



FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES

ICADE

# **PREDICCIÓN DEL PRECIO DEL PETRÓLEO**

Autor: Rodrigo Montero Ballesteros

Director: Isabel-Catalina Figuerola-Ferretti Garrigues

MADRID | Junio 2025

## Abstracts

### English

This work aims to develop and evaluate an econometric model capable of accurately forecasting the price of Brent crude oil. To this end, an ARIMA approach is employed to capture the univariate dynamics of crude oil prices. In addition, a multivariate VAR model is developed to analyze how other variables influence oil price behavior. The study includes stationarity tests, optimal lag selection, and impulse response analysis to interpret the effects of shocks on the price of oil. The ARIMA model shows superior performance in terms of predictive accuracy. To assess the performance of both models, several error metrics have been used to objectively quantify their forecasting precision. Furthermore, the VAR model allows for the study of the dynamic relationships between variables through impulse response functions. It is concluded that the ARIMA model is more suitable for direct forecasting, while the VAR model can be useful for analyzing structural relationships if expanded to include additional economic variables. Finally, future research could focus on developing a more comprehensive VAR model that incorporates additional factors such as global oil production or demand.

**Key words:** oil, ARIMA model, VAR model, time series, forecasting, econometrics.

### Spanish

Este trabajo tiene como finalidad desarrollar y evaluar un modelo econométrico que permita predecir con precisión el precio del petróleo Brent. Para ello, se emplea en esta investigación un enfoque ARIMA con el fin de capturar la dinámica univariante del precio del crudo. Por otro lado, se desarrolla un modelo multivariante (VAR) que permite analizar cómo influyen otras variables en el precio del crudo. El trabajo incluye pruebas de estacionariedad, selección óptima de rezagos y análisis de impulso-respuesta para interpretar los efectos de choques sobre el precio del crudo. El modelo ARIMA muestra un rendimiento superior en términos de capacidad predictiva. Para evaluar el rendimiento de ambos modelos se han utilizado varias métricas de error que permiten cuantificar de forma objetiva la precisión de los modelos. Por otro lado, el modelo VAR permite estudiar la dinámica entre variables a través de funciones impulso-respuesta. Se concluye que el modelo ARIMA es más apropiado para la predicción directa, mientras que el VAR puede ser útil para analizar relaciones estructurales si se ampliara con más variables económicas. Finalmente, se propone como futura línea de investigación el desarrollo de un modelo VAR más completo que incorpore factores adicionales como la producción o la demanda mundial de petróleo.

**Palabras clave:** petróleo, modelo ARIMA, modelo VAR, series temporales, predicción, econometría.

# Índice

|   |    |
|---|----|
| <b>1. Introducción</b> .....                                    | 4  |
| <b>2. Marco teórico</b> .....                                   | 5  |
| <b>2.1 La importancia económica del petróleo</b> .....          | 5  |
| <b>2.2 Modelo ARIMA</b> .....                                   | 5  |
| <b>2.3 Modelo VAR</b> .....                                     | 7  |
| <b>2.4 Historia del precio del petróleo (2000 – 2024)</b> ..... | 9  |
| <b>2.5 Limitación en los modelos</b> .....                      | 10 |
| <b>3. Metodología</b> .....                                     | 11 |
| <b>3.1 Recolección de datos</b> .....                           | 11 |
| <b>3.2 Procesamiento de los datos</b> .....                     | 12 |
| <b>3.3 Análisis inicial de los datos</b> .....                  | 12 |
| <b>3.4 Modelos utilizados</b> .....                             | 13 |
| <b>3.5 Evaluación de los modelos</b> .....                      | 13 |
| <b>3.6 Herramientas utilizadas</b> .....                        | 14 |
| <b>4. Desarrollo del modelo</b> .....                           | 14 |
| <b>4.1 Extracción de los datos</b> .....                        | 14 |
| <b>4.2 Análisis descriptivo de los datos</b> .....              | 16 |
| <b>4.2.1 Precio del petróleo</b> .....                          | 16 |
| <b>4.2.2 Índice del dólar estadounidense</b> .....              | 18 |
| <b>4.2.3 Índice del S&amp;P500</b> .....                        | 19 |
| <b>4.3 Rendimientos</b> .....                                   | 20 |
| <b>4.4 Modelo ARIMA</b> .....                                   | 22 |
| <b>4.5 Modelo VAR</b> .....                                     | 25 |
| <b>5. Resultados</b> .....                                      | 28 |
| <b>6. Conclusiones</b> .....                                    | 30 |
| <b>7. Bibliografía</b> .....                                    | 32 |

# 1. Introducción

Uno de los temas cruciales en la economía actual es la predicción del precio del petróleo, ya que influye directamente en sectores importantes como el transporte, la energía o la industria. Las fluctuaciones en su precio tienen un impacto significativo en la inflación, las inversiones o los costes de producción de muchas empresas. Después de eventos como la pandemia del COVID -19, la invasión rusa a Ucrania o la crisis del petróleo de 2014; la volatilidad del precio del petróleo se ha disparado, provocando que aumente la necesidad de herramientas precisas que predigan el precio del petróleo.

Este mercado se caracteriza por su alta complejidad, ya que está influenciado por muchos factores. Por tanto, analizar las variables que justifiquen su volatilidad y su precio y desarrollar un modelo predictivo es esencial para que las instituciones puedan tomar decisiones informadas.

El objetivo principal del Trabajo de Fin de Grado (TFG) es crear y analizar un modelo econométrico que sea capaz de predecir de forma precisa el precio del petróleo Brent empleando un enfoque ARIMA (Autoregressive Integrated Moving Average). Por otro lado, se desarrollará un modelo VAR (Vector Autoregression). Este tipo de modelos analizar las relaciones entre múltiples variables. Las variables escogidas para la investigación son el índice bursátil S&P500 y el tipo de cambio del dólar estadounidense. Estos indicadores tienen relevancia en la evolución del precio del crudo y, por tanto, se analizará cuál es el impacto del movimiento de estas variables en el precio del petróleo. Aunque hay otras muchas variables que tienen influencia en el precio del petróleo (por ejemplo, la producción o la demanda del petróleo), esta investigación ha usado estas dos variables mencionadas anteriormente. Los principales motivos de su inclusión son su frecuencia diaria registrada en la plataforma donde se ha extraído la base de datos y su relevancia macroeconómica.

Este trabajo no sólo busca identificar un modelo que prediga de forma precisa el precio, sino que también se centra en aportar conclusiones sobre su aplicabilidad. De esta forma, este trabajo servirá también como una guía para entender la dinámica del mercado y la justificación de la fluctuación del precio.

## **2. Marco teórico**

### **2.1 La importancia económica del petróleo**

El crudo es uno de los activos más estratégicos de la economía global. Este activo no sólo influye en sectores como el del transporte o el de la energía, sino que también influye de manera directa en la cadena de valor industrial. Por tanto, este impacto tiene repercusiones en la inflación, la toma de decisiones de inversión empresarial, en el comercio o en la política monetaria de los bancos centrales

Durante estos últimos años, el precio del petróleo ha experimentado tramos de alta volatilidad causados por crisis financieras (2008), conflictos internacionales (guerra de Ucrania, 2022) e incluso pandemias (2019). Esta complejidad hace que predecir el precio del petróleo sea uno de los mayores retos en la economía global.

Generalmente, las series temporales son un papel fundamental para la predicción de tendencias y para tomar decisiones razonadas. Sin embargo, el precio del petróleo no se comporta de forma lineal y muestra patrones muy volátiles. Por tanto, para predecir esta serie temporal tan compleja hay que elegir adecuadamente el modelo de predicción. En este contexto, los modelos ARIMA y VAR, univariantes y multivariantes respectivamente, han sido utilizados como enfoques más lineales para intentar predecir la dinámica del precio del crudo. A continuación, se describen ambos modelos y se revisa la literatura que ha empleado estos modelos en la predicción.

### **2.2 Modelo ARIMA**

El modelo ARIMA es uno de los modelos más tradicionales para predecir series temporales. Es una combinación entre componentes autorregresivos (AR) y componentes de media móvil (MA). A esto se le añade un componente de integración que permite suprimir las tendencias no estacionarias mediante una diferenciación. La parte “AR” del modelo se refiere a que el valor actual de la serie está basado en sus valores anteriores, es decir, el precio del petróleo se basa en el histórico que ha tenido. La parte MA indica que el valor actual de la serie está basado en los errores de los pronósticos pasados. Por tanto, en un modelo ARIMA (p,d,q) el valor de la serie está influenciado por los términos p, d y q. El término p es el número de valores históricos al precio actual que influyen en él. Es el orden autorregresivo. El término q indica el orden de la media móvil, es decir, el número de rezagos del componente de ruido). A la hora de desarrollar el modelo, los

precios se someten a transformaciones (por ejemplo, logarítmicas) y diferenciaciones para poder conseguir la estacionariedad.

Posteriormente, se identifican los valores de  $p$  y  $q$  óptimos según el enfoque Box-Jenkins. Para identificar estos valores se emplean funciones de autocorrelación parcial (PACF) y funciones de autocorrelación (ACF). Por tanto, este modelo ARIMA captará las relaciones lineales de en los valores históricos, teniendo en cuenta varios términos que ayudan a reducir los errores. El hecho de que sea tan simple lo hace muy útil como punto de partida en modelos financieros. Sin embargo, este tipo de modelos no llega a explicar las relaciones no lineales. Para ajustar la precisión del modelo se usan métodos de máxima verosimilitud o mínima cuadrática. Posteriormente, se valida el modelo con pruebas sobre residuos.

