos que posteriormente nombraremos y que afectan directamente a los datos y resultados de ambas series durante dicho periodo.

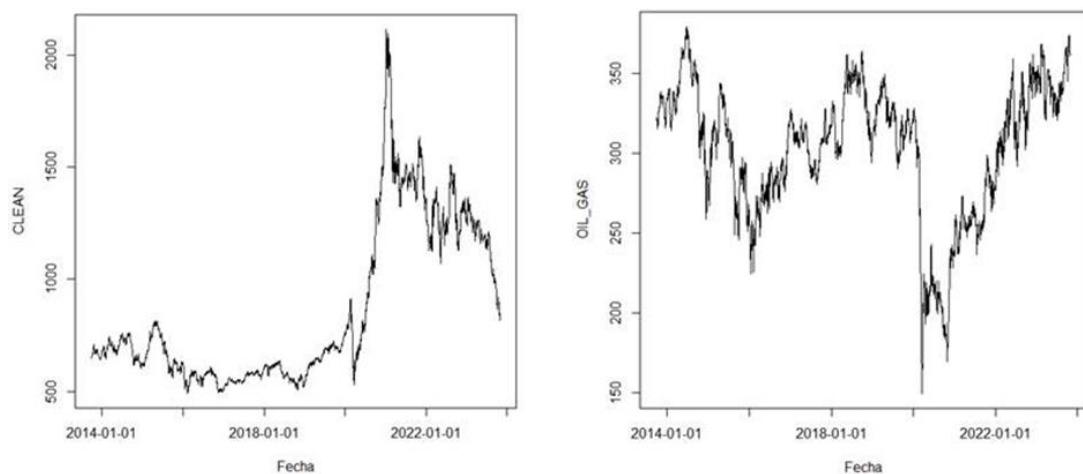
Las series de precios se han recogido en las siguientes páginas web:

<https://www.spglobal.com/spdji/es/indices/esg/sp-global-clean-energy-index/#overview>

<https://es.investing.com/indices/stoxx-europe-600-oil---gas-historical-data>

Dado que los precios, como se pueden observar en los siguientes gráficos, no son series estacionarias tendremos que trabajar con las rentabilidades diarias.

Ilustración 1. Índices diarios de las series analizadas



En estos gráficos podemos ver como al principio del periodo las energías limpias se encontraban muy bajas mientras que las sucias están bastante elevadas y se mantiene así hasta principios del año 2020 donde hay un pequeño máximo que coincidiría con la pandemia de la COVID-19 y lo contrario ocurre con las energías sucias que tienen una pequeña caída.

No obstante, lo más destacado de estos gráficos sucede sobre mediados de febrero del 2022, en la que sucedió el último gran problema mundial de las últimas décadas como es la Guerra de Ucrania, concretando con los datos vemos el gran pico que tienen las energías limpias frente a la gran caída de las energías sucias, esto fue provocado porque dentro de la terrible guerra militar hubo grandes guerras con el tema de las energías.

De hecho, los países de la UE actuaron de manera coordinada para garantizar el suministro de energía y unos precios asequibles, ya que dicha guerra generó preocupación en relación con la seguridad del suministro energético debido a la decisión de Rusia de suspender el suministro de gas a varios Estados miembros de la UE y que contribuyó a crear una alarma social y económica sobre el uso de energías fósiles.

Para hacer frente a los elevados precios de las energías, los ministros de la UE acordaron unas nuevas normas para establecer un mecanismo de corrección del mercado destinado a proteger a los ciudadanos y a la economía frente a precios excesivamente elevados. El Reglamento tiene por objeto limitar los episodios de precios excesivos del gas en la UE que no reflejan los precios del mercado mundial, garantizando al mismo tiempo la seguridad del suministro de energía y la estabilidad de los mercados financieros.

Centrándonos en las energías sucias el Consejo decidió fijar un tope al precio del petróleo para el petróleo crudo, los aceites de petróleo y los aceites de minerales bituminosos originarios o exportados de Rusia, en 60 dólares estadounidenses por barril.

El tope al precio del petróleo ruso tiene por objeto limitar las subidas bruscas de precios provocadas por las condiciones de mercado extraordinarias, y reducir drásticamente los ingresos que Rusia obtiene del petróleo tras desencadenar su guerra ilegal de agresión contra Ucrania. También servirá para estabilizar los precios mundiales de la energía y al mismo tiempo atenuar las consecuencias negativas en el suministro energético de terceros países.

Además, los impactos en la energía causados por la crisis de la COVID-19 se han intensificado en los últimos meses por la invasión rusa a Ucrania, lo que ha generado incertidumbre en los mercados mundiales de petróleo y gas y ha disparado los precios de la energía.

Por otro lado, aumentaron el uso de energías renovables como consecuencia de esta guerra con un aumento de más del 20% del uso de las energías eólica y solar en la Unión Europea (UE), que sustituyó casi el 75% de las importaciones rusas de gas fósil, mientras que el mundo está listo para agregar tanta energía renovable en los próximos años.

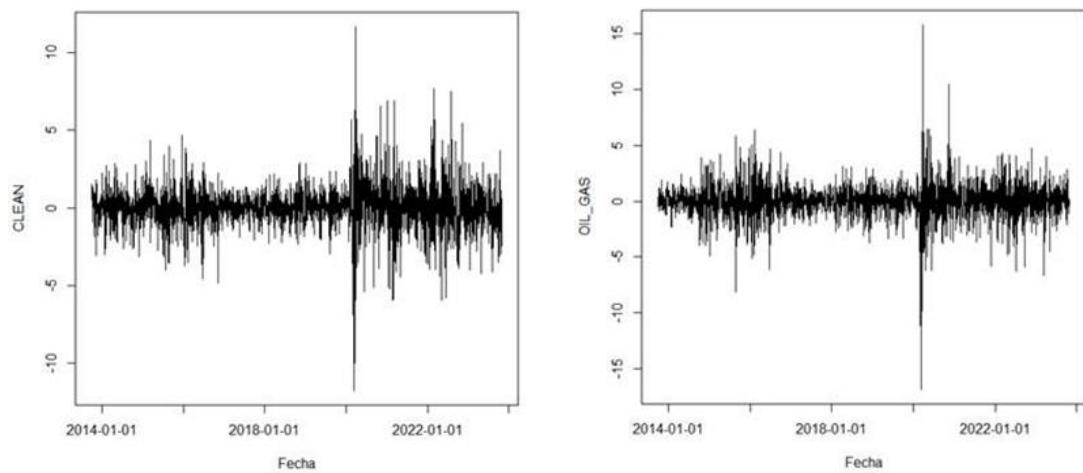
A continuación, se calcula la rentabilidad diaria, en tanto por cien, empleando la siguiente expresión:

