

2

Predicción de precios del petróleo WTI utilizando modelos ARIMA y redes neuronales: un análisis para 2022

Jorge Valverde Frias

Ingeniero Petrolero
Universidad Nacional Autónoma de México
jorge_valverde@comunidad.unam.mx
<https://orcid.org/0009-0009-5584-7843>




CC BY-NC 4.0

2

Predicción de precios del petróleo WTI utilizando modelos ARIMA y redes neuronales: un análisis para 2022

WTI Crude Oil Price Prediction Using ARIMA and Neural Network Models: An Analysis for 2022

 <http://doi.org/10.5281/zenodo.15200039>

49

Jorge Valverde Frias

 <https://orcid.org/0009-0009-5584-7843>

Recibido: 2024/09/24
Aceptado: 2024/11/11
Publicado: 2024/12/15

Código JEL:
C32 - C45 - Q41 - Q47

Resumen

Este estudio compara el desempeño de los modelos ARIMA y Redes Neuronales en la predicción del precio del petróleo durante 2022, un año caracterizado por alta volatilidad debido a factores como la guerra en Ucrania. Se analizaron 252 datos diarios, incluyendo variables exógenas como tasas de interés, oferta, demanda y balanza comercial. Los resultados evidencian que las Redes Neuronales superaron al modelo ARIMA (3, 0, 1) en precisión: obtuvieron un menor error absoluto medio (2.018 vs. 2.34 dólares) y un menor error porcentual (2.66 % vs. 3.21 %). Además, las Redes Neuronales mejoraron su desempeño con el tiempo, mientras que el ARIMA mostró deterioro en el largo plazo. Aunque ARIMA fue más eficiente a corto plazo y menos exigente en datos, la red neuronal logró captar mejor las dinámicas no lineales del mercado, con un coeficiente de correlación de 19.56 %, frente al 5.49 % de ARIMA. Se concluye que las Redes Neuronales ofrecen mayor robustez y precisión en contextos de incertidumbre prolongada, y se recomienda explorar modelos híbridos que combinen las fortalezas de ambos enfoques.

Palabras Clave

petróleo, previsión económica, modelos matemáticos, redes neuronales, volatilidad del mercado

Referencia APA 7ª ed.

Valverde, J. (2024, diciembre). Predicción de precios del petróleo WTI utilizando modelos ARIMA y redes neuronales: un análisis para 2022. *Un Espacio Para la Ciencia*, 7(1), 47-74. <http://doi.org/10.5281/zenodo.15200039>

Citación en el texto

Valverde (2024)
(Valverde, 2024)

Abstract

This study compares the performance of ARIMA and Neural Network models in forecasting oil prices during 2022, a year marked by high volatility due to factors such as the war in Ukraine. A total of 252 daily data points were analyzed, including exogenous variables such as interest rates, supply, demand, and trade balance. Results show that Neural Networks outperformed the ARIMA (3, 0, 1) model in terms of accuracy, achieving a lower mean absolute error (2.018 vs. 2.34 USD) and a lower percentage error (2.66% vs. 3.21%). Moreover, the Neural Network model improved its performance over time, whereas ARIMA showed a decline in long-term forecasting accuracy. Although ARIMA proved more efficient in the short term and required less data, the Neural Network better captured the market's nonlinear dynamics, with a correlation coefficient of 19.56% compared to ARIMA's 5.49%. The study concludes that Neural Networks provide greater robustness and accuracy in prolonged periods of uncertainty and recommends exploring hybrid models that combine the strengths of both approaches.

Keywords

oil, economic forecasting, mathematical models, neural networks, market volatility

APA 7th ed. Reference

Valverde, J. (2024, December). WTI Crude Oil Price Prediction Using ARIMA and Neural Network Models: An Analysis for 2022. *Un Espacio Para la Ciencia*, 7(1), 47-74. <http://doi.org/10.5281/zenodo.15200039>

In-Text Citation

Valverde (2024)
(Valverde, 2024)

Introducción

El mercado del petróleo en 2022 se caracterizó por una alta volatilidad derivada de factores económicos, productivos y geopolíticos que alteraron de manera significativa la oferta y la demanda global. Entre los eventos más relevantes destaca el conflicto entre Rusia y Ucrania, que generó incertidumbre en los mercados energéticos debido a sanciones internacionales y restricciones a las exportaciones de petróleo ruso, lo que impactó los precios de forma directa. De acuerdo con la Agencia Internacional de Energía (IEA, 2022), estas dinámicas contribuyeron a una marcada inestabilidad, afectando la economía global, los costos de transporte y la calidad de vida en diversas regiones. Estas consecuencias fueron exacerbadas por las sanciones impuestas por la Unión Europea y Estados Unidos, dirigidas a limitar las importaciones de petróleo y gas ruso (European Commission, 2022; White House, 2022).

La predicción precisa de los precios del petróleo se vuelve esencial en este contexto, ya que permite a países exportadores, empresas energéticas y entidades financieras tomar decisiones informadas y mitigar riesgos en un mercado altamente dinámico. Sin embargo, la complejidad de este mercado, influenciado tanto por factores históricos como por variables exógenas (tasas de interés, producción, oferta y demanda), representa un desafío significativo para los métodos tradicionales de pronóstico (Hamilton, 2009; Nusair & Olson, 2019).