Varios estudios han utilizado este tipo de modelo para predecir el precio del crudo. En primer lugar, Attarde y Desai (2024) modelaron ARIMA a datos con frecuencia mensual del precio del petróleo Brent (1994 – 2012). Aplicaron finalmente un ARIMA (2,0,1), ya que se ajustaba mejor a la volatilidad del precio. Aplicaron funciones logarítmicas y diferencias para lograr la estacionariedad. Por otro lado, Tularam y Saeed (2016) desarrollaron un análisis que indicaba que un ARIMA (2,1,2) predecía mejor el precio y se ajustaba mejor a la volatilidad. Concluyeron que este modelo era más sofisticado y robusto en comparación con otros modelos de mayor simplicidad. En estos dos casos, los modelos ARIMA fueron capaces de representar de forma lineal los precios históricos del petróleo.

Otros autores como Sagiru Mati et al. (2023) emplearon otro enfoque distinto. Usaron junto al modelo ARIMA un indicador binario de guerra entre Rusia y Ucrania. Este indicador servía para evaluar el impacto de las guerras en el precio del petróleo. Tomaba un valor u otro en función de las tensiones políticas entre ambos países.

Por tanto, el modelo ARIMA es un buen enfoque para modelar el precio del crudo, no sólo por su sencillez sino porque también han tenido un buen desempeño cuando las series temporales han sido localizadas y diferenciadas. Es un modelo que permite incorporar la dinámica histórica del precio del petróleo. En este caso, resultará útil aplicar una transformación logarítmica dado que el precio del petróleo es más volátil y tiende a tener una mayor dispersión en sus retornos. Sin embargo, es conveniente señalar que ARIMA asume una linealidad entre los valores históricos y el valor actual, por lo que no capta

valores influyentes externos. A pesar de esto, los modelos ARIMA son la base de muchos modelos de predicción lineal.

### 2.3 Modelo VAR

El modelo Vector Autoregression (VAR) es un tipo de modelo multivariante que amplía un modelo autorregresivo univariante a múltiples series relacionadas. Así como el modelo ARIMA (p,d,q), el modelo VAR también tiene término. El término  $p$  en un modelo VAR indica que cada variable se modela en función de sus  $p$  rezagos y en función de los  $p$  rezagos de las otras variables. Si considerásemos más de una variable (por ejemplo, el precio del Brent, el índice bursátil S&P500 y el índice del dólar), el VAR capturaría las relaciones dinámicas entre ellas y cómo dependen unas de otras. El VAR se resume, técnicamente, a un conjunto de sistemas de ecuaciones lineales con forma AR(p) en cada una de las variables. Este tipo de modelos es muy útil en finanzas o en macroeconomía donde se necesita explorar los impactos entre varias variables. La principal diferencia, por tanto, con los modelos ARIMA es que el VAR no distingue entre variables exógenas o endógenas. Todas las series son tratadas de manera simétrica, lo que permite explorar relaciones de causalidad y estimar funciones de impulso-respuesta.

Para la estimación del precio del petróleo, sería interesante agregar información de indicadores económicos. Por ello, incluir en el modelo VAR el índice **S&P500** y el **tipo de cambio del dólar** puede aportar valor a la investigación. El S&P500 es el índice que refleja el estado de la economía: una economía fuerte y enriquecida puede aumentar la demanda de los productos energéticos y, por tanto, aumentar el precio del Brent. Por el contrario, una crisis es señal de menor requerimiento energético, por lo que reduciría el precio del petróleo. Por tanto, la evolución de este índice puede provocar cambios futuros en el precio del Brent. Por otro lado, dado que el Brent se negocia en dólares, la fuerza del dólar impacta de forma directa en el precio real del petróleo para los compradores internacionales. Kilian y Zhou (2020) concluyen que incluir el tipo de cambio del dólar es “esencial” en los modelos VAR del petróleo. Cuando el dólar se aprecia, el precio del petróleo aumenta para otros mercados.

La literatura utiliza VAR para analizar variables junto con indicadores económicos. Kilian y Zhou (2020) revisaron varios modelos VAR aplicados al precio del petróleo. Incluyeron variables relevantes como la oferta, la demanda o el tipo de cambio. A pesar de que su modelo es más estructural comparado con otros modelos, concluyeron que la inclusión

de variables macro o índices bursátiles (por ejemplo, S&P500) es muy habitual a la hora de pronosticar el precio del Brent dentro del modelo VAR. De manera similar, Escribano et al. (2023) modelaron la conexión dinámica entre varios mercados accionarios y el precio del petróleo, encontrando que había cierta evidencia de transmisión de shocks tras la crisis del 2008. A pesar de que su estudio se centra más en índices bursátiles como el S&P500 de manera más cualitativa, este estudio refleja que es estadísticamente relevante la relación que hay entre el precio del petróleo y el precio de las acciones. Por tanto, estos estudios generalmente concluyen que el modelo VAR ofrece predicciones más precisas por el hecho de poder incorporar varias variables en el modelo. Además, el análisis de resultados impulso-respuesta (observado posteriormente en esta investigación también) ayuda a interpretar la relación dinámica entre las variables escogidas y el precio del petróleo: por ejemplo, cómo un shock negativo en el precio del dólar impacta en el precio del petróleo.

En resumen, este tipo de modelos que incluye el Brent, el S&P500 y el dólar permite analizar de forma simultánea cómo afectan unas variables a otras. Por ejemplo, un aumento brusco en el S&P500 podría ser causado por un aumento del precio del Brent por expectativas económicas fuertes; por otro lado, un debilitamiento del tipo de cambio del dólar puede provocar un aumento en el precio del crudo. No obstante, cabe destacar que en otros estudios se han estudiado modelos VAR que incorporan otras variables explicativas como los inventarios o la producción global (Figuerola-Ferretti et al., 2021). En esta investigación se han escogido finalmente el S&P500 y el índice del dólar debido a su disponibilidad diaria y a su relevancia macroeconómica. Por otro lado, la selección de variables con alta frecuencia permite mantener la coherencia temporal del modelo, tal y como se destaca en algunas investigaciones muy recientes centradas en este tipo de predicciones dinámicas (Figuerola-Ferretti, McCrorie & Paraskevopoulos, 2020).

Además, estos modelos VAR pueden ser útiles para estudiar distintos escenarios: por ejemplo, ¿cómo se movería el precio del petróleo si se espera una subida del índice S&P500? Estudios como el de Escribano et al. (2023) muestran que, desde la crisis del 2008, la correlación entre el precio del crudo y los mercados bursátiles ha aumentado. Esto afirma que añadir el S&P500 aportará información relevante para analizar los movimientos del petróleo. Por otro lado, Kilian y Zhou (2020) sugieren no excluir el tipo de cambio del dólar en estos modelos.

Por tanto, esta revisión confirma que ambos modelos, tanto el ARIMA como el VAR, han sido herramientas clásicas y efectivas para la predicción del precio del petróleo. El ARIMA se centra más en la dinámica de los precios históricos de una única variable y el VAR amplía este modelo incorporando información y datos de otras variables, lo que conlleva a un modelo más preciso a la hora de predecir los precios.

## **2.4 Historia del precio del petróleo (2000 – 2024)**

El precio del Brent ha registrado períodos alcistas y bajistas pronunciados desde el año 2000. Generalmente, el aumento en la demanda, las crisis o las tensiones geopolíticas han tenido bastante influencia en los precios. Los datos utilizados en esta sección vienen de diversas fuentes especializadas en el sector energético. Se han consultado particularmente los registros históricos en Datosmacro.com (2024), Investing.com (2024) y Macrotrends.net (2024), así como los informes de IEA (International Energy Agency, 2023). Los momentos más destacados de este período son:

- 2008: En este año el Brent alcanzó un precio de ~143.94\$/barril el 3 de julio de 2008. El precio se desplomó a finales de año hasta llegar a 30/40 \$/barril tras la quiebra de Lehman Brothers.
- 2014 – 2016: en este período hubo un exceso de oferta debido al auge del *shale oil* en EE. UU. El precio volvió a caer desde los ~100\$/barril a mediados de 2014 hasta ~36\$/barril a finales de 2015.
- 2020: la demanda del petróleo se vio colapsada por los confinamientos. Por las mismas fechas estalló una guerra de producción petrolífera entre Arabia Saudí y Rusia. El precio cayó aproximadamente un 65.6% en el primer trimestre.
- 2021: este año se caracterizó por la crisis energética global. La escasez de combustibles fósiles y la escasez de gas natural hicieron que la demanda del petróleo aumentara. En septiembre de 2021, el precio del petróleo tenía un promedio de ~74.4\$/barril y en octubre superó los 83\$.
- 2022: la guerra en Ucrania provocó que el precio del Brent aumentara aproximadamente en un 30% en un par de semanas. Durante los primeros meses de 2022, el precio superó los 110\$/barril. La guerra causó una reducción en la producción y el suministro del petróleo, provocando que los precios suban. A finales de 2022, la reapertura de producción causó una bajada de precios hasta llegar los ~97\$/barril.

- 2023 – 2024: después de la alta volatilidad durante los últimos años, el precio del Brent tenía un promedio de ~80\$/barril cerrando el año en ~77.04\$/barril. En 2024, subió de nuevo y finalmente llegó a cerrar el año en ~74.64\$/barril.