$$Rentabilidad = 100 \times \frac{(P^t - P^{t-1})}{P^{t-1}}$$

Las series de rentabilidades van a ser estacionarias y se podrá aplicar los modelos estadísticos de series temporales, tanto univariantes como bivariantes. En los siguientes gráficos se muestran las series de rentabilidades para ambas series.

En estos gráficos se observan las características empíricas de agrupamiento de rentabilidades grandes (positivas o negativas) y de rentabilidades pequeñas (positivas y negativas). Además, se observan valores muy elevados en algunos momentos que coinciden con los sucesos comentados anteriormente y que provocan que ambas series presenten una alta curtosis (con colas pesadas tanto a derecha como a izquierda). Todo ello indica que tendremos que emplear modelos ARCH para su ajuste puesto que la varianza o volatilidad del mercado se observa que es variable en el tiempo.

Ilustración 2. Rentabilidades diarias, en tanto por cien, de las series analizadas



3.1 ANÁLISIS UNIVARIANTE

Para ambas series vamos a estimar modelos ARMA-GARCH con el objetivo de ajustar tanto la rentabilidad como la volatilidad. El estudio empírico se ha realizado con el software R empleando las librerías correspondientes para cada uno de los modelos.

En las Tablas 1 y 2 se presentan las estimaciones para los dos índices de energías estudiadas “CLEAN” y “OIL_GAS”, respectivamente.

El ajuste del modelo ARMA se realizó empleando los gráficos de las funciones de autocorrelación y autocorrelación parcial de las propias rentabilidades y se obtuvieron los mejores modelos según el criterio de selección BIC. En el índice CLEAN se seleccionó

un modelo MA (2), mientras que para el índice OIL_GAS se determinó una ARMA (1,1). Además, en el índice OIL_GAS se han introducido dos intervenciones en las fechas 9 y 24 de marzo de 2020 porque son dos datos atípicos coincidiendo con la crisis de la COVID-19 provocando una rentabilidad negativa del 16,83% y otra positiva del 15,78%, respectivamente. Para recoger mejor el comportamiento de la volatilidad se han empleado modelos GARCH (1,1) ya que las funciones de autocorrelación y autocorrelación parcial de los residuos cuadráticos mostraban valores significativos para bastantes retardos. El test ARCH indicaba que eran significativos hasta 10 valores retardados, con p-valores prácticamente cero. Hay que señalar que la rentabilidad media de ambas series es cero y, por tanto, en ninguna serie se ha introducido la constante como parámetro del modelo. Por último, se modelizaron los errores de ambos modelos con una distribución t de Student para recoger el exceso de curtosis que presentaban las series.

Tabla 1. estimación del modelo MA(2)-GARCH(1,1) para el índice CLEAN

	Estimate	Std. Error	t value	Pr(> t)
ma1	0,1478	0,0199	7,4456	0,0000
ma2	0,0364	0,0206	1,7645	0,0776
omega	0,0218	0,0072	3,0309	0,0024
alpha1	0,0842	0,0138	6,1020	0,0000
beta1	0,9077	0,0144	63,1506	0,0000
shape	6,3974	0,8063	7,9339	0,0000

Tabla 2. Estimación del modelo ARMA(1,1)-GARCH(1,1) para el índice OIL_GAS

	Estimate	Std. Error	t value	Pr(> t)
ar1	-0,8793	0,1003	-8,7668	0,0000
ma1	0,9018	0,0910	9,9114	0,0000
mxreg1	-16,7535	2,0024	-8,3668	0,0000
mxreg2	15,2448	3,5855	4,2518	0,0000
omega	0,0224	0,0081	2,7542	0,0059
alpha1	0,0676	0,0125	5,4009	0,0000
beta1	0,9239	0,0137	67,2754	0,0000
shape	6,3260	0,7689	8,2270	0,0000

En ambas estimaciones se observa que todos los p-valores son prácticamente cero, indicando que los coeficientes estimados son significativamente diferentes de cero. Por lo tanto, no hay ningún coeficiente que podamos eliminar. Los valores de los coeficientes de la parte MA o ARMA indica la relación lineal que existe entre la rentabilidad de hoy con respecto a las noticias inesperadas pasadas en la parte MA (errores del modelo) y la rentabilidad del día anterior en la parte AR. En la parte de la volatilidad se observa que las noticias inesperadas cuadráticas tienen un coeficiente de 0,0842 y 0,0676, respectivamente. Sin embargo, la volatilidad del día previo afecta con un valor estimado del 0,9077 y 0,9239, respectivamente, señalando que permanecerá una noticia inesperada durante bastante tiempo influyendo en la volatilidad del mercado.

En la Tabla 3 se presenta un análisis descriptivo de las dos series de errores para cada índice. Como se ha dicho anteriormente, la rentabilidad media de ambos índices es cero como podemos observar con sus p-valores elevados del 0,3352 y 0,4231, respectivamente. Si observamos los coeficientes de asimetría y de curtosis es evidente que no siguen una distribución normal ninguna de las dos series de errores estandarizados, aunque evidentemente ambas tienen varianza 1. Hemos aplicado el test de bondad de ajuste de Kolmogorov-Smirnov para corroborar la hipótesis planteada de que dicha distribución es una t de Student y el resultado se muestra en la Tabla 4. Para ambas series el p-valor es elevado, por tanto, es evidente que la hipótesis planteada de una distribución t de Student es sostenida por los datos.