En respuesta a esta necesidad, los modelos ARIMA (Modelos Autorregresivos Integrados de Medias Móviles) y las Redes Neuronales Artificiales (RNA) han surgido como herramientas prometedoras. Mientras que ARIMA es un modelo estadístico lineal enfocado en el comportamiento temporal de las series históricas, las redes neuronales son capaces de identificar patrones no lineales y dinámicos, ofreciendo una mayor flexibilidad frente a entornos volátiles y no estacionarios (Ahmed & Shabri, 2014; Yee & Samsudin, 2021).

El presente estudio tiene como objetivo comparar el desempeño de los modelos ARIMA y las Redes Neuronales Artificiales en la predicción de los precios del petróleo. Para ello, se utilizarán 252 datos de precios diarios recopilados durante un período anual, con el fin de analizar patrones históricos y evaluar la influencia de variables externas. Se aplicarán métricas de desempeño como el Error Absoluto Medio (MAE) y el Error Porcentual Absoluto Medio (MAPE), siguiendo recomendaciones metodológicas de precisión establecidas por Stroock (2011) y Willmott y Matsuura (2005), para determinar cuál de los dos enfoques resulta más robusto y preciso en un escenario de alta volatilidad.

En última instancia, este estudio busca proporcionar herramientas predictivas que contribuyan al desarrollo de estrategias eficientes en el mercado energético. Una predicción precisa de los precios del petróleo permitirá a los actores del mercado anticiparse a las fluctuaciones y optimizar sus decisiones en un entorno marcado por la incertidumbre y los constantes cambios globales.

Revisión de la Literatura

La predicción de series temporales, en particular los precios del petróleo, ha sido abordada mediante diversas metodologías analíticas. Entre las más utilizadas se encuentran los modelos ARIMA y las Redes Neuronales Artificiales (RNA), que permiten capturar tanto las relaciones lineales como las no lineales presentes en los datos.

Los modelos ARIMA (Autoregressive Integrated Moving Average) son técnicas estadísticas utilizadas para predecir valores futuros a partir de información histórica. Estos modelos combinan tres componentes esenciales: AR (autorregresivo), I (integración) y MA (media móvil). El componente autorregresivo evalúa la relación lineal entre valores pasados y actuales, mientras que el término de integración asegura la estacionariedad de la serie temporal mediante diferenciación. Por su parte, la media móvil suaviza las fluctuaciones al promediar errores residuales en diferentes periodos (Box et al., 2015; Zohuri et al., 2022).

Existen diversos estudios que respaldan la eficacia de los modelos ARIMA en la predicción de precios del petróleo. Marques y Barros (2024) compararon modelos ARIMA y de suavizamiento exponencial, concluyendo que el modelo ARIMA mostró un mejor desempeño en términos de precisión predictiva. De forma similar, Alrweili y Fawzy (2022) destacaron la flexibilidad del modelo híbrido ARIMA-ANN, que combina relaciones lineales y no lineales en series temporales complejas. Otros estudios, como el de Yahaya et al. (2021), evidenciaron que ARIMA tiene un buen desempeño a corto plazo, mientras que el modelo GARCH ofrece mejores resultados en predicciones a largo plazo. Ahmed y Shabri (2014) también subrayaron la capacidad de los modelos ARIMA para manejar datos de alta frecuencia, aunque con limitaciones en mercados volátiles. Por último, Ariyanti y Yusnitasari (2023) demostraron que los modelos ARIMA y SARIMA presentan buenos ajustes con datos diarios, resaltando la capacidad de SARIMA para manejar estacionalidad en los datos.

Las Redes Neuronales Artificiales (RNA), en particular el Perceptrón Multicapa (PMC), son una arquitectura de aprendizaje automático diseñada para capturar patrones no lineales en los datos. Este modelo está compuesto por una capa de entrada, encargada de recibir las variables de entrada; capas ocultas, donde se procesan y transforman los datos mediante funciones de activación; y una capa de salida, que produce las predicciones finales (Haykin, 2005). Las RNA se entrenan ajustando iterativamente los pesos de las conexiones mediante algoritmos como el descenso del gradiente, que minimiza una función de pérdida, como el error de suma de cuadrados. Una de las funciones más utilizadas en las redes neuronales es la tangente hiperbólica, debido a sus propiedades matemáticas y su capacidad para introducir no linealidades, lo cual es clave en la predicción de datos complejos como los precios del petróleo (Haykin, 2005; Chandar et al., 2015).

La literatura reciente ha explorado ampliamente el uso de redes neuronales en la predicción de precios del petróleo. LeCun et al. (2015) destacan la relevancia de los perceptrones multicapa en

el aprendizaje profundo, mientras que Bishop (2006) ofrece un análisis riguroso de las técnicas de entrenamiento y estructura de las redes neuronales. Asimismo, Aggarwal (2018) presenta una visión integral de las arquitecturas neuronales, destacando sus aplicaciones prácticas en problemas complejos como las predicciones de series temporales. Wang y Wu (2013) demostraron que las redes neuronales combinadas con algoritmos estadísticos mejoran la precisión de las predicciones. Por otra parte, Rojas (1996) aborda los fundamentos teóricos y prácticos del perceptrón multicapa, brindando ejemplos detallados sobre su implementación. Yee y Samsudin (2021) compararon RNA con modelos ARIMA, concluyendo que las RNA ofrecen un ajuste más robusto en series temporales con fluctuaciones complejas. Estas investigaciones subrayan la capacidad de las redes neuronales para modelar relaciones complejas y no lineales, características fundamentales para la predicción de precios en mercados volátiles.

