

Pronóstico de la producción de petróleo de las empresas públicas del Ecuador mediante la aplicación del modelo estadístico ARIMA

Forecasting oil production of public companies in Ecuador by applying the ARIMA statistical model

Kevin Kinjang Li Ye¹⁹
Eimy Maria Aguilar Game²⁰
Milena Gardenia Muñoz Franco²¹

Artículo recibido el 17/07/2023

Artículo aprobado el 10/10/2023

Resumen

En esta investigación se pronosticó, mediante el modelo estadístico ARIMA, la producción de petróleo de las empresas públicas del Ecuador. Los datos utilizados abarcaron el periodo desde enero del 2007 hasta octubre del 2022. Posteriormente, se realizó pruebas estacionarias con el propósito de identificar el tipo de serie y de determinar la necesidad de aplicar diferenciación para poder ajustar el modelo a una serie estacionaria. El modelo óptimo y eficiente que se utilizó para realizar la predicción fue la serie ARIMA (0,1,2) (0,0,1). Adicionalmente, se llevó a cabo un análisis utilizando la prueba de Ljung-Box para evaluar la calidad del modelo, y los resultados indicaron que el modelo es apropiado para los datos. En este estudio se pronosticó la producción de petróleo para los siguiente 10 meses lo cual se prevé una disminución leve en la producción.

Palabras claves: Producción petróleo, ARIMA, pronóstico, series temporales, estadística.

Abstract

In this research, the ARIMA statistical model was used to forecast the oil production of Ecuador's public companies. The data used covered the period from January 2007 to October 2022. Subsequently, stationary tests were carried out to identify the type of series and to determine the need to apply differencing to adjust the model to a stationary series. The optimal and efficient model used for forecasting was the ARIMA (0,1,2) (0,0,1) series. Additionally, an analysis using the Ljung-Box test was conducted to evaluate the quality of the model, and the results indicated that the model is appropriate for the data. In this study,

¹⁹ Licenciado en Negocios Internacionales, kevinliye18@gmail.com, <https://orcid.org/0009-0001-7001-3005>.

²⁰ Licenciado en Negocios Internacionales, eimy.agame14@gmail.com, <https://orcid.org/0009-0008-3653-1600>.

²¹ Licenciado en Negocios Internacionales, milenagmf@gmail.com, <https://orcid.org/0009-0002-8299-5867>.

oil production was forecasted for the next 10 months and a slight decrease in production is expected.

Key words: Oil Production, ARIMA, forecast, time series, statistics.

Introducción

El objetivo de la presente investigación es realizar un pronóstico de la producción de petróleo de las empresas públicas del Ecuador utilizando el modelo autorregresivo integrado de media móvil (ARIMA) mediante el programa R Studio.

Esta decisión se fundamenta en la relevancia de los modelos de series de tiempo univariados para lograr mejores predicciones, como se ha señalado en investigaciones previas (Asteriou y Hall, 2007, citado en Sánchez et al, 2013, p. 316). Dicha proyección es crucial para tomar decisiones administrativas y aplicar las medidas apropiadas, ya que uno de los principales ingresos del país es la producción y exportación de petróleo. Además, este estudio aborda la importancia de utilizar herramientas de Inteligencia de Negocios como R Studio.

El problema de investigación se centra en la necesidad de mejorar los rendimientos empresariales en un contexto de alta competitividad, donde la predicción y estimación de la producción de petróleo es un factor determinante. Por tanto, se plantea la pregunta. ¿Las empresas públicas del sector petrolero del Ecuador tendrán una buena proyección en la producción de petróleo para los siguientes 10 meses?

1. Revisión literaria

Existen muchos estudios que utilizan el modelo ARIMA para efectuar pronósticos de producción a corto plazo. Sin embargo, son limitadas las investigaciones científicas referentes a la producción de petróleo en las empresas públicas del Ecuador. Los estudios predominantes se centran mayormente en el sector agrícola.