Figura 1. Evolución del precio petróleo Brent



Fuente: <https://datosmacro.expansion.com>

## 2.5 Limitación en los modelos

Los modelos utilizados para esta investigación (ARIMA y VAR) tienen restricciones estructurales que van a dificultar predecir el precio del Brent de forma precisa. En primer lugar, estos modelos no capturan fácilmente las dinámicas no lineales o los cambios repentinos (por ejemplo, una volatilidad variable). Por tanto, estos modelos tienen que asumir relaciones lineales estacionarias. También, estos modelos tienen una cierta dependencia en supuestos estadísticos que no siempre se cumplen.

Por otro lado, los algoritmos de *Machine Learning* como los árboles de decisión o las redes neuronales, pueden modelar estas no linealidades y superar los límites que estos modelos más tradicionales tienen. Parisa Foroutan y Salim Lahmiri (2024) demostraron que estos algoritmos de aprendizaje profundo tienen menor error a la hora de lanzar predicciones. No obstante, estos modelos requieren una gran cantidad de observaciones y un riguroso tratado de datos. También, afirmaron que el petróleo es un activo con una volatilidad abrupta y una fuerte no linealidad. Entrenar correctamente un algoritmo profundo ajustando varios hiperparámetros y validando todos los datos que se van a entrenar excede el alcance de esta investigación con recursos más limitados. Para construir este tipo de algoritmos, habría que basarse en otras predicciones para estimar correctamente el precio del Brent. Esta metodología es bastante compleja además de que

los resultados suelen tener menor interpretabilidad. Por ello, se ha descartado el uso de este tipo de algoritmos para esta investigación.

Por tanto, en esta investigación, se utilizarán los modelos ARIMA y VAR en vez de los modelos de *Machine Learning*. Estos modelos no necesitan de una estructura compleja para poder analizar el precio del Brent. Por otro lado, estos modelos son mucho más transparentes, y permiten un análisis económico de los resultados. Por tanto, usar algoritmos de *Machine Learning* haría que pudiese haber riesgo de sobreajuste, hubiese falta de interpretabilidad o requiriese de un conocimiento técnico excesivo. A pesar de todo esto, expertos del sector afirman que estimar el precio del petróleo de forma precisa es un objetivo muy difícil de lograr. El CEO de BP (British Petroleum) afirma que “*no se pueden pronosticar los precios del petróleo con ningún grado de precisión en ningún periodo, ni corto ni largo*” (*Forecasting the Price of Oil*, 2011).

### **3. Metodología**

Se siguieron una serie de pasos desde la extracción y limpieza de datos hasta la creación y desarrollo de los modelos predictivos. Todos estos pasos se realizaron empleando técnicas reconocidas en análisis de series temporales y utilizando herramientas aceptadas en el ámbito académico. A continuación, se presenta cada paso de la metodología en orden lógico.

#### **3.1 Recolección de datos**

En primer lugar, se llevó a cabo la recolección de datos históricos de los últimos 5 años enfocándose en las variables identificadas en el marco teórico. El precio del petróleo crudo, el tipo de cambio del dólar estadounidense y el índice S&P500 son las variables de interés que se han obtenido a través de la plataforma Factset. Factset provee datos financieros y agrega información histórica y en tiempo real de todos los mercados, incluyendo el de materias primas. Esta fuente garantiza la fiabilidad de los datos.

Para unificar los datos de las tres series, se unificaron las tres fuentes en un único conjunto teniendo como índice la fecha. Se han extraído aproximadamente 5 años de historia con alrededor de 1200 observaciones por series. Este período aporta muchas condiciones de mercado distintas (por ejemplo, la crisis de Ucrania), por lo que el conjunto aporta variabilidad.

### **3.2 Procesamiento de los datos**

En segundo lugar, una vez los datos han sido extraídos, se importan en un *Python script*, que es donde se va a realizar toda la investigación. Con las librerías y las modalidades que ofrece el software, se juntan las series temporales en un único *dataframe*. Para hacer un análisis correcto y lanzar predicciones adecuadamente, es necesario cambiar el orden del índice. En el conjunto de datos, el primer registro es el último valor histórico de las series temporales. Para hacer un análisis en *Python* es necesario que el primer registro sea siempre la última observación histórica, es decir, es necesario que la serie temporal vaya de más antigua a más reciente. Por esto mismo, revertimos el orden del índice para que el primer registro sea el más antiguo.

### **3.3 Análisis inicial de los datos**

A continuación, se realiza un EDA (Análisis exploratorio de datos en inglés). Este análisis tiene el fin de comprender la estructura de las series y las relaciones. En esta fase, se incluyen tanto visualizaciones, que ayudan a entender la serie temporal, como resúmenes estadísticos. En primer lugar, se han calculado las estadísticas descriptivas de cada variable para conocer y entender la serie temporal. El cálculo de la media, la desviación estándar o los máximos y mínimos, por ejemplo, aportará una noción básica de la volatilidad y el comportamiento de las variables.

En segundo lugar, a través de los gráficos se pueden entender las tendencias y los patrones en los datos de las series temporales. Se ha realizado un gráfico de líneas por serie temporal para identificar los períodos de alza, los períodos de mayor volatilidad o los períodos de baja. Graficar todas las series temporales permite contrastar las tendencias de las variables y analizar si hay algún tipo de relación entre ellas. Por ejemplo, si un período en el que el índice S&P500 se fortalecía, analizar si el petróleo tendía a fortalecerse también, o no.

Por otro lado, se ha construido una matriz de correlación. Para la construcción de esta matriz, se han calculado los coeficientes de correlación de Pearson. Se han construido también diversos gráficos para poder profundizar más en el análisis de las variables. Se han construido gráficas como un histograma de variaciones porcentuales, un boxplot de variaciones o un gráfico de Drawdown estimado.

### 3.4 Modelos utilizados

Para esta investigación se han aplicado dos modelos de series temporales distintos. Como ya se ha mencionado en el marco teórico, se usarán ARIMA y VAR para predecir el precio del petróleo. Ambos modelos fueron desarrollados y entrenados en el entorno de Python.

En el modelo ARIMA, se incorporan componentes autorregresivos (AR) y de medias móviles (MA). Se evalúa en esta parte la combinación óptima para desarrollar el modelo. Por otro lado, se evaluaron los residuos para comprobar si se comportan como White noise (ruido blanco en inglés), que significaría que no tienen estructura. Se ha desarrollado también una gráfica para ver tanto los residuos como sus funciones de autocorrelación.

Debido a que contamos con dos variables más para el estudio (tipo de cambio del dólar e índice S&P500), se va a implementar el modelo VAR. El VAR permite modelar varias series temporales dinámicamente. Se usa en este modelo un VAR sobre series diferenciadas, ya que los datos no son estacionarios. Para la selección de retardos óptimos del VAR, se han utilizado los criterios de información AIC (Akaike Information Criterion) y BIC (Bayesian Information Criterion), evaluando desde 1 hasta 10 órdenes. Este modelo, como ya se ha mencionado anteriormente, permite capturar las relaciones entre las variables. Por ejemplo, si hay un aumento en el índice S&P500 que precede un aumento en el precio del petróleo, el modelo lo va a aprender y a utilizar para optimizar las predicciones.

### 3.5 Evaluación de los modelos

La evaluación de los modelos se ha realizado mediante varias métricas de error. En primer lugar, se ha utilizado el RMSE (Root Mean Squared Error), que es la raíz del error cuadrático medio. Esta métrica se calcula haciendo la raíz cuadrada de la media de los cuadrados de los errores de predicción. De este modo, penaliza los errores más grandes, por lo que es de mucha utilidad. Además, el hecho de usar números con la misma medida hace que esta métrica sea fácil de interpretar. Cuanto más baja es esta métrica, mejor es el modelo.

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{N - P}}$$

En segundo lugar, se ha calculado el MAE (Mean Absolute Error), que es el error absoluto medio. Esta métrica se calcula como el promedio del valor absoluto de los errores. Indica cuál es la media de los errores. Esta métrica penaliza de forma lineal todos los errores, por lo que difiere del RMSE. Complementa el RMSE porque es una métrica con mayor robustez ante los valores atípicos. Cuanto más bajo es el MAE, mejor es el modelo.

$$MAE = \frac{\sum |y_i - x_i|}{n}$$

Por último, se ha calculado  $R^2$  (coeficiente de determinación), que mide la varianza de la predicción que es explicada por el modelo. Toma valores entre 0 y 1. Un coeficiente cercano a 1, quiere decir que el modelo explica la mayor parte de la variabilidad de la predicción. Por tanto, cuanto mayor es el coeficiente, mejor va a ser el modelo.

### **3.6 Herramientas utilizadas**

Todo el proceso de análisis de datos y desarrollo del modelo se ha realizado utilizando el lenguaje de programación de Python. Este lenguaje permite una investigación profunda e interpretable debido a su flexibilidad y a su amplia colección de librerías. Las librerías imprescindibles para el estudio son pandas, NumPy y Matplotlib. La primera librería, pandas, permite la lectura y la manipulación de los datos. Se ha utilizado principalmente para leer los ficheros Excel que contienen los datos de FactSet, para estructurarlos en un *DataFrame* y para limpiar y transformar los datos. La segunda librería, NumPy, permite operaciones numéricas como los cálculos estadísticos. Se ha utilizado en la investigación para realizar cálculos como logaritmos o raíces cuadradas. Por último, se ha utilizado la librería Matplotlib, que permite generar gráficos y visualizaciones para analizar más detalladamente los datos y para presentar resultados.