Seguidamente podemos ver un estudio gráfico de ambas series de residuos estandarizados en las Figuras 3 y 4. Para cada residuo estandarizado se representa el histograma junto a la densidad teórica planteada, el Q-Q plot y el diagrama de caja. El histograma parece simétrico y apuntado ajustándose correctamente a la distribución t de Student. El gráfico Q-Q plot (cuantiles teóricos frente a los observados) se ajustan muy bien al modelo con todos sus valores dentro de las bandas de confianza y, por último, el diagrama de cajas podemos observar que es simétrico con una caja estrecha, mientras que los bigotes son más extensos y con muchos valores por fuera lo que confirma que es una t de Student.

Tabla 3. Análisis descriptivo de las series de errores para ambos modelos

	Índice CLEAN			Índice OIL-GAS		
	Estadistico	Error estandar	p-valor	Estadistico	Error estandar	p-valor
Media	0,0083	0,0195	0,3352	-0,0038	0,0196	0,4231
Extremo inferior	-0,0299			-0,0422		
Extremo superior	0,0466			0,0346		
Media recortada al 5%	0,0129			0,0140		
Mediana	0,0192			0,0432		
Varianza	0,9853			0,9914		
Desviación estandar	0,9926			0,9957		
Mínimo	-4,8239			-6,6166		
Máximo	4,6834			5,9121		
Rango	9,5073			12,5287		
Rango intercuartil	1,1652			1,1809		
Asimetría	-0,1041	0,0481	0,0152	-0,3710	0,0481	0,0000
Curtosis	1,3908	0,0963	0,0000	2,3064	0,0963	0,0000

Tabla 4. Test de Kolmogorov-Smirnov para los residuos estandarizados

	Índice CLEAN		Índice OIL-GAS	
	Estadistico	p-valor	Estadistico	p-valor
Test de Kolmogorov-Smirnov	0,0139	0,7037	0,0204	0,2317

El estudio de las funciones de autocorrelación y autocorrelación parcial de los residuos estandarizados y de sus cuadrados muestran que no hay valores significativos para los primeros retardos. El contraste de Ljung-Box (ver Tabla 5) en ambos casos no muestra la existencia de ninguna relación lineal, con p-valores por encima del 10% y el contraste ARCH (véase Tabla 6) tampoco detecta dicho efecto para los primeros retardos con p-valores superiores al 30%.

Ilustración 3. Estudio gráfico de los residuos estandarizados para el índice CLEAN

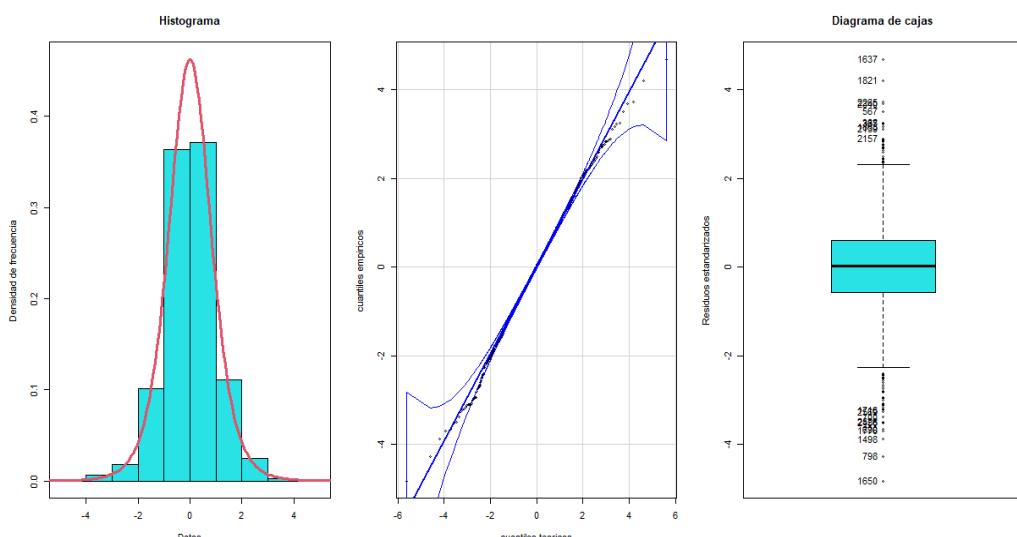


Ilustración 4. Estudio gráfico de los residuos estandarizados para el índice OIL_GAS