La comparación entre los modelos ARIMA y las Redes Neuronales Artificiales revela que ambos enfoques presentan ventajas y limitaciones dependiendo de la naturaleza de los datos y el horizonte temporal de la predicción. Mientras que los modelos ARIMA son efectivos para capturar patrones lineales y estacionales en series temporales, las redes neuronales destacan en su capacidad para modelar relaciones no lineales y dinámicas complejas. Ning et al. (2022) señalaron que los modelos ARIMA son más adecuados para predicciones de corto plazo, mientras que las RNA muestran ventajas en horizontes más amplios. Sharma y Yadav (2020) concluyeron que la integración de ambos enfoques podría generar modelos más robustos en entornos de alta volatilidad. La selección del modelo más adecuado dependerá del contexto específico del problema y de las características intrínsecas de los datos analizados (Fama, 1965; Claeskens & Hjort, 2008).

Metodología

El objetivo de esta investigación fue comparar el desempeño de los modelos ARIMA (Modelos Autorregresivos Integrados de Medias Móviles) y las Redes Neuronales Artificiales (RNA) en la predicción de los precios del petróleo. Se evaluó su precisión, adaptabilidad y bondad de ajuste mediante métricas cuantitativas, con el fin de determinar cuál de estos modelos ofrece mejores resultados en diferentes escenarios.

Para el análisis, se recopilaron 252 datos de precios diarios del petróleo correspondientes a los días hábiles entre el 3 de enero de 2022 y el 3 de enero de 2023. La fuente principal de datos fue la Agencia Internacional de Energía (IEA) y la Administración de Información Energética de Estados Unidos, seleccionadas por su confiabilidad y frecuencia diaria en la publicación de datos. Esta serie temporal incluye la variabilidad estacional del precio del petróleo, permitiendo capturar cambios en la demanda a lo largo del año.

El proceso metodológico inició con un análisis exploratorio de datos, con el objetivo de identificar patrones, tendencias y estacionalidad en la serie temporal. Esta etapa permitió seleccionar parámetros adecuados para los modelos ARIMA, como el orden de diferenciación y la identificación de componentes estacionales. En el caso de las Redes Neuronales Artificiales, se integraron variables exógenas relevantes (tasas de interés, oferta, demanda y producción) que influyen directamente en el comportamiento del mercado petrolero.

Una vez procesados los datos, se procedió a la estimación y ajuste de los modelos. Los parámetros del modelo ARIMA fueron calculados mediante técnicas de máxima verosimilitud, optimizando su precisión y eliminando componentes no significativos. Para las Redes Neuronales, se realizó un ajuste de los hiperparámetros, considerando el número de capas, neuronas y la tasa de aprendizaje, con el objetivo de lograr una adecuada convergencia del modelo.

La validación de los modelos se realizó utilizando métricas de desempeño ampliamente reconocidas en series temporales, como el Error Absoluto Medio (MAE), el Error Porcentual Absoluto Medio (MAPE) y los criterios de información de Akaike (AIC) y Bayesiano de Schwarz (BIC). Estas métricas permitieron evaluar la precisión y estabilidad de cada modelo en diferentes horizontes temporales.

Finalmente, se realizó la comparación entre ARIMA y Redes Neuronales, analizando los resultados obtenidos a partir de las métricas mencionadas. Esta comparación permitió identificar cuál de los dos enfoques es más efectivo para predecir los precios del petróleo, considerando tanto los datos históricos como las variables externas que afectan su comportamiento.

La implementación de los modelos y el análisis de datos se llevaron a cabo utilizando el software estadístico SPSS de IBM (2019). Este software facilitó la realización del análisis exploratorio, la estimación de los parámetros y la validación de los modelos, asegurando un proceso homogéneo y consistente en la comparación de los resultados.


Resultados

En esta sección se presentan los resultados obtenidos a partir del análisis descriptivo de los datos y la evaluación comparativa de los modelos ARIMA y Redes Neuronales en la predicción de los precios del petróleo durante el año 2022.

El análisis de la muestra inicia con el comportamiento del precio del barril de petróleo a lo largo del año de estudio. En la Figura 1, se observa una fuerte volatilidad en los precios, con un inicio cercano a los 78 dólares por barril. Posteriormente, se presenta una subida acelerada que supera los 120 dólares, alcanzando su punto máximo en marzo con un valor aproximado de 123 dólares. Tras esta subida, el precio experimenta una caída progresiva, tocando nuevamente el piso de 78 dólares. Finalmente, hacia finales del año, se observa una nueva tendencia bajista, llegando a valores cercanos a 71 dólares. Estos movimientos están claramente influenciados por factores externos, como la invasión de Rusia a Ucrania, que provocó incrementos abruptos en los precios del crudo a mediados de febrero.

Figura 1

Evolución del Precio del Barril de Petróleo entre 2021 y 2023



Nota: Representación gráfica de las fluctuaciones del precio del barril de petróleo en USD desde octubre de 2021 hasta marzo de 2023. Las anotaciones destacan puntos clave en la dinámica del mercado.