Los estudios con modelos univariados de series de tiempo son eficaces a corto plazo, en el trabajo de Serrano et. al (2013), se empleó dicho modelo para predecir la producción de carne. Este enfoque fue destacado por su superioridad en comparación con otros métodos predictivos, como los modelos de regresión lineal multivariados, los cuales, pese a su amplia utilización con propósitos predictivos, han arrojado resultados insatisfactorios. No obstante, es importante recalcar que este modelo presenta una ventaja donde la construcción del modelo no tiene un fundamento teórico, dado que se basa en el uso del comportamiento de la misma variable para realizar la predicción (Vogelvang, 2005), como ocurrió en el estudio realizado por Cacino et. al (2022) que efectúa un pronóstico sobre la producción de mora, donde el enfoque adoptado carece de una estructura teórica que ha demostrado ser más preciso para pronosticar la situación del mundo real en comparación con otros métodos de regresión y econométricos. De igual manera, tal como se observa en el estudio llevado a cabo por Sánchez et. al (2013), en la que se aplicó el modelo ARIMA para pronosticar la

producción de leche, la fundamentación teórica del modelo no es relevante, lo cual incrementa la aplicabilidad de los modelos de series de tiempo en la predicción de su comportamiento. **Series de tiempos**

En el ámbito del análisis de datos, se hace referencia a una serie de tiempo como aquella variable que engloba datos recopilados, registrados u observados, los cuales están ordenadas cronológicamente en el tiempo cuyo objetivo es predecir valores en el futuro (Murillos et. al, 2003; Ramírez et. al, 2021). Con la aplicación de los modelos de series temporales, “se puede describir y predecir el comportamiento de un fenómeno que cambia en el tiempo, y que muestra dependencia entre las observaciones sucesivas” (Arellano 2001, como se citó Sánchez et. al, 2013, p. 213). Esta tiene como finalidad orientar las decisiones en muchas áreas del mundo como los mercados, el transporte, la identificación de fallas, el clima y entre otros (Botero y Cano, 2008). De la misma manera, los datos de las series de tiempo pueden utilizarse para analizar patrones, tendencias y fluctuaciones en la variable a lo largo de diferentes puntos temporales.

En el análisis de las series temporales, se identifican cuatro componentes: tendencia, estacionalidad, ciclos y residuos, estas contribuyen a comprender la variabilidad presente en los datos a lo largo del tiempo (Gallego-Nicasio, et. al, 2018).

Tendencia: en el análisis de las series temporales, Murillo et al. (2003) definen una serie de tiempo con tendencia como aquella que exhibe un componente de largo plazo que refleja el crecimiento o la declinación de la serie a lo largo de un periodo. Este concepto es fundamental para comprender cómo ciertos fenómenos evolucionan con el tiempo. Además, señalan que esta tendencia se origina como resultado de una interacción compleja de factores económicos, demográficos o ambientales que ejercen un impacto continuo y sostenido a lo largo de tiempo.

Estacional: la estacionalidad en las series de tiempo se refiere a un patrón de cambio que ocurren cada año. Se considera estacional cuando exhibe comportamientos que se repiten constantemente anualmente. Este fenómeno se vuelve relevante en el análisis de pronósticos de datos, ya que la estacionalidad es uno de los patrones estadísticos más ampliamente empleados para la predicción (Murillos et al, 2003; Diebold, 2001; Melo y Santana; 2016).

Ciclo: el efecto cíclico se caracteriza por la variación en forma de onda que se produce en torno a la tendencia general. Estos patrones cíclicos tienden a repetirse cada dos, tres o más años, lo que implica una periodicidad en los cambios observados. Los procesos se desarrollan en plazos más prolongados dentro del período de observación (Murillos et. al, 2003; Páez et. al, 2016).

Irregular: el componente irregular emerge como el factor residual, es decir, lo que queda después de considerar las tendencias y patrones esperados en los datos. Representan las fluctuaciones impredecibles que no pueden ser explicadas por las tendencias y relaciones habituales en la serie temporal (Murillos et. al, 2003; Páez et. al, 2016).

Por otro lado, Arellano (2001), citado por Sánchez et al. (2014), destaca que los modelos de series temporales permiten describir y predecir el comportamiento de fenómenos que muestran dependencia entre las observaciones sucesivas. Esta dependencia es esencial para comprender cómo un fenómeno evoluciona con el tiempo y cómo influyen diferentes factores en su comportamiento.

Existen distintos tipos de modelos estadísticos de las series de tiempo. “Sin embargo, se destaca el modelo ARIMA por su simplicidad y practicidad en la modelación y pronóstico” (Amaris et. al, 2017, p. 90). La modelación ARIMA (Autorregresive Integrated Moving Average) fue desarrollada por George Box y Gwilym Jenkins en la década de los setenta del siglo pasado y constituyó una revolución en el análisis de modelos dinámicos y para los datos de series temporales (Sánchez et. al, 2013; Enders, 2008).

Modelo ARIMA

El ARIMA se le conoce con el nombre genérico de método “Autorregresivo integrado de medias móviles”, que deriva de sus tres componentes: AR (autorregresivo), I (integrado) y MA (Medias Móviles) (Gallego