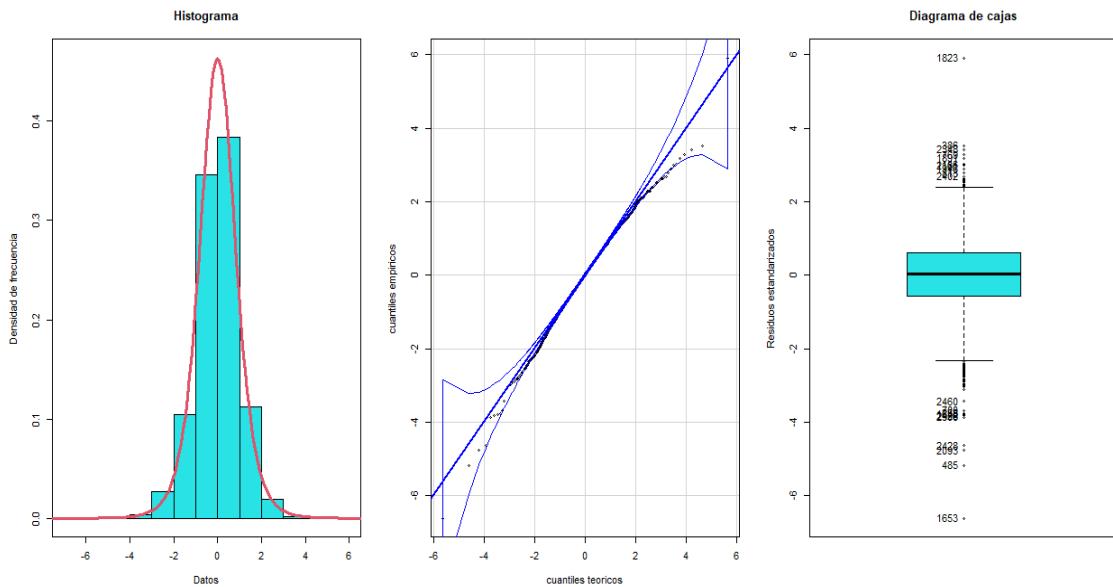


Tabla 5. Test de Ljung-Box para los residuos estandarizados y sus cuadrados

		Índice CLEAN		Índice OIL-GAS	
		Estadistico	p-valor	Estadistico	p-valor
Residuos estandarizados	Retardo 1	1,959	0,1616	2,256	0,1090
	Retardo 5	3,347	0,2748	3,097	0,4124
	Retardo 9	5,320	0,3838	3,826	0,7311
Residuos estandarizados cuadráticos	Retardo 1	0,092	0,7615	2,644	0,1039
	Retardo 5	1,350	0,7768	4,281	0,2211
	Retardo 9	2,277	0,8695	6,487	0,2461

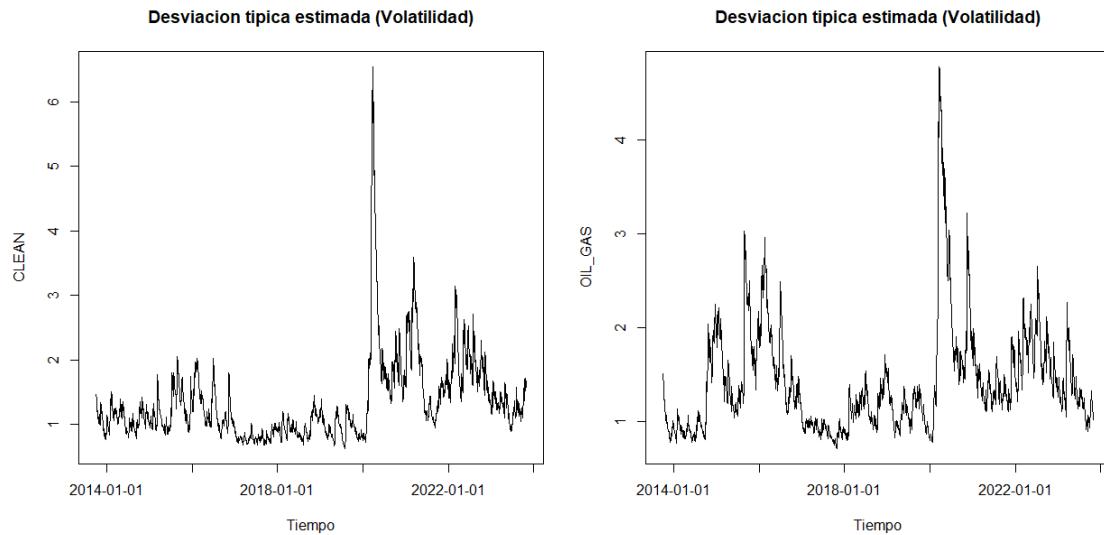
Tabla 6. Test ARCH para los residuos estandarizados

		Índice CLEAN		Índice OIL-GAS	
		Estadistico	p-valor	Estadistico	p-valor
Residuos estandarizados	Retardo 3	0,413	0,5204	0,536	0,4650
	Retardo 5	0,539	0,8721	2,810	0,3185
	Retardo 7	0,870	0,9338	3,901	0,3611

Finalmente, en la Figura 5 se presentan las estimaciones de la desviación típica (volatilidad) de cada índice analizado. Se observa claramente que no es constante en el tiempo, indicando que intervalos temporales hay mayor variabilidad en el mercado y en cuales menos. En general, podemos ver que hay mayor volatilidad en el índice OIL_GAS, pero se observan claramente algunos picos que coinciden en ambas volatilidades. En primer lugar, alrededor de marzo del año 2020 que coincide con la terrible pandemia a nivel mundial causada por la COVID-19, con sus respectivos repuntes durante los dos

años siguientes. Posteriormente, en segundo lugar, observamos otro pico no tan elevado, pero no menos importante, a mediados de febrero del 2022 como es la guerra de Ucrania la cual afecto a todo el mundo, ya que aparte de los ataques militares hubo una crisis de ciertas energías como podemos ver de nuevo en el gráfico.

Ilustración 5. Volatilidad estimada de cada índice

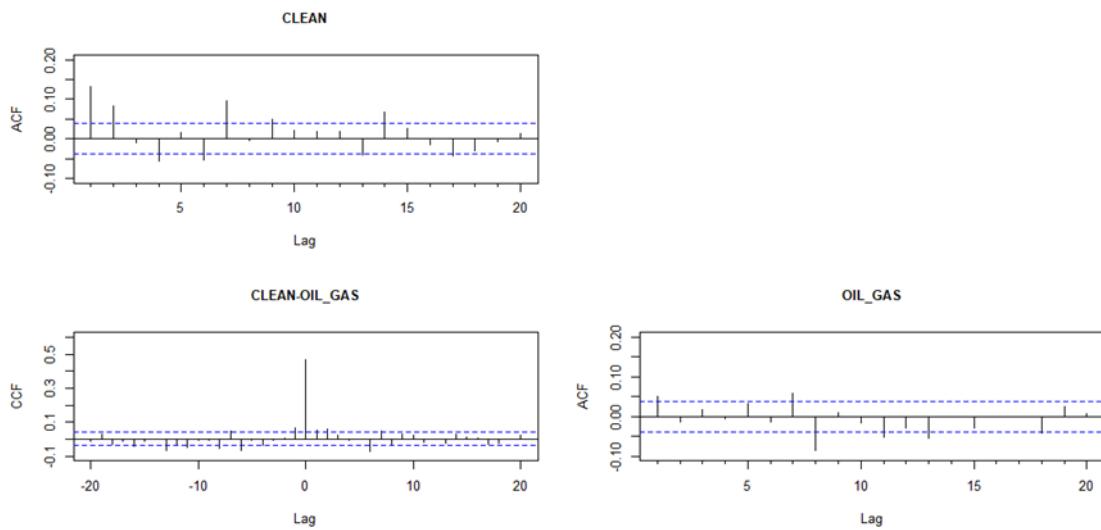


3.2 ANÁLISIS BIVARIANTE

En esta subsección vamos a estudiar de forma conjunta ambos índices para poder explicar las relaciones mutuas entre ambas. El modelo que plantearemos será VAR-DCC-GARCH, es decir, para la rentabilidad aplicaremos un modelo vectorial autorregresivo (extensión de los modelos ARMA univariantes) y para explicar la volatilidad emplearemos modelos de correlación dinámica condicional cuyas varianzas condicionales univariantes serán los modelos GARCH (1,1) vistos en la subsección anterior (véase Gargallo y otros (2021)).