En términos de volatilidad, se encontró que la volatilidad diaria del precio del petróleo fue del 3.04 %, una cifra elevada en comparación con otros activos financieros de alta volatilidad, como las acciones del sector tecnológico. Al analizar la volatilidad anual, el valor alcanzó el 48.19 %, lo que sugiere que el precio del petróleo pudo variar hasta casi la mitad de su valor a lo largo de un año, confirmando la naturaleza altamente dinámica de este mercado.

Por otra parte, los rendimientos logarítmicos del precio del petróleo, mostrados en la Figura 2, permitieron analizar los cambios porcentuales de manera aditiva, facilitando la interpretación de los movimientos del activo. Los rendimientos logarítmicos se calcularon como la diferencia entre el logaritmo del precio final y el logaritmo del precio inicial, lo que permitió identificar la magnitud y dirección de las fluctuaciones a lo largo del tiempo.

En cuanto al desempeño de los modelos predictivos, se observó que los modelos ARIMA (3, 0, 1) y Redes Neuronales fueron los más precisos. La correlación entre los precios reales y los resultados del modelo ARIMA (3, 0, 1) fue de 5.49 %, mientras que la correlación entre los precios reales y el modelo de Redes Neuronales fue

Figura 2

Tendencia de Rendimientos Logarítmicos del Precio del Petróleo



Nota: Análisis de rendimientos logarítmicos del precio del barril de petróleo entre diciembre de 2021 y enero de 2023. Se observan variaciones agrupadas y una tendencia decreciente general resaltada por la línea de tendencia.


notablemente superior, alcanzando el 19.56 %. Además, al comparar directamente el desempeño entre ambos modelos, se encontró una correlación del 36.61 %, lo que evidencia que la red neuronal tiene un mejor ajuste general a los datos observados (Figura 3).

El error promedio del modelo de Redes Neuronales fue de 2.018 dólares, mientras que el modelo ARIMA (3, 0, 1) registró un error de 2.34 dólares, lo que representa una diferencia mínima entre ambos. En contraste, los otros modelos ARIMA presentaron un desempeño considerablemente menor, con errores absolutos de 85.96 dólares para ARIMA (0, 2, 0), 12.53 dólares para ARIMA (0, 1, 0), 14.83 dólares para ARIMA (3, 1, 2) y 14.67 dólares para ARIMA (3, 1, 1).

El análisis del error porcentual, confirma esta tendencia. El modelo ARIMA (3, 0, 1) presentó un error porcentual de 3.21 %, mientras que el modelo de Redes Neuronales obtuvo un error menor de 2.66 %, posicionándose como el mejor modelo en términos de precisión. Los otros modelos ARIMA registraron errores significativamente mayores, destacando el modelo ARIMA (0, 2, 0) con un 116 %,

Figura 3

Comparación de Predicciones del Precio del Petróleo con Modelos ARIMA y Redes Neuronales



Nota: Comparación entre el precio real del barril de petróleo (línea roja punteada) y las predicciones generadas por diferentes modelos ARIMA y una red neuronal. Los modelos incluyen diversas configuraciones de parámetros ARIMA, mostrando diferencias en su capacidad de aproximación.


seguido del ARIMA (0, 1, 0) con 16.87 %, el ARIMA (3, 1, 2) con 19.94 % y el ARIMA (3, 1, 1) con 19.73 %.

Al analizar los errores en términos de máximos y mínimos, se encontró que el modelo ARIMA presentó un error máximo de 7.5 %, mientras que el modelo de Redes Neuronales alcanzó un 5 %, es decir, una diferencia de aproximadamente 2.5 %. En cuanto a los valores mínimos, ambos modelos coincidieron, registrando un error cercano al 0.3 %.

Finalmente, los criterios de información refuerzan la superioridad del modelo de Redes Neuronales en comparación con el ARIMA (3, 0, 1). En la Figura 4, se observa que el modelo de Redes Neuronales registró un AIC de -1388.39 y un BIC de -1388.39, valores más bajos en comparación con el AIC de -1249.83 y el BIC de -1235.44 obtenidos por el modelo ARIMA (3, 0, 1). Esto indica que la red neuronal logra un mejor equilibrio entre ajuste y complejidad del modelo, siendo más eficiente y robusta para predecir los precios del petróleo.

Figura 4

Comparación de los Criterios AIC y BIC entre Modelos de Predicción



Nota: Valores de los criterios de información Akaike (AIC) y Bayesiano (BIC) para los modelos ARIMA y la red neuronal. Estos indicadores evalúan la calidad del modelo penalizando la complejidad, donde valores más bajos reflejan un mejor equilibrio entre ajuste y parsimonia.


Discusión

El análisis del comportamiento del precio del petróleo a lo largo del año 2022 muestra una alta volatilidad y fluctuaciones significativas, como se observa en la Figura 5. El precio presentó una periodicidad cercana a un mes, donde subidas pronunciadas pierden fuerza rápidamente hasta tocar niveles mínimos, como los 73 dólares por barril. Estos resultados resaltan la complejidad y dinamismo del mercado energético, lo cual justifica la necesidad de modelos robustos para su predicción.