## **4. Desarrollo del modelo**

### **4.1 Extracción de los datos**

La investigación se ha construido en base a las series temporales obtenidas en la plataforma de FactSet. Se ha seleccionado esta fuente de datos por la frecuencia de

actualización y, sobre todo, por su fiabilidad, lo que garantiza la precisión y la calidad de los datos utilizados en el estudio.

Se han extraído tres variables que representan los factores clave, según la literatura, de la evolución del precio del petróleo. En primer lugar, se ha seleccionado el precio del petróleo crudo. El nombre de esta variable en FactSet es WTI Spot Price. La medida es dólares estadounidenses por barril. Se han extraído los con periodicidad diaria en un rango de 5 años. En segundo lugar, se ha extraído el índice del dólar estadounidense. En FactSet esta variable figura como Dollar Index Spot Price. La medida son puntos del índice y sigue la misma naturaleza que el precio del petróleo: periodicidad diaria en un rango de 5 años. Por último, se ha extraído el índice bursátil S&P500. En FactSet se conoce como S&P 500 Index (SPX). Sigue también la misma naturaleza que el resto de las variables.

Estas tres variables han sido seleccionadas de forma estratégica para la investigación, como ya se ha mencionado anteriormente en la literatura. El precio del petróleo es la variable objeto de predicción. El índice del dólar estadounidense es relevante en esta investigación, ya que el precio del petróleo se comercia en dólares en los mercados internacionales. Por este motivo, las fluctuaciones en el índice del dólar impactan en el precio. El S&P500 es considerado como una variable macroeconómica que puede influir en la demanda energética y en la evolución del precio del petróleo.

Estas variables se han descargado directamente de FactSet y se han almacenado en distintos ficheros Excel (.xlsx). Todos los ficheros contienen en la primera hoja las columnas de interés: la fecha y el precio de cierre diario. En algún caso, también aparecen las variaciones en términos absolutos y porcentuales. Debido a que estas columnas serán calculadas posteriormente con el código, no se van a tener en cuenta en la lectura de datos.

Para la integración de las tres series, se ha utilizado la librería de pandas para leer los archivos y concatenarlos en un único DataFrame. El tipo de unión es interna (inner join) lo que asegura que no hay valores faltantes en algunas fechas. El índice de este nuevo DataFrame centralizado es la variable que contiene las fechas, lo que permite realizar operaciones basadas en el tiempo (por ejemplo, el cálculo de las variaciones diarias en términos absolutos).

Como ya se ha mencionado anteriormente, se han utilizado los últimos 5 años, que incluyen eventos significativos en el precio del petróleo (por ejemplo, la recuperación del

COVID-19 o la guerra de Ucrania). Esta fase incluye periodos alcistas y bajistas que enriquecen el análisis.

Durante el análisis de datos, se ha evaluado la integridad de los datos. Este proceso asegura la calidad de los datos para la investigación. Se evalúa la completitud para asegurarse de que todas las series contienen el mismo número de observaciones sin valores nulos. Evalúa también el formato de los valores para poder manipularlos posteriormente. Se revisaron también los máximos y mínimos de cada serie para garantizar que no haya ningún outlier (una cotización negativa, por ejemplo).

## **4.2 Análisis descriptivo de los datos**

Para el análisis inicial exploratorio de los datos, se ha investigado de forma separada las tres series temporales consideradas para el estudio: el precio del petróleo, el índice del dólar estadounidense y el índice bursátil S&P500. Todas las series tienen un total de 1188 observaciones que comprenden desde el 14 de abril del 2020 hasta el 31 de diciembre del 2024. Para analizar en profundidad cada una de las variables se ha desarrollado una función llamada *inspección*. Esta función realiza de forma automática cálculos estadísticos para comprender la naturaleza de las variables y desarrolla gráficas que apoyan el estudio. Se revisa en esta parte el análisis de cada variable de forma separada y detallada.

### **4.2.1 Precio del petróleo**

Tras el choque de la pandemia del COVID-19 en los inicios del 2020, el precio del petróleo ha mostrado una recuperación. El primer registro observado en la serie temporal es de 29.60 USD/barril, mientras que a finales de 2024 llegó a superar los 75 USD/barril.

Figura 2. Evolución del precio petróleo



Como se puede observar en la Figura 2, la trayectoria del precio del petróleo ha sufrido un incremento notorio. El valor del precio ha tenido exactamente una variación total del 152.16%. Sin embargo, este crecimiento no ha sido monótono. Se observan períodos de alta volatilidad (por ejemplo, la caída brusca de abril de 2020 en la que llegó a cotizar en 19.33 USD/barril). Se observan también varios picos altos durante el 2022, periodo en el cual el precio llegó a su máxima cotización registrada (127.98 USD/barril). Esta cotización se debe al conflicto geopolítico entre Ucrania y Rusia. Posteriormente, la cotización del precio experimentó una corrección a la baja y se estabilizó. Durante este periodo, el precio cotiza alrededor de los 70 – 80 USD/barril.

En términos estadísticos, el precio medio del petróleo es de 76.52 USD/barril, mientras que la mediana es de 79.10 USD/barril. El mínimo y el máximo registrado del precio son de 19.33 USD/barril y 127.98 USD/barril respectivamente, como ya se ha mencionado. Estas cifras sugieren que el precio del petróleo ha sido altamente volátil durante estos últimos 5 años. La volatilidad diaria del precio es de 2.46% mientras que la anualizada es de 39.02%. La variación diaria media del precio es del 0.11%.

Otra métrica para tener en cuenta es el MDD (*Máximo DrawDown*), que indica la mayor caída porcentual que ha experimentado una inversión desde su punto más alto hasta el punto más bajo antes de alcanzar un nuevo máximo. El precio del petróleo ha tenido un MDD de un -45.94%.

### 4.2.2 Índice del dólar estadounidense

El índice del dólar tiene movimientos más moderados en comparación con el precio del petróleo. El índice del dólar también sufrió una caída post COVID-19 para luego recuperarse. El primer registro observado es de 98.89 puntos. Tuvo durante este periodo de investigación una variación total del 9.71%.

Figura 3. Evolución del índice del dólar estadounidense



Tras abril de 2020, el índice del dólar sufrió una caída notable para llegar a los 90 puntos a comienzos de 2021. No obstante, a partir del 2021 y durante el 2022, el índice se fortaleció alcanzando un valor alrededor de 114 puntos. Este crecimiento coincide con la implementación de las políticas monetarias restrictivas de la Reserva Federal. Posteriormente, el índice retrocedió y se estabilizó en la zona de 105 puntos a finales de 2024.

En términos estadísticos, el índice del dólar tuvo una media de 100.07 puntos, mientras que la mediana estuvo en los 101.87 puntos. La desviación estándar es aproximadamente de 5.9 puntos. Esto indica que el activo es menos volátil que el precio del petróleo. El valor mínimo y máximo observado en este periodo es de 89.44 y 114.11, respectivamente. Este rango es mucho más acotado que el rango del precio del petróleo. La volatilidad diaria del índice fue de 0.43%, mientras que la volatilidad anualizada fue de 6.81%. En cuanto al MDD, se registró un máximo de -12.56%. Estas métricas demuestran que el índice del dólar estadounidense es un activo mucho menos volátil que el precio del petróleo.

### 4.2.3 Índice del S&P500

Por último, el índice del S&P500 representa también la recuperación tras la caída posterior al COVID-19. Este periodo fue alcista. El primer registro observado de la serie es de 2846 puntos y tuvo una variación total de 106.66%.

Figura 4. Evolución del índice S&P500



Hasta finales del año 2021, el índice S&P500 ascendió desde los 2846 puntos hasta los 4700 puntos. Posteriormente, el índice sufrió una corrección bajando cerca de un 20%. Tras esta bajada, el índice volvió a mantener una tendencia creciente más moderada en 2023. A finales de 2024, el índice se sitúa alrededor de los 6000 puntos.

En términos estadísticos, la media diaria del índice es de 4333 puntos, mientras que la mediana es de 4269 puntos. La desviación estándar del índice es de 720 puntos. El mínimo y el máximo registrado en la serie es de 2736 y 6090, respectivamente. El mínimo se encuentra en los inicios de la serie mientras que el máximo se encuentra entre los últimos registros. Esto indica la tendencia ascendente que ha tenido el índice. La volatilidad diaria del índice fue de 1.08%, mientras que la anualizada fue de 17.11%. En cuanto al MDD, se registró un máximo de -25.43%.

Estas métricas nos indican que el S&P500 es un activo medianamente volátil y rentable a su vez. El índice del dólar ha registrado una menor volatilidad, mientras que el precio del petróleo ha registrado la mayor volatilidad diaria. Véase en la *Tabla 1* un resumen de los resultados obtenidos en esta fase.