En primer lugar, representamos gráficamente las funciones de autocorrelación parcial de cada serie de forma univariante y la función de correlación cruzada entre ambas para detectar las relaciones entre las rentabilidades en la Figura 6.

Ilustración 6. Funciones de autocorrelación y de correlación cruzada de ambas series



Se observa, como ya habíamos visto en la subsección anterior, que hay relaciones entre la rentabilidad actual y los retardos anteriores en los dos gráficos de la diagonal que son las funciones de autocorrelación parcial univariante. El gráfico fuera de la diagonal muestra que hay correlación significativa fuerte simultánea, es decir, en el mismo instante de tiempo y menor con el día anterior y posterior, aunque también es significativa. Este estudio permite justificar el uso de un modelo VAR (vector autorregresivo) para explicar de forma conjunta las rentabilidades de ambos índices.

En concreto, el modelo VAR (1) que se plantea es el siguiente:

$$\begin{pmatrix} X_t \\ Y_t \end{pmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{pmatrix} \begin{pmatrix} X_{t-1} \\ Y_{t-1} \end{pmatrix} + \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} \mathbb{I}_{t=1650} + \begin{pmatrix} \beta_3 \\ \beta_4 \end{pmatrix} \mathbb{I}_{t=1661} + \varepsilon_t$$

donde X_t es la rentabilidad del índice CLEAN e Y_t es la rentabilidad del índice OIL_GAS. Además, se han introducido dos intervenciones en los instantes 1650 y 1661 que corresponden con las fechas 9 de marzo de 2020 y 24 de marzo de 2020 (crisis de la COVID), como en la subsección anterior.

Las estimaciones obtenidas del modelo VAR(1) con sus p-valores entre paréntesis se presentan en la Tabla 7.

Tabla 7. Estimación del modelo VAR(1)

	CLEAN.11	OIL_GAS.11	exo1 (1650)	exo2 (1661)
CLEAN	0,1508 (0.0000)	0,0250 (0.2145)	-10,1642 (0.0000)	12,5822 (0.0000)
OIL_GAS	0,0775 (0.0000)	0,0019 (0.9257)	-16,5667 (0.0000)	16,2363 (0.0000)

Se observa que los coeficientes del modelo son significativos salvo para el retardo de la rentabilidad del OIL_GAS. Esto sugiere que las energías limpias (CLEAN) y el sector OIL_GAS están interconectados de manera significativa en el corto plazo, con las variaciones en las energías limpias influenciando de manera significativa tanto el presente como el próximo período. Sin embargo, el hecho de que el retardo uno del OIL_GAS no sea significativo indica que el impacto de las variaciones pasadas en el sector de energías fósiles puede no ser tan relevante en el período inmediatamente siguiente.

A pesar de que el modelo VAR (1) ha logrado capturar efectivamente el comportamiento medio de las energías limpias y el sector de energías fósiles, se ha observado que no ha sido igualmente exitoso en modelar el comportamiento en volatilidad, ya que se han identificado residuos heterocedásticos. Esta heterocedasticidad implica que la varianza de los errores no es constante a lo largo del tiempo, lo que puede indicar la presencia de patrones no lineales o cambios en la volatilidad a lo largo de las observaciones. Para poder ajustar este comportamiento se plantea un modelo de correlación dinámica condicional de los presentados en la sección previa.

Se ha contrastado que los errores $\varepsilon_t = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{pmatrix}$ tienen media 0 ($E[\varepsilon_t] = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$), pero su matriz de varianzas y covarianzas H_t no puede considerarse constante porque ambos índices son series heterocedásticas, por lo tanto, dicha matriz H_t es dinámica en el tiempo y emplearemos modelos de correlación dinámica condicional (CCC, DCCS y DCCA).

Se van a estimar los tres modelos y se seleccionará mediante el criterio de selección de modelos BIC el que mejor se ajuste. Los valores obtenidos del criterio BIC para los modelos se muestran en la Tabla 8.

Tabla 8. Criterio de selección BIC de los modelos

CRITERIO DE BAYES	
CCC	6,4232
DCC Simétrico	6,4152
DCC Asimétrico	6,4182

El mínimo criterio BIC corresponde al modelo DCCS, indicando que dicho modelo es la opción más adecuada. El DCCS permite que la matriz de correlación evolucione de manera dinámica, reflejando cambios en la relación de las variabilidades condicionales entre las series a lo largo del tiempo. A diferencia del CCC, que asume una correlación constante, el DCCS captura de manera más efectiva las variaciones en la volatilidad, adaptándose a las complejidades inherentes a la relación entre energías limpias y fósiles, cuyas estimaciones se muestran en la Tabla 9. Además, la estimación del parámetro g de asimetría en el modelo DDCA no era significativo implicando que las correlaciones dinámicas entre ambas rentabilidades no vienen influenciadas de forma diferente por errores positivos o negativos, es decir, importa la noticia inesperada, pero no si son ganancias o pérdidas inesperadas.