Al comparar los dos mejores modelos, ARIMA (3, 0, 1) y Redes Neuronales, se observan comportamientos distintos en las predicciones. Por un lado, el modelo ARIMA muestra una tendencia alcista, logrando reconocer los máximos del precio real en dos ocasiones. Como se aprecia en las dos últimas cimas del precio real, el modelo se mantiene dentro del rango de la volatilidad, aunque presenta un sesgo debido a su naturaleza de ponderar valores

Figura 5

Comparación Detallada de Predicciones: Modelo ARIMA (3, 0, 1) vs. Red Neuronal




Nota: Comparación entre el precio real del barril de petróleo (línea roja punteada) y las predicciones generadas por el modelo ARIMA (3, 0, 1) y la red neuronal. Se destacan áreas clave donde cada modelo presenta mayor precisión o desviación respecto al precio real.

pasados. Por otro lado, el modelo de Redes Neuronales muestra un comportamiento más estable, con predicciones menos sensibles a las fluctuaciones del precio. Este modelo se asemeja a una media móvil, ya que permanece en la mitad del rango de variación del precio, sin mostrar una tendencia definida, oscilando entre 76.7 y 78.7 dólares por barril.

Los coeficientes de correlación obtenidos confirman la diferencia en el desempeño entre ambos modelos. El modelo ARIMA (3, 0, 1) presenta una correlación del 5.49 % con respecto al precio real, mientras que el modelo de Redes Neuronales alcanza una correlación superior, con un valor de 19.56 %. La diferencia en los coeficientes refleja que el modelo de Redes Neuronales tiene un mejor ajuste general a la tendencia real, aunque, en algunos casos, los resultados pueden desviarse ligeramente debido a su menor sensibilidad a fluctuaciones puntuales.

En cuanto a los errores absolutos, la Figura 6 muestra que el modelo ARIMA (3, 0, 1) presenta picos de error más elevados, alcanzando un valor máximo de 5.5 dólares, mientras que el modelo de Redes Neuronales tiene un valor máximo de 4.5 dólares, con una

Figura 6
Evolución del Error Absoluto entre Modelos de Predicción




Nota: Comparación del error absoluto entre el modelo ARIMA (3, 0, 1) y la red neuronal respecto al precio real del petróleo. Las líneas de tendencia muestran la evolución general del error para cada modelo, destacando puntos clave donde las predicciones presentan mayores discrepancias.

diferencia de 1 dólar entre ambos modelos. Además, se observa una mayor volatilidad en los errores del modelo ARIMA, donde estos valores máximos se repiten tres veces a lo largo del tiempo. Al analizar la tendencia del error, se encontró que el modelo ARIMA aumenta su error en un 40 % a lo largo del período de predicción, pasando de 2 a 2.8 dólares. En contraste, el modelo de Redes Neuronales muestra una tendencia decreciente, reduciendo su error en un 42 %, pasando de 2.8 a 1.2 dólares.

La comparación de los errores porcentuales, como se presenta en la Figura 7, refuerza estas observaciones. El modelo de Redes Neuronales presenta una tendencia bajista en su error porcentual, disminuyendo de 3.5 % a 1.8 %, lo que equivale a una mejora de 1.7 %. Por el contrario, el modelo ARIMA (3, 0, 1) pierde precisión a medida que avanza la predicción, aumentando su error de 2.6 % a 3.7 %, con una diferencia de 1.1 % (Figura 8). Esto indica que el modelo de Redes Neuronales se adapta mejor a los datos en el largo plazo, mejorando progresivamente su desempeño conforme se avanza en la ventana de predicción.

Figura 7
Evolución del Error Porcentual en Predicciones de Modelos

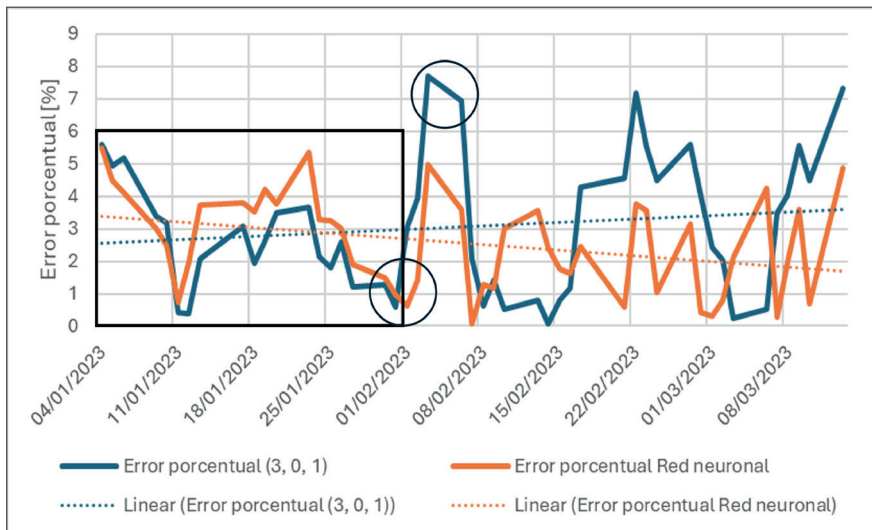


Nota: Comparación del error porcentual entre el modelo ARIMA (3, 0, 1) y la red neuronal respecto al precio real del petróleo. Las líneas de tendencia resaltan la evolución general del error porcentual, destacando periodos de mayor y menor precisión en las predicciones.