**Tabla 1.** Resumen de las estadísticas de las variables

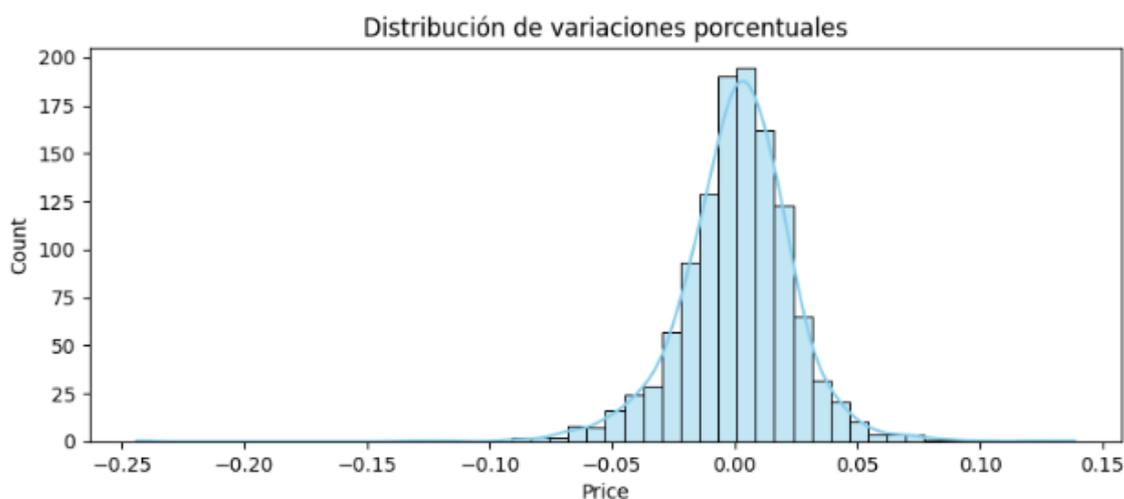
|                        | Petróleo | Dólar   | S&P500  |
|------------------------|----------|---------|---------|
| Media                  | 76,52    | 100,07  | 4333    |
| Mediana                | 79,10    | 101,87  | 4269    |
| Mínimo                 | 19,33    | 89,44   | 2736    |
| Máximo                 | 127,98   | 114,11  | 6090    |
| Desviación estándar    | 19,43    | 5,91    | 720     |
| Variación total        | 152,16%  | 9,71%   | 106,66% |
| Variación diaria media | 0,11%    | 0,01%   | 0,07%   |
| Volatilidad diaria     | 2,46%    | 0,43%   | 1,08%   |
| Volatilidad anualizada | 39,02%   | 6,81%   | 17,11%  |
| MDD                    | -45,94%  | -12,56% | -25,43% |

### 4.3 Rendimientos

Es habitual realizar un análisis de los rendimientos (variaciones relativas, por ejemplo) de las distintas series temporales. Por ello, se va a considerar los rendimientos diarios de cada serie. Analizar la distribución de estos rendimientos, proporcionará información sobre la presencia de outliers, asimetrías, etc.

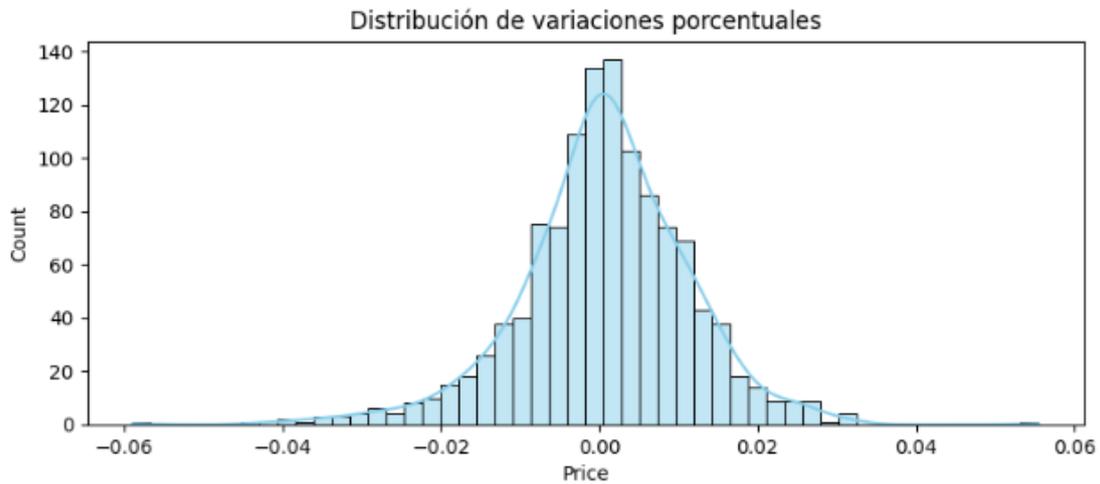
En primer lugar, se observa que la distribución de los rendimientos diarios del precio del petróleo tiene sesgo a la izquierda. En la Figura 5 se puede observar un histograma con estos rendimientos. Esta figura revela que todos los rendimientos tienen media 0 y tienen colas extendidas en ambos extremos. Esto explica los resultados obtenidos en el apartado anterior. La variación diaria media es de 0.11% y tiene una volatilidad diaria de 2.46%. También se puede observar un rendimiento diario de un -24%, lo que es claramente un outlier.

**Figura 5.** Distribución de variaciones porcentuales del petróleo



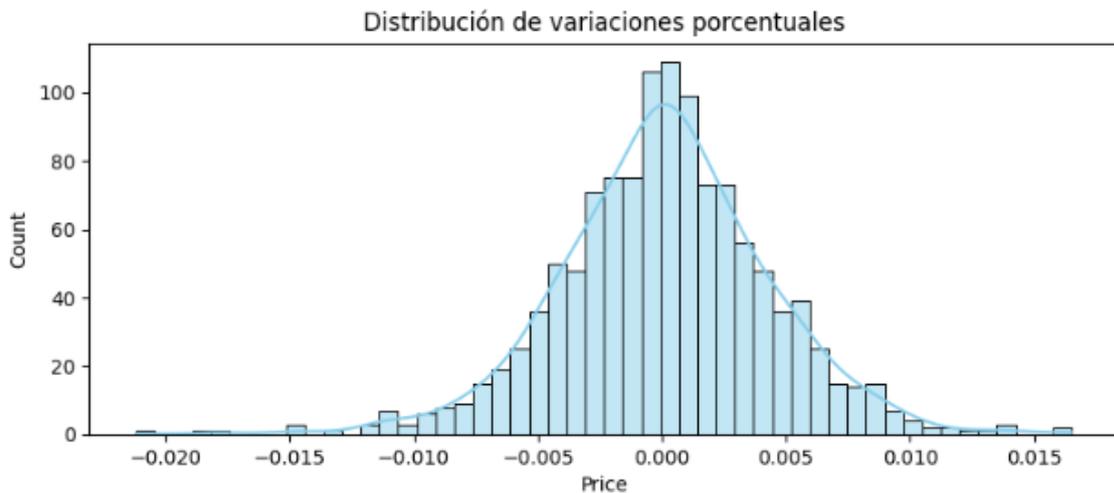
En segundo lugar, los rendimientos diarios del índice S&P500 muestran alguna desviación significativa de la normalidad. El gráfico de las distribuciones de los retornos (Figura 6) demuestra que tienen una asimetría negativa. Este suceso es debido a que las bajadas son mayores en términos absolutos que las subidas.

*Figura 6. Distribución de variaciones porcentuales del S&P500*



Por último, los rendimientos diarios del índice del dólar tienen una distribución más cercana a la normalidad. Es el activo con menor volatilidad de los tres, como ya se ha mencionado en la anterior sección. Sin embargo, las distribuciones tienen también asimetría negativa. En términos de outliers, el índice del dólar no ha tenido ninguna variación diaria extraordinaria. La mayor caída fue un -2.1%, mientras que la mayor ganancia fue de un 1.65%.

*Figura 7. Distribución de variaciones porcentuales del índice del dólar estadounidense*



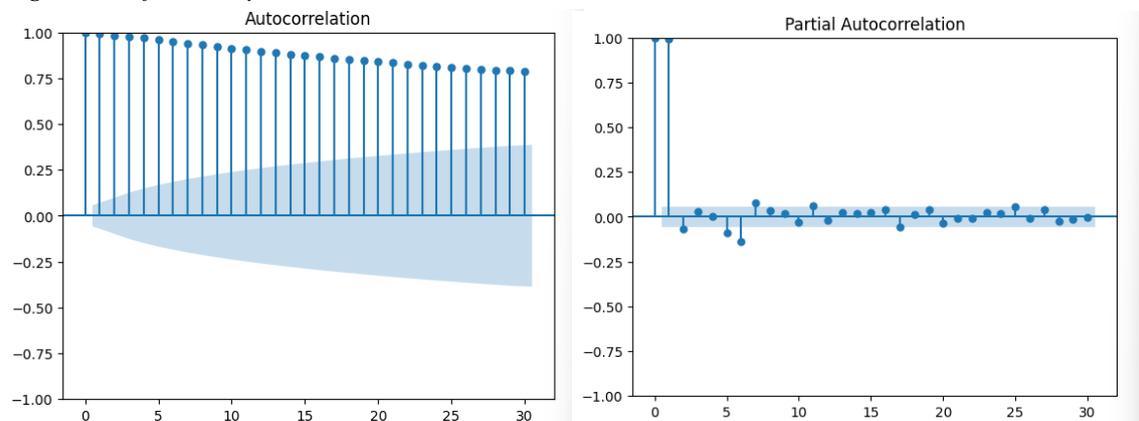
## 4.4 Modelo ARIMA

Para poder modelar el precio del petróleo como única variable, se ha utilizado el modelo ARIMA. Para ello, se ha realizado una transformación logarítmica para poder lograr la estacionariedad. Con este paso, la varianza es estabilizada por el logaritmo. Se ha reducido la heterocedasticidad y el análisis de los shocks es más interpretable.

Tras la transformación logarítmica de la serie, se ha analizado el nivel de la estacionariedad con la prueba ADF (Dickey – Fuller aumentada). Esta prueba contrasta la no estacionariedad (hipótesis nula) frente a la estacionariedad. El resultado mostró un p-valor menor a 0.01, lo que indica que se rechaza la hipótesis nula. Por tanto, la serie es estacionaria.