En la Tabla 9 se observan que todos los coeficientes son significativos porque sus p-valores son nulos o prácticamente nulos. La matriz de varianzas y covarianza dinámica según el modelo DCCS tiene un valor estimado $a=0,0170$ y $b=0,9744$, indicando una alta persistencia en mantener la influencia de las noticias inesperadas que llegan al mercado porque la suma de ambos $a+b=0,9914$ es muy cercana a 1. Además, se ha empleado una distribución t de student para los errores para recoger su alta curtosis y los grados de libertad estimados son 6,78, tal como se había observado en la subsección anterior

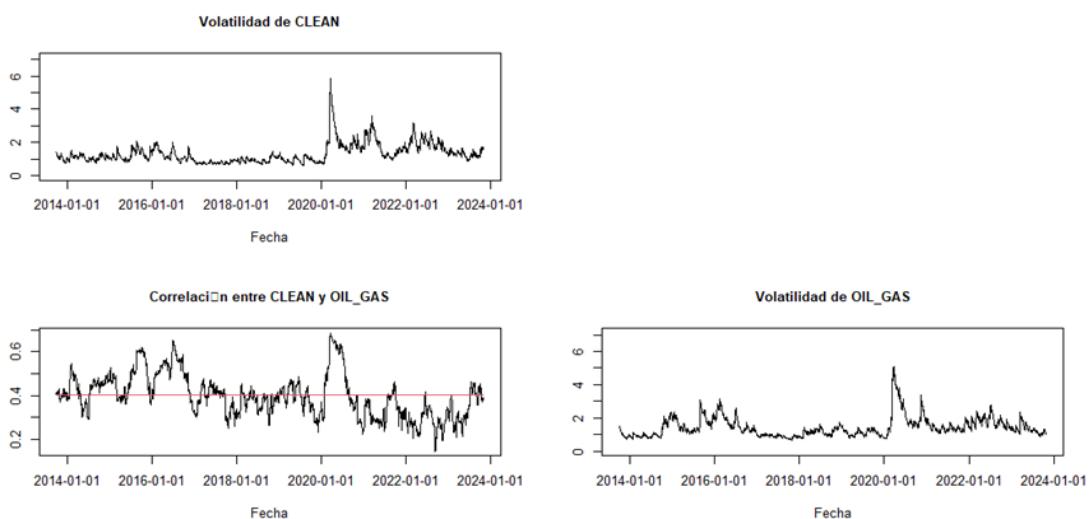
Tabla 9. Estimación del modelo DCCS-GARCH(1,1)

	Estimate	Std. Error	t value	Pr(> t)
[CLEAN]. omega	0,0181	0,0078	2,3248	0,0200
[CLEAN]. alpha1	0,0835	0,0183	4,5743	0,0000
[CLEAN]. beta1	0,9100	0,019	47,4750	0,0000
[OIL_GAS]. omega	0,0185	0,0079	2,3460	0,0190
[OIL_GAS]. alpha1	0,0776	0,0170	4,5524	0,0000
[OIL_GAS]. beta1	0,9176	0,0162	56,4705	0,0000
[Joint]dcca1	0,0170	0,0057	3,0070	0,0026
[Joint]dccb1	0,9744	0,0108	90,4538	0,0000
[Joint]mshape	6,7808	0,4749	14,2818	0,0000

Se presentan las volatilidades estimadas para ambas series y la correlación entre ellas en el panel gráfico de la Figura 7. Se observa claramente que la correlación (gráfico fuera de la diagonal) es cambiante en el tiempo y se señala con una línea roja el valor estimado si la correlación fuera constante en todo el periodo analizado. Dicha correlación es distinta de cero indicando que los movimientos o variabilidades de ambas series están relacionadas y en algunos instantes de tiempo toma valores que llegan a 0,70.

Las volatilidades de ambas series (gráficos en la diagonal) son similares a los obtenidos en la subsección anterior puesto que los valores estimados del modelo GARCH(1,1) prácticamente coinciden. Ambas señalan episodios de alta variabilidad en torno al inicio de la pandemia de la COVID 19 y de la guerra de Ucrania.

Ilustración 7. Volatilidad estimada de cada índice y la correlación entre ambas



3.3 CÁLCULO DE LOS PESOS DE LA CARTERA FORMADA POR LOS ÍNDICES

El objetivo de esta subsección será determinar los pesos de cada índice en la cartera para corroborar que el mercado potencia o incentiva la inversión en energías renovables frente a las energías fósiles que son más contaminantes. Una explicación más detallada se puede ver en Gargallo y otros (2021).

Sean las rentabilidades $r_t = \begin{pmatrix} X_t \\ Y_t \end{pmatrix}$ en un instante t de ambos índices, con X_t la rentabilidad de la serie denominada CLEAN e Y_t la rentabilidad de la series denominada OIL_GAS; y denotamos por $w_t = \begin{pmatrix} w_{1t} \\ w_{2t} \end{pmatrix}$ los pesos de la cartera formada por dichos índices. La rentabilidad de la cartera sería el producto $w_t' r_t$ y el riesgo o volatilidad se calcularía como $w_t' \cdot \text{Var}[r_t | I_{t-1}] \cdot w_t$, siendo I_{t-1} la información conocida hasta el instante t-1. Para explicar el cálculo de los pesos de la cartera óptima se denota $\Omega_t = \text{Var}[r_t | I_{t-1}]$ a la matriz de varianzas y covarianza condicional de la rentabilidad de ambas series

Para construir la cartera óptima se deben determinar los pesos para que con una rentabilidad fija tengamos el menor riesgo o menor varianza, es decir, resolver el problema:

$$\min_{w_t} w_t' \cdot \Omega_t \cdot w_t \quad \text{sujeto a que} \quad w_t' \mu = \mu_0$$

donde μ es la rentabilidad esperada.

La solución a este problema es la siguiente:

$$w_t = \frac{\Omega_t^{-1} \mu}{\mu' \Omega_t^{-1} \mu} \mu_0$$

- Dado que Ω_t no es conocida emplearemos su estimación: H_t , como se ha visto en la subsección anterior se empleará 1 modelo DCCS-GARCH(1,1) con la información hasta el instante t-1.
- Para calcular μ , trabajamos con diferentes escenarios calculando la rentabilidad trimestral durante todo el periodo estudiado. El peso dado a cada índice será el promedio de todos los pesos calculados para cada escenario posible.