En términos de adaptabilidad, se observa que el modelo de Redes Neuronales ajusta sus predicciones de manera dinámica a lo largo del tiempo, lo cual se evidencia en la Figura 9. La prueba de autocorrelación muestra que los valores predichos mantienen relación con valores pasados en retardos específicos, como el 11 y el 14, lo que sugiere que el modelo considera tanto los datos recientes como los más alejados en su proceso de aprendizaje. En contraste, el modelo ARIMA, como se muestra en la Figura 10, reduce gradualmente la importancia de los valores pasados, priorizando únicamente los datos más recientes en sus predicciones.

La representación de las predicciones contra las fechas en las Figuras 11 y 12 resalta otra diferencia clave entre los modelos. El modelo ARIMA presenta un comportamiento más mecánico o estático, ya que sus predicciones se limitan a puntos específicos en el tiempo. Por otro lado, el modelo de Redes Neuronales ofrece predicciones más dinámicas, generando valores que se ajustan de manera más consistente a los periodos de tiempo analizados. Esta característica del modelo de Redes Neuronales resulta

Figura 8
Detalle del Error Porcentual en Modelos de Predicción



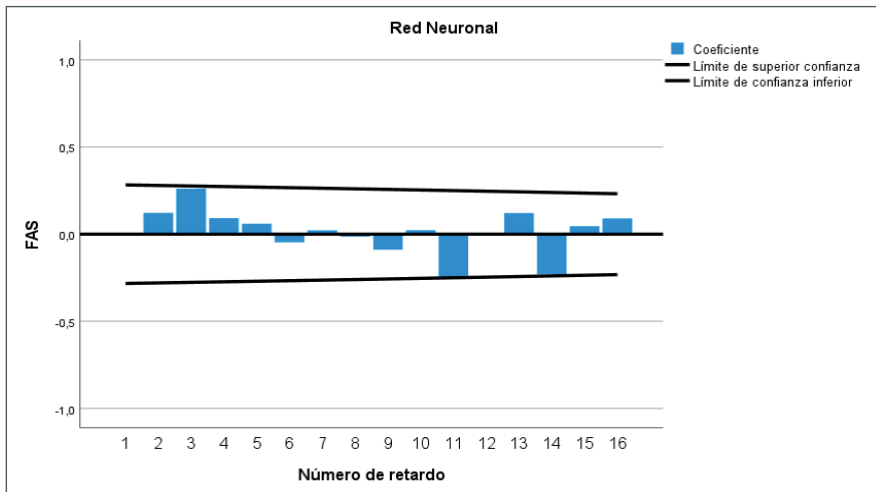
Nota: Análisis detallado del error porcentual de los modelos ARIMA (3, 0, 1) y la red neuronal respecto al precio real del petróleo. Las áreas resaltadas y las líneas de tendencia indican periodos clave y patrones en la precisión relativa de las predicciones.

particularmente útil para aplicaciones en planeación financiera, donde se requieren proyecciones más continuas y estables en el tiempo.

Se encontró que el modelo de Redes Neuronales presenta un desempeño superior en términos de error absoluto, error porcentual y adaptabilidad a largo plazo, lo que lo hace más adecuado para la predicción de precios del petróleo en escenarios volátiles. Aunque el modelo ARIMA (3, 0, 1) ofrece resultados precisos en el corto plazo, su desempeño tiende a deteriorarse conforme avanza el tiempo, mostrando una menor capacidad de adaptación a cambios en la tendencia. Además, es importante considerar que, mientras el modelo ARIMA requiere únicamente datos históricos, el modelo de Redes Neuronales demanda un conjunto más amplio de variables exógenas, como tasas de interés, producción, oferta y demanda, lo que puede representar una barrera en su implementación práctica.

La elección entre ambos modelos dependerá, por lo tanto, del horizonte de predicción y la disponibilidad de datos, siendo el

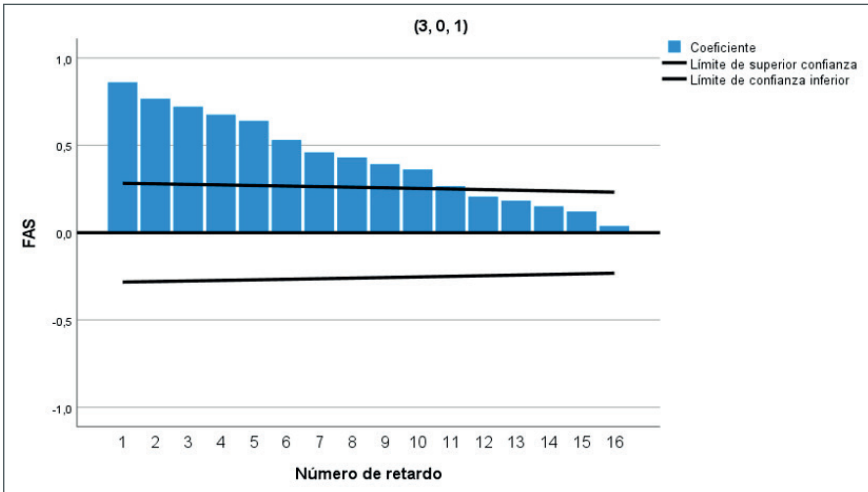
Figura 9
Análisis de los Coeficientes de Autocorrelación Parcial en la Red Neuronal



Nota: Representación de los coeficientes de autocorrelación parcial (FAS) para la red neuronal en función del número de retardos. Los límites de confianza superior e inferior indican el rango dentro del cual los coeficientes no son estadísticamente significativos.