Posteriormente, se ha procedido a identificar los términos óptimos para el modelo ARIMA mediante ACF y PACF. Para determinar el término p y q se analizaron los gráficos de ACF (autocorrelación) y PACF (autocorrelación parcial). En un proceso únicamente autorregresivo con término p, los coeficientes mostrados en el gráfico ACF decaen de forma gradual, mientras que en el gráfico de PACF hay p coeficientes distintos de 0.

**Figura 8.** Gráficos ACF y PACF

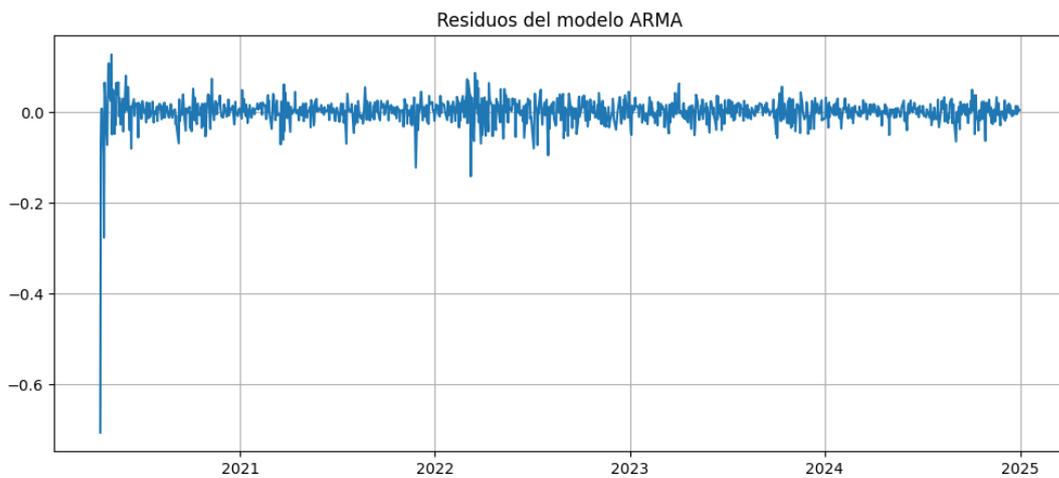


Como se puede observar en la figura 8, el precio con la transformación logarítmica tiene una dependencia lineal hasta el segundo término p, por lo que el modelo óptimo será AR(2). En la gráfica ACF se pueden observar los coeficientes decayendo gradualmente, por lo que no se necesita implementar términos de MA (media móvil) en el modelo. Por tanto, siguiendo la metodología de Box-Jenkins, el modelo que se va a usar va a ser un ARIMA(2,0,0), lo que equivale a un AR(2).

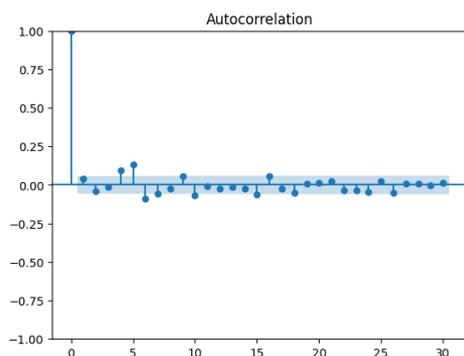
El modelo se estimó en base a la serie transformada del logaritmo del precio del petróleo. Se ha estudiado con profundidad los parámetros del modelo. El estudio indica que ambos coeficientes autorregresivos son estadísticamente significativos, es decir, muestran un p-valor inferior a 0.05. El coeficiente del primer rezago es de 1.05, mientras que el segundo es de -0.05. El modelo también incluye una constante estadísticamente significativa con un coeficiente de 4.10. Como su medida está expresada en logaritmos, habría que aplicar una transformación para obtener el valor real. En términos reales este coeficiente tendría un valor de ~60 USD/barril.

Para evaluar el desempeño del modelo, se han analizado la ACF y PACF de los residuos. No se observó ninguna autocorrelación significativa. Por ello, los residuos se comportan como *White noise* (ruido blanco) (Figura 9). Además, se realizó la prueba Ljung-Box, que analiza la autocorrelación residual. No hay rezagos significativos en esta prueba (Figura 10). Por último, se ha generado un histograma de los residuos para verificar que la media fuese 0 (Figura 11). Por todo esto, el modelo AR(2) ha sido la elección óptima para modelar los precios logarítmicos del petróleo.

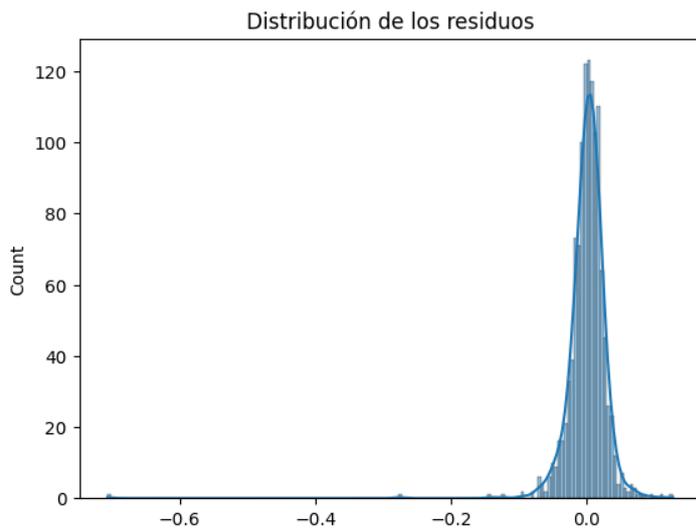
**Figura 9.** Evolución de los residuos del modelo AR(2)



**Figura 10.** ACF residual

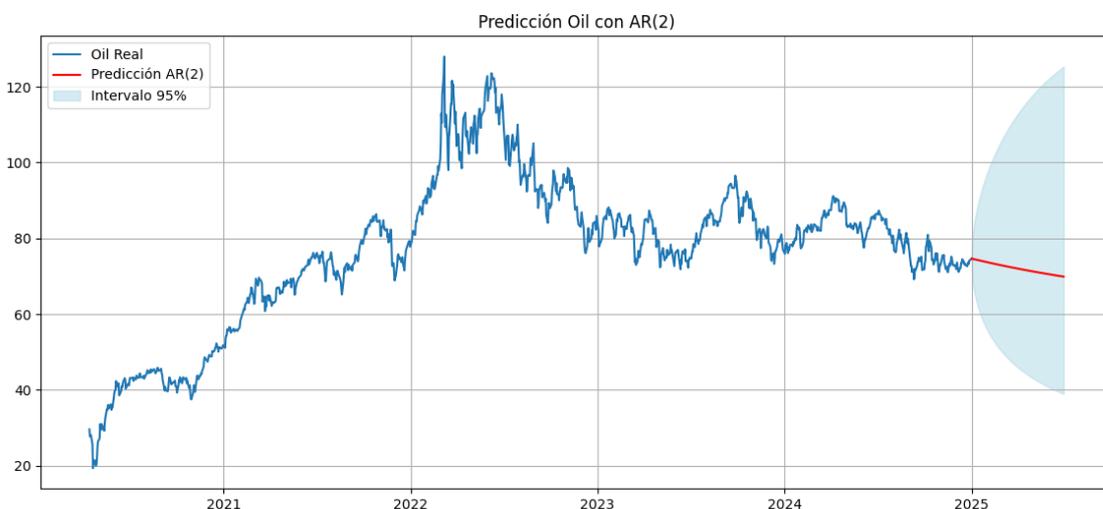


**Figura 11.** Histograma de los residuos



Con este modelo, se han generado las predicciones del precio del petróleo para los próximos 6 meses. Como el modelo se ha entrenado con la transformación logarítmica, ha sido necesario calcular las predicciones en logaritmos para luego volver a transformarlas en valores reales. Como se puede observar en la Figura 12, las predicciones (línea roja) muestran una tendencia bajista. Se muestran también las bandas de confianza al 95%. Estas bandas muestran la incertidumbre en el precio del petróleo. Son más estrechas en los primeros periodos, y más anchas en los últimos. Estas bandas explican que el precio del petróleo tiene una probabilidad del 95% de cotizar en esta área. El tener unas bandas tan anchas, sugiere que hay factores que no están siendo considerados en el modelo (tensiones geopolíticas, por ejemplo).

**Figura 12.** Predicción del precio del petróleo con AR(2)



En resumen, el modelo ARIMA es un modelo sencillo (por su interpretabilidad y baja complejidad) y robusta para predecir o estimar el precio a corto plazo. No obstante, al ser univariante tiene alguna limitación.

#### **4.5 Modelo VAR**

Teniendo en cuenta la principal limitación del modelo ARIMA, se ha decidido desarrollar un modelo VAR (Vector Autorregresivo). Este modelo capturará las interrelaciones dinámicas entre el precio del petróleo, el índice del dólar estadounidense y el índice bursátil S&P500.

Al igual que en el modelo ARIMA, se ha aplicado una transformación logarítmica a cada serie temporal. También se ha comprobado la estacionariedad de cada serie empleando la prueba ADF de forma individual. Los resultados obtenidos son estadísticamente significativos para rechazar la hipótesis nula ( $p < 0.05$ ). Por tanto, se ha logrado la estacionariedad. Se ha tenido que calcular las diferencias de los logaritmos, es decir, los retornos. Este cambio fue debido a que las series logarítmicas no eran estacionarias, ya que no superaban la prueba ADF. Por ello, se ha realizado esta transformación en las series temporales.