El estudio planteado para la estimación será trimestral, es decir, iremos añadiendo las rentabilidades de un trimestre nuevo para volver a estimar el modelo y actualizar los pesos

correspondientes. En cada instante de tiempo con el modelo estimado haremos las predicciones de la matriz de varianzas y covarianzas (volatilidad de la cartera) para volver a optimizar la cartera con el menor riesgo posibles para una rentabilidad fija dada.

Siguiendo con este planteamiento de los trimestres y rentabilidades trimestrales normalizadas, desde un principio partíamos de una serie con 33 trimestres, sin embargo, se encuentran algunas negativas que habrá que descartar porque un inversor solo fija rentabilidades positivas y se eliminarán escenarios que se puedan repetir, por lo que al final tendremos solo 16 escenarios de posibles rentabilidades y que se muestran en la Tabla 10.

Tabla 10. Rentabilidades trimestrales μ

	CLEAN	OIL_GAS
Escenario 1	0,5700	0,8217
Escenario 2	0,9963	0,0856
Escenario 3	0,4900	0,8717
Escenario 4	0,9208	0,3901
Escenario 5	0,9005	0,4348
Escenario 6	0,5278	0,8494
Escenario 7	0,8472	0,5312
Escenario 8	0,8131	0,5822
Escenario 9	0,9977	0,0677
Escenario 10	0,9999	0,0167
Escenario 11	0,8682	0,4962
Escenario 12	0,2255	0,9742
Escenario 13	0,9875	0,1574
Escenario 14	0,3690	0,9294
Escenario 15	1,0000	0,0000
Escenario 16	0,0000	1,0000

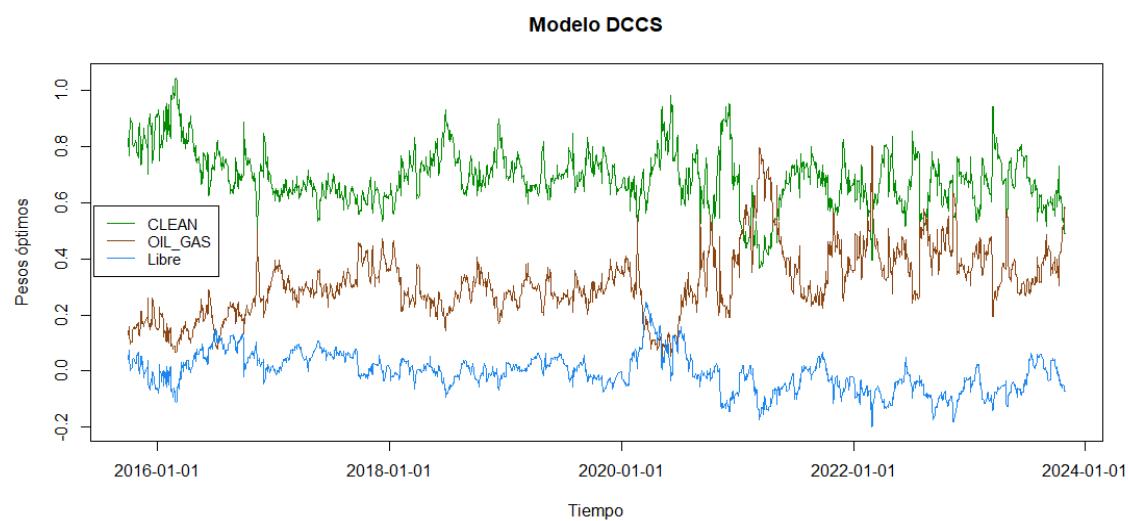
El procedimiento para el instante t comenzará fijando el periodo de estimación, desde el instante inicial hasta el final del trimestre anterior al instante t de tiempo. Con dicha información se estimará el modelo VAR(1)-DCCS-GARCH(1,1) como se ha visto en la subsección anterior y de forma iterativa se estimará la matriz de varianzas y covarianza condicional H_t , con los parámetros estimados y las rentabilidades diarias que llegan hasta

el instante $t-1$. Con la matriz estimada H_t y cada μ recogido en un escenario, se calculará los pesos óptimos para ese escenario y el peso asignado, como se ha explicado, será el promedio de los 16 pesos óptimos calculados en cada escenario.

La suma de los pesos generalmente no es 1, por lo tanto, el peso que falta ($1 - w_{1t} - w_{2t}$) se asigna a un activo libre de riesgo, que suelen ser letras del tesoro o inversiones con un interés fijo.

La Figura 8 presenta los pesos de la cartera óptima, indicado que prácticamente el peso de las energías renovables (CLEAN) es mayor que el de las energías fósiles (OIL_GAS) prácticamente en todo el periodo estudiado, salvo en periodos de tiempo muy concretos. Esto implica que el mercado ofrece más rentabilidad en el índice de las energías renovables asumiendo un riesgo menor que invirtiendo en energías fósiles.