Figura 10


Análisis de los Coeficientes de Autocorrelación Parcial en el Modelo ARIMA (3, 0, 1)



Nota: Representación de los coeficientes de autocorrelación parcial (FAS) para el modelo ARIMA (3, 0, 1) en función del número de retardos. Los límites de confianza superior e inferior marcan el rango de significancia estadística.

Figura 11

Predicción del Modelo ARIMA (3, 0, 1) con Intervalos de Confianza

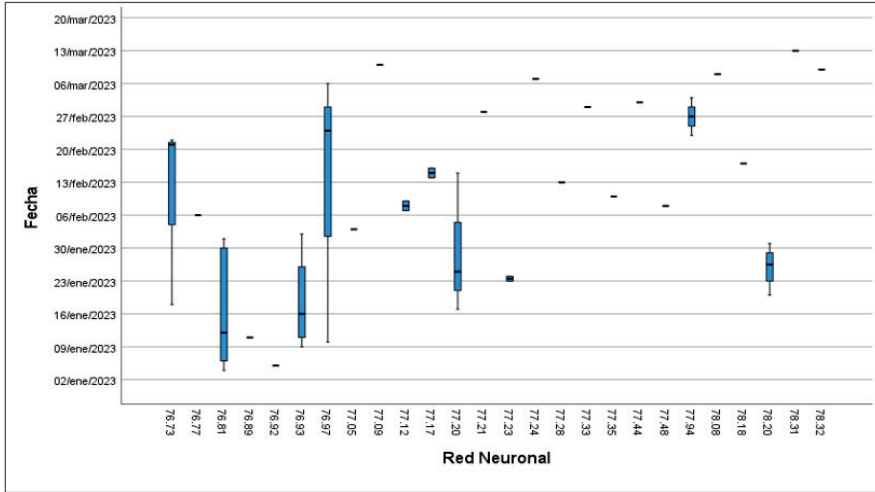


Nota: Predicción del precio del petróleo utilizando el modelo ARIMA (3, 0, 1) desde enero hasta marzo de 2023. Los puntos representan los valores estimados y las barras indican los intervalos de confianza asociados a las predicciones.

modelo ARIMA más adecuado para proyecciones de corto plazo y el modelo de Redes Neuronales más eficiente para predicciones de largo plazo y escenarios dinámicos.

Figura 12

Predicción de la Red Neuronal con Intervalos de Confianza



Nota: Predicción del precio del petróleo utilizando una red neuronal desde enero hasta marzo de 2023. Los puntos representan los valores estimados y las barras muestran los intervalos de confianza asociados, reflejando la variabilidad en las predicciones.

Conclusiones

El presente estudio comparó el desempeño de los modelos ARIMA (3, 0, 1) y Redes Neuronales en la predicción de los precios del petróleo, encontrando que el modelo de Redes Neuronales ofrece mayor precisión y adaptabilidad a las dinámicas complejas del mercado energético.

Uno de los hallazgos más relevantes es que el modelo de Redes Neuronales logró un menor error absoluto medio y error porcentual, con diferencias de 0.325 dólares y 0.55 %, respectivamente, respecto al mejor modelo ARIMA (3, 0, 1). Además, se observó que la precisión de la red neuronal mejora a lo largo del tiempo, disminuyendo su margen de error conforme avanza la ventana de predicción. Este comportamiento contrasta con el modelo ARIMA, que si bien presenta mayor precisión en el corto plazo, muestra una tendencia creciente en sus errores, evidenciando su limitada capacidad de adaptación en horizontes temporales más amplios.

Un aporte relevante del estudio es la incorporación de factores exógenos en el modelo de Redes Neuronales, como la producción, tasas de interés, oferta, demanda y balanza comercial, con una importancia relativa de 57.8 %, 27.3 %, 6 %, 3.7 % y 5.2 %, respectivamente. Estos resultados subrayan que la inclusión de variables externas mejora significativamente el rendimiento del modelo predictivo, permitiéndole captar relaciones más complejas y no lineales que afectan el precio del petróleo.

Otro aporte significativo es el análisis de la sensibilidad de los modelos frente a los datos. La correlación entre los valores reales y las predicciones de la red neuronal alcanzó 19.56 %, mientras que en el modelo ARIMA (3, 0, 1) fue de apenas 5.49 %, lo que demuestra que la red neuronal es cuatro veces más efectiva para captar las variaciones del mercado. Sin embargo, el estudio también identifica una limitación importante: el modelo ARIMA es más eficiente en términos de datos, utilizando solo 252 registros históricos, mientras que la red neuronal requiere 1512 registros, lo

que podría representar un desafío en contextos con disponibilidad limitada de información.

Se concluye que el modelo ARIMA (3, 0, 1) es más adecuado para predicciones a corto plazo, donde su simplicidad y bajos requerimientos de datos son ventajas competitivas. En cambio, el modelo de Redes Neuronales es preferible para predicciones a largo plazo y en escenarios de alta volatilidad, debido a su mayor capacidad de ajuste y generalización.