Tras evaluar la estacionariedad de las series, se ha analizado cuál debe ser la estructura óptima del VAR, es decir, cuántos *lags* hay que incluir. Para estudiar el número óptimo de lags se han empleado los criterios de información AIC (Akaike Information Criterion) y BIC (Bayesian Information Criterion). Se han estimado los VAR con distintas órdenes y se han comparado los valores de AIC y BIC. El criterio AIC sugiere incluir 2 *lags* en el modelo, mientras que el criterio BIC no sugirió incluir ningún *lag*. Se optó por seguir el criterio AIC para poder capturar suficiente dinámica temporal, es decir, modelar la variable  $t$  en función de sus valores anteriores ( $t_{-1}$  y  $t_{-2}$ ).

Una vez fijado el número de lags, se estima el VAR(2). El modelo se basa en 3 ecuaciones (una para cada serie temporal), y cada una con 6 predictores distintos (2 lags por cada una de las series temporales). Los coeficientes calculados ayudan a entender la causalidad entre las variables, es decir, el impacto que tiene la desviación de una variable en las demás variables.

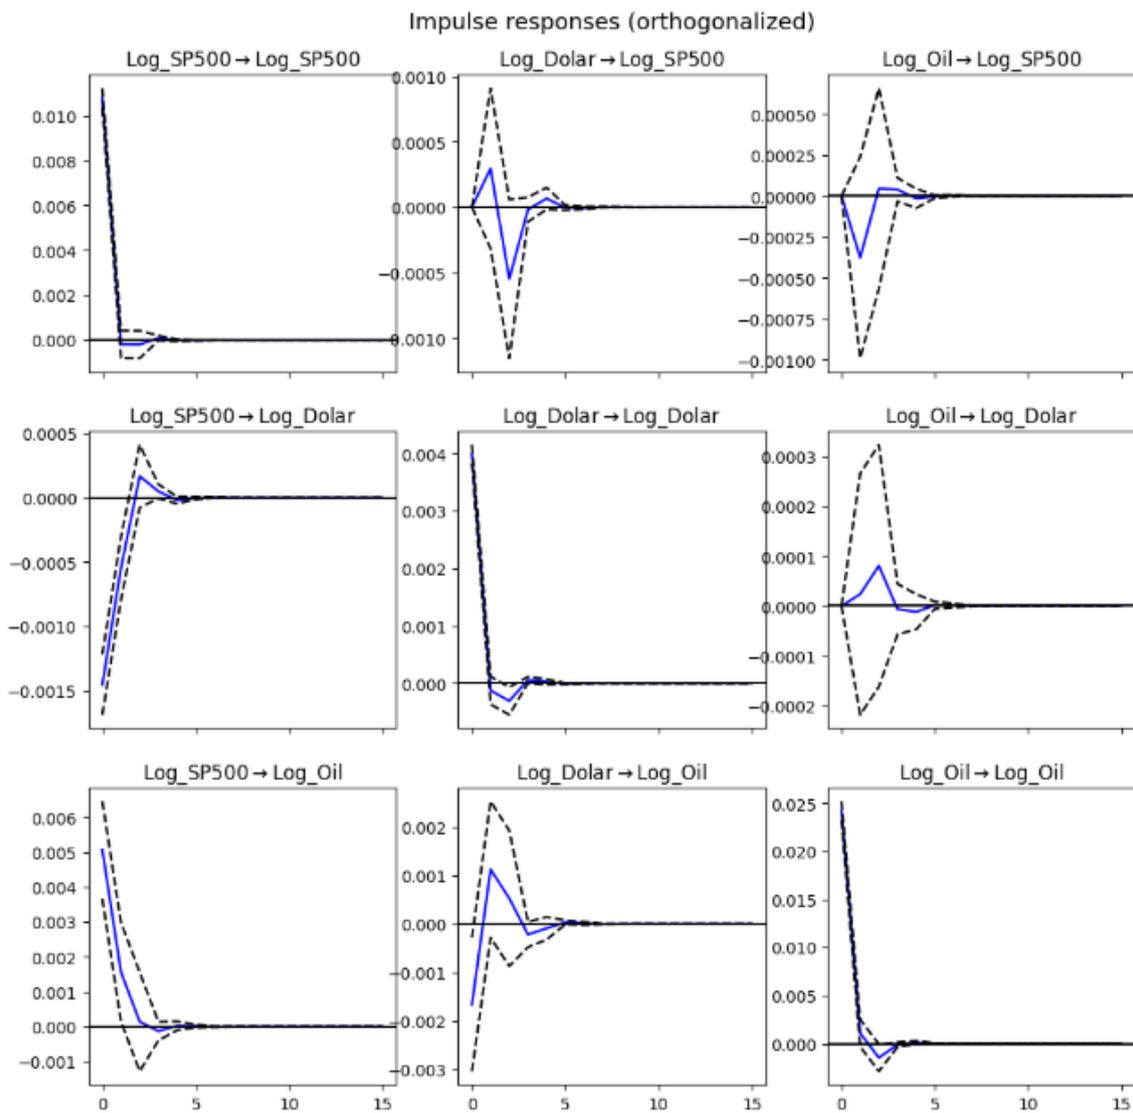
En primer lugar, en la ecuación del precio del petróleo se observa que su segundo rezago es estadísticamente significativo ( $p < 0.05$ ), y con un coeficiente bajo (-0.06). El primer rezago del índice S&P500 es también estadísticamente significativo con un coeficiente

de 0.16. Esto implica que un cambio positivo del S&P500 impacta de forma positiva también en el precio del petróleo. Por otro lado, el índice del dólar tiene un coeficiente positivo (0.3) pero un p-valor de 0.096, lo que sugiere que un fortalecimiento del dólar podría aumentar el precio del petróleo. El resto de los rezagos dentro de la ecuación del precio del petróleo tienen una probabilidad bastante alta por lo que no se puede afirmar con certeza el impacto de sus respectivas variables en el precio del petróleo.

Por último, se han evaluado las funciones de impulso-respuesta (IRF). Estas funciones miden el impacto de un choque de una variable en el resto de las variables. Se ha utilizado la descomposición de Cholesky para identificar estos *shocks*. Estos resultados muestran información económica temporal (cómo responde el precio del petróleo ante un *shock* del S&P500, por ejemplo). Aunque el modelo VAR se haya estimado sobre las diferencias logarítmicas, se ha explorado también un modelo VAR estimado directamente sobre los logaritmos de las series temporales. Esto permitirá una interpretación más directa y un mejor entendimiento de las dinámicas. En la Figura 13 se puede observar los impactos en todas las variables que tienen los distintos *shocks*. Todos los *shocks* no van a tener impacto a largo plazo. Sin embargo, a muy corto plazo pueden tener un impacto significativo. Se ha elegido la variable S&P500 como la más exógena, de ahí el orden de las variables para hacer este ejercicio.

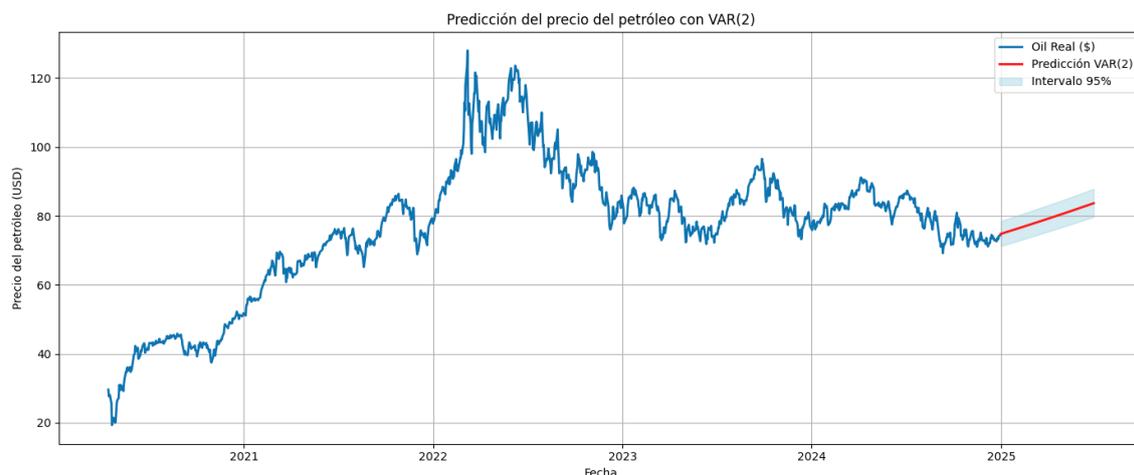
En la diagonal principal, se puede observar el impacto en las variables que tendrían los *shocks* de esas mismas variables. Evidentemente, el impacto será estadísticamente significativo. En la última fila, se puede observar el impacto que tiene un *shock* en el precio del petróleo. Se puede ver el impacto significativo de un *shock* en el S&P500. En los primeros días, el impacto causaría una subida de precio. Por otro lado, un *shock* en el índice de cambio del dólar tendría impacto únicamente el primer día, ya que los resultados no son estadísticamente significativos. Durante el resto de los días, el *shock* no tendría efecto en el precio del petróleo. También es interesante analizar el impacto que puede llegar a tener el precio del petróleo. El precio del dólar no llega a responder ante un impulso en el precio del petróleo, ya que lo más probable es que la respuesta sea 0. Además, el S&P500 tampoco llega a responder ante un impulso en el precio del petróleo.