Ilustración 8. Pesos de la cartera óptima

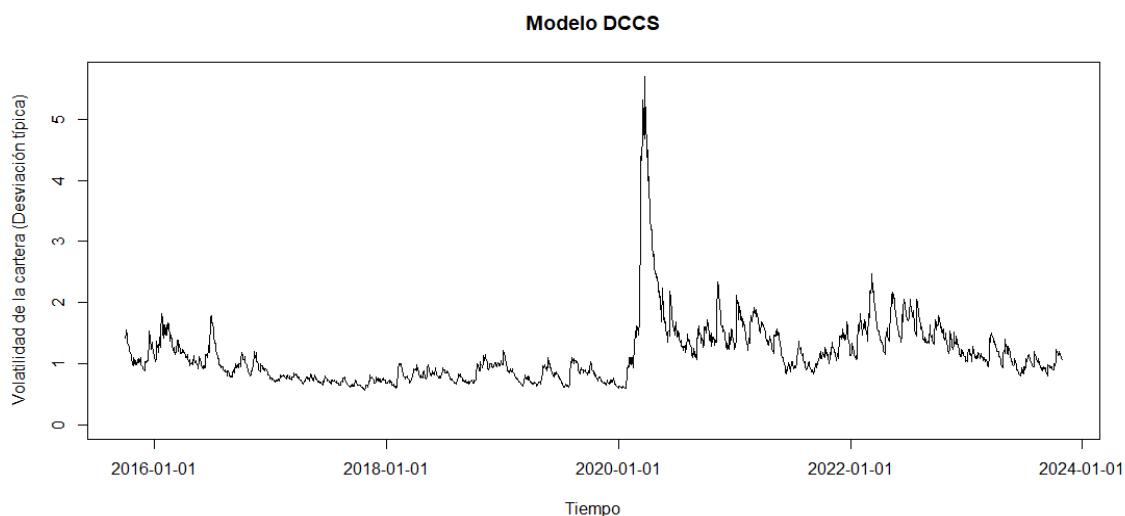


Possiblemente si hubiéramos empezado este periodo unos cuantos años antes veríamos como la línea de energías verdes “CLEAN” estaría más abajo antes de este periodo, ya que antes no había esta preocupación a nivel mundial por las energías limpias y cuidar el medioambiente para el futuro por el gran problema que se nos avecina por el cambio climático.

Por otra parte, hay que destacar como ambas energías se juntan en los puntos destacados con anterioridad a lo largo de este estudio como son la pandemia mundial “COVID-19” alrededor de marzo del año 2020 y la Guerra de Ucrania a mediados de febrero del 2022 en la cual suben las energías sucias.

Por último, se presenta el grafico de la volatilidad (véase Figura 10) de la cartera óptima construida, donde se observa desde el inicio del periodo hasta principios del 2020 una variabilidad controlada y constante, con un riesgo escaso, pero en marzo del 2020 tiene un fuerte crecimiento hasta casi al 6% que coincide con la pandemia de la COVID_19 y posteriormente, se producen más variabilidades con otro episodio de alta volatilidad, casi del 3%, con la Guerra de Ucrania sobre mediados de febrero del 2022.

Ilustración 9. Volatilidad de la cartera óptima



4. CONCLUSIONES

Dada la trascendencia de reducir la huella de carbono y fomentar la inversión en energías limpias, es crucial establecer metas claras y ambiciosas. Estos objetivos deben ser no solo realistas y alcanzables, sino que deben instar a la sociedad y a los mercados a emprender acciones concretas para mitigar el cambio climático. A pesar de que la conciencia pública sobre este tema está en constante crecimiento y la sociedad se encuentra cada vez más comprometida, la urgencia se hace evidente en la actualidad con fenómenos climáticos extremos.

La inversión en energías limpias para frenar el cambio climático y favorecer la transición energética se ha notado de manera muy acusada durante y posteriormente a la pandemia de la COVID 2019. Tal vez por la mayor financiación y apoyo político que ha tenido durante estos últimos meses como por el hecho de que la demanda de las tecnologías relacionadas con las energías limpias ha aumentado.

Algunos posibles beneficios de este tipo de energías limpias podrían incluir la reducción de las emisiones de gases de efecto invernadero y el no agotamiento de recursos provenientes de combustibles fósiles. Además, las políticas actuales favorecen el aumento de la capacidad de generación de energías limpias, la promoción de la investigación y desarrollo de nuevas tecnologías, la dotación de inventivos y ayudas a empresas y la implementación de regulaciones que fomentan la inversión en energías limpias.

Concretamente en el caso de nuestro país, España, según estimaciones de la Asociación de Empresas de Energías Renovables (APPA), la transición energética podría generar inversiones entre los 80.000 y los 100.000 millones de euros entre el 2018 y el 2030. Las expectativas favorables del mercado, particularmente para el sector fotovoltaico, se deben en parte a las ventajas geográficas del país, que en su área sur recibe tanta luz como el norte del continente africano. En consecuencia, de cara al futuro el sector público de España estima además una inversión de 200.000 millones euros hasta el 2030, dirigidos hacia la eficiencia energética y el desarrollo de renovables, entre otros.

En este contexto, los mercados financieros desempeñan un papel crucial en la transición hacia una economía baja en carbono y sostenible. Al incentivar la inversión en energías limpias, los mercados pueden contribuir significativamente a la reducción de la huella de carbono y al desarrollo de un futuro más sostenible, ya que dichos mercados son los motores del mundo y la economía.

Por lo tanto, el trabajo ha estudiado la construcción de una cartera diversificando en dos índices que recogen la inversión en industrias relacionadas con los combustibles fósiles frente a otra que se basa en el uso de energías verdes. La construcción de la cartera óptima entre estas dos series financieras destaca un pronunciado incremento en la presencia de energías renovables en comparación con las no renovables en los últimos años. Este cambio representativo en la composición de las energías, visualizado de manera clara en la representación gráfica de los pesos de la cartera, subraya la tendencia ascendente de las fuentes de energía sostenibles, marcando un hito significativo en el panorama energético-financiero.

5. BIBLIOGRAFÍA

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroscedasticity. *Journal of Econometrics*, 31, pp. 307-327.
- Bollerslev, T.; Chou, R.Y. y Kroner, K.F (1992). ARCH modeling in finance. *Journal of Econometrics*, 52, pp. 5-59.
- Bollerslev, T.; Engle, R.F. y Nelson, T. (1994). Handbook of Econometrics, Volume 4, Pages 2959-3038
- Engle, R.F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of UK inflation. *Econometrica*, 50, pp. 987-1008.
- Gargallo, P.; Lample, L.; Miguel, J.A.; Salvador, M. (2021). Co-Movements between Eu Ets and the Energy Markets: A Var-Dcc-Garch Approach. *Mathematics*, 9, 1787-1823.
- Sevilla Marco, Mario (2018). Análisis del riesgo de mercado en series financieras: un estudio comparativo. Universidad de Zaragoza, Zaragoza. p. 24.
- Tobar, Luis Marco (2017). Análisis del riesgo para mercados financieros. Universidad de Zaragoza, Zaragoza. p. 37.