Como recomendación, se sugiere que futuros estudios analicen períodos históricos con eventos similares, como conflictos bélicos o crisis energéticas, para identificar con mayor precisión los factores externos que influyen en el precio del petróleo y evaluar la robustez de los modelos en condiciones extremas. Además, se plantea la necesidad de explorar modelos híbridos que integren las fortalezas de ARIMA y Redes Neuronales, con el objetivo de optimizar el desempeño predictivo y reducir los errores a corto y largo plazo.

Referencias

- Aggarwal, C. (2018). *Neural networks and deep learning: A textbook* [Abstract]. Springer Cham. <http://bit.ly/3ZJdoOJ>
- Ahmed, R. A., & Shabri, A. B. (2014). Daily crude oil price forecasting model using ARIMA, generalized autoregressive conditional heteroscedastic and support vector machines. *American Journal of Applied Sciences*, 11(3), 425–432. <https://doi.org/10.3844/ajassp.2014.425.432>
- Alrweili, H., & Fawzy, H. (2022). Forecasting crude oil prices using an ARIMA-ANN hybrid model [Abstract]. *Journal of Statistics Applications & Probability*, 11(3), 845–855. <https://doi.org/10.18576/jsap/110308>
- Ariyanti, V. P., & Yusnitasari, T. (2023). Comparison of ARIMA and SARIMA for forecasting crude oil prices. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(2), 405–413. <https://doi.org/10.29207/resti.v7i2.4895>
- Bishop, C. M. (2006). *Pattern recognition and machine learning* [Abstract]. Springer. <https://doi.org/10.1007/978-0-387-31073-2>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley. <https://doi.org/10.1002/9781118675021>
- Chandar, S. K., Sumathi, M., & Sivanandam, S. N. (2015). Prediction of stock market price using hybrid of wavelet transform and artificial neural network. *Indian Journal of Science and Technology*, 9(8), 1-5. <https://doi.org/10.17485/ijst/2016/v9i8/87905>
- Claeskens, G., & Hjort, N. L. (2008). *Model selection and model averaging*. Cambridge University Press. <http://dx.doi.org/10.1017/CBO9780511790485>
- European Commission. (2022, June 2). *Russia's war on Ukraine: EU adopts sixth package of sanctions against Russia*. <https://tinyurl.com/3vs6k835>

- Fama, E. F. (1965). The behavior of stock-market prices. *The Journal of Business*, 38(1), 34–105. <https://doi.org/10.1086/294743>
- Hamilton, J. D. (2009). Causes and consequences of the oil shock of 2007–08 [Abstract]. *Brookings Papers on Economic Activity*, 2009(Spring), 215–261. <https://doi.org/10.1353/eca.0.0047>
- Haykin, S. (2005). *Neural Networks and Learning Machines*. Pearson. <https://bit.ly/481BcPY>
- IBM. (2019). *Guía de usuario de IBM SPSS Statistics 26 Core system*. <https://ibm.co/3XVcE6u>
- IEA. (2022, 15 de noviembre). *Oil market report*. IEA. <https://bit.ly/3YflyNq>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Marques, J., & Barros, A. (2024). Oil-price forecasting based on ARIMA, exponential smoothing, and autoregressive neural network models. *Contribuciones a las Ciencias Sociales*, 17(9), e10331. <https://doi.org/10.55905/revconv.17n.9-070>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022, July). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Nusair, S. A., & Olson, D. (2019). The effects of oil price shocks on Asian exchange rates: Evidence from quantile regression analysis. *Energy Economics*, 78, 44–63. <https://doi.org/10.1016/j.eneco.2018.11.009>
- Rojas, R. (1996). *Neural Networks: A Systematic Introduction*. Springer Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-61068-4>
- Sharma, S., & Yadav, M. (2020, Summer). Analyzing the robustness of ARIMA and neural networks as a predictive model of crude oil prices. *Theoretical and Applied Economics*, 27(2(623)), 289–300. <https://bit.ly/47Cds4J>
- Stroock, D. W. (2011). *Probability theory: An analytic view* (2nd ed.). Cambridge University Press. <https://bit.ly/3TZ149i>

- Wang, G., & Wu, J. (2013). Crude oil price forecasting based on the ARIMA and BP neural network combinatorial algorithm [Abstract]. *ICLEM 2012: Logistics for Sustained Economic Development—Technology and Management for Efficiency*. <https://doi.org/10.1061/9780784412602.0075>
- White House. (2022, March 8). *Fact sheet: United States bans imports of Russian oil, liquefied natural gas, and coal*. The White House. <https://bit.ly/4dr6j8l>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>
- Yahaya, A. E., Etuk, H. E., & Amos, E. (2021). Comparative performance of ARIMA and GARCH model in forecasting crude oil price data. *Asian Journal of Probability and Statistics*, 15(4), 251–275. <https://doi.org/10.9734/ajpas/2021/v15i430378>
- Yee, K. W., & Samsudin, H. B. (2021). Comparison between artificial neural network and ARIMA model in forecasting palm oil price in Malaysia. *International Journal of Scientific Engineering and Science*, 5(11), 12–15. <https://bit.ly/3YgSQvP>
- Zohuri, B., Mossavar-Rahmani, F., & Behgounia, F. (2022). Statistical forecasting—regression and time series analysis. In *Knowledge is Power in Four Dimensions: Models to Forecast Future Paradigm with Artificial Intelligence Integration in Energy and Other Use Cases* (pp. 709–722). Elsevier. <https://doi.org/10.1016/B978-0-323-95112-8.00021-0>