Figura 13. Gráficos IRF



En cuanto a las predicciones calculadas con este modelo (Figura 14), son distintas a las del modelo ARIMA. En ambos casos, las predicciones siguen una tendencia bajista de cara al 2025. Además, las bandas del intervalo del 95% son mucho más estrechas, por lo que, a priori, parece un modelo más preciso.

**Figura 14.** Predicción del precio del petróleo con VAR(2)



## 5. Resultados

Tras haber desarrollado ambos modelos, tanto el AR(2) y el VAR(2), el estudio se centra ahora en valorar ambos modelos, compararlos y decidir cuál es el modelo más preciso para estimar el precio del petróleo.

En el primer caso, se ha aplicado un modelo AR(2) sobre los logaritmos del precio del petróleo. Este modelo ha resultado ser bastante robusto. Los coeficientes, ya mencionados anteriormente, son estadísticamente significativos. Además, se han calculado las métricas de error. Véase en la Tabla 2 los resultados de las métricas de error que presenta el modelo AR(2).

**Tabla 2.** Resultados modelo AR(2)

| Métrica de error | Valor  |
|------------------|--------|
| RMSE             | 0,0322 |
| MAE              | 0,0179 |
| R <sup>2</sup>   | 0,9886 |

Estos resultados demuestran que es un modelo bastante robusto. Este modelo tiene una alta capacidad explicativa y tiene un error medio bajo. Se ha demostrado también que no hay evidencias de heterocedasticidad o de autocorrelación, ya que se han hecho pruebas de diagnóstico.

En cuanto al segundo modelo, VAR(2), se ha estimado y desarrollado en base a los logaritmos de las siguientes series temporales: el precio del petróleo, el índice bursátil S&P500 y el índice del dólar estadounidense. Los resultados ofrecen información precisa

de la relación que tienen estas variables. Se concluyó que el precio del petróleo depende a corto plazo de los rezagos del S&P500 y del propio petróleo. Las funciones impulso-respuesta desarrolladas en esta investigación, enriquecieron la interpretación del VAR. Un impulso positivo del S&P500 desemboca en una respuesta positiva en el precio del petróleo. Sin embargo, un impulso positivo o negativo del petróleo, va a tener muy poco impacto en el S&P500.

Las métricas de error de este modelo fueron muy parecidas a las del modelo AR(2). Además, al no ser un modelo demasiado robusto y al no captar ciertas complejidades del mercado, el modelo es aceptable. Véase en la Tabla 3 los resultados de las métricas de error del modelo VAR(2).

*Tabla 3. Resultados modelo VAR(2)*

| Métrica de error | Valor  |
|------------------|--------|
| RMSE             | 0,0247 |
| MAE              | 0,0171 |
| R <sup>2</sup>   | 0,012  |

Estos resultados indican que el modelo también es robusto. No es un modelo demasiado complejo, y es bueno a la vez. La única métrica que no destaca mucho es el coeficiente de determinación R<sup>2</sup>. Este valor no es indicio de un mal modelo, es totalmente común en series modeladas en tasas de crecimiento. La mayor parte de la variabilidad de las tasas de crecimiento están en shocks aleatorios. Prueba de ello es el resultado obtenido en este análisis.

En comparación, ambos modelos son aceptables. Sin embargo, el modelo AR(2) tiene un mejor rendimiento para el petróleo. Esta conclusión es consistente con investigaciones recientes como Figuerola-Ferretti et al. (2021), quienes han evidenciado que, en determinadas situaciones, los modelos univariantes tienen una mejor capacidad predictiva que los modelos multivariantes. Cabe destacar que los resultados del modelo VAR hubiesen sido diferentes si se hubiesen seleccionado otras variables como ya se ha mencionado en apartados anteriores. Ambos modelos son precios, pero el AR explica mayor parte de la variabilidad del precio del petróleo que el VAR. Su interpretación es directa y tiene un error medio bajo también.

En línea con la literatura (Baumeister & Kilian, 2012) se puede concluir que el modelo AR es preferible a otros modelos para predecir a corto o medio plazo el precio del petróleo.

## 6. Conclusiones

En esta investigación se han desarrollado y comparado dos modelos que predicen el precio del petróleo. En primer lugar, se ha desarrollado un modelo AR(2) en base a los logaritmos del precio del petróleo. En segundo lugar, se ha desarrollado un modelo multivariante (VAR) sobre las diferencias logarítmicas del precio del petróleo, el índice S&P500 y el índice del dólar estadounidense.

El principal logro de esta investigación ha sido confirmar que el precio del petróleo muestra un fuerte componente autorregresivo. Por ello, el modelo AR(2) logró precisar los valores del precio. Por otro lado, se ha logrado entender las relaciones dinámicas entre las distintas series temporales observadas en el estudio.

En esta investigación, los dos modelos utilizados tienen carácter lineal, lo cual supone una limitación. No se están capturando las no linealidades del mercado. Estas no linealidades tienen influencia directa en el precio del petróleo. Otra limitación del estudio es la escasez de variables. Se han utilizado únicamente 2 series temporales más para poder entender la dinámica del precio del petróleo. Incluir variables como los precios del oro o indicadores de economía global puede enriquecer mucho el análisis.

Se propone como línea de futura investigación explorar los modelos que usan las redes neuronales. Este algoritmo de aprendizaje automático captura las no linealidades del mercado (Zhang, 2003; Yu et al., 2008). Este tipo de modelos permite incluir más variables y capturar las no linealidades en las series temporales. Por otro lado, se propone como línea de investigación futura añadir en el modelo VAR variables utilizados en estudios previos, como los inventarios del crudo o la producción industrial (Figuerola-Ferretti, McCrorie & Paraskevopoulos, 2020). Estas variables usadas en otros estudios ofrecerían una mejor explicación de los movimientos del precio del petróleo.

Por tanto, se ha demostrado que se puede realizar una estimación sobre el precio del petróleo con modelos simples y clásicos. Estos modelos ayudan, sin ninguna duda, a la toma de decisiones financieras. Para estudios futuros, estos modelos deben llegar a ser más sofisticados y deben emplear algoritmos de machine learning.

## **Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado**

**ADVERTENCIA:** Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Rodrigo Montero Ballesteros, estudiante de E2 + Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Predicción del precio del petróleo", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir "no he usado ninguna"]:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
10. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
11. **Generador de datos sintéticos de prueba:** Para la creación de conjuntos de datos ficticios.
12. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
13. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
14. **Generador de encuestas:** Para diseñar cuestionarios preliminares.
15. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 16/06/2025

Firma: Rodrigo Montero Ballesteros

## 7. Bibliografía

- Alquist, R., & Kilian, L. (2010). What do we learn from the price of crude oil futures? *Journal of Applied Econometrics*, 25(4), 539–573.
- Alruqimi, M., & Di Persio, L. (2024). *Multistep Brent oil price forecasting with a multi-aspect meta-heuristic optimization and ensemble deep learning model*. **Energy Informatics**, 7, 130.
- Attarde, S. M., & Desai, S. (2024). *Forecasting world crude oil price: Using ARIMA model*. **Frontiers in Health Informatics**, 13(7).
- Baumeister, C., & Kilian, L. (2012). Real-time forecasts of the real price of oil. *Journal of Business & Economic Statistics*, 30(2), 326–336.
- Beckers, B., & Beidas-Strom, S. (2015). Forecasting oil prices: The role of fundamentals and speculation. *IMF Working Paper No. 15/29*.
- BP. (2019). *Statistical Review of World Energy 2019*. British Petroleum.
- Escribano, A., Koczar, M. W., Jareño, F., & Esparcia, C. (2023). *Shock transmission between crude oil prices and stock markets*. **Resources Policy**, 83.
- Figuerola-Ferretti, I., Gonzalo, J., & Guijarro, J. (2021). Oil price analysts' forecasts: Are they any good? *Journal of Futures Markets*, 41(11), 1692–1711.
- Figuerola-Ferretti, I. C., McCrorie, J. R., & Paraskevopoulos, I. (2020). Mild explosivity in recent crude oil prices. *Energy Economics*, 87, Article 104387.
- Figuerola-Ferretti, I. C., Rodríguez, A., & Schwartz, E. (2021). Oil price analysts' forecasts. *Journal of Futures Markets*, 41(9), 1351–1374.
- Foroutan, S., & Lahmiri, S. (2024). Forecasting Brent oil price with hybrid machine learning and wavelet methods: An empirical study. *Energies*, 17(3), 2182.
- International Energy Agency. (2023). *Oil Market Report – December 2023*.
- Investing.com. (2024). *Historical Brent Oil Prices*.
- Kilian, L., & Zhou, X. (2020). Oil market VAR models: A survey. *Journal of Economic Surveys*, 34(5), 933–969.
- Kilian, L., & Zhou, X. (2020). *The econometrics of oil market VAR models* (Fed. Reserve Bank of Dallas, Working Paper No. 2006).
- Macrotrends. (2024). *Brent Crude Oil Prices – Historical Chart*.
- Tularam, G. A., & Saeed, T. (2016). *Oil-Price Forecasting Based on Various Univariate Time-Series Models*. **American Journal of Operations Research**, 6(3), 226–235.
- U.S. Energy Information Administration (EIA). (2021). *Short-Term Energy Outlook (STEO)*.
- Yu, L., Wang, S., & Lai, K. K. (2008). Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. *Energy Economics*, 30(5), 2623–2635.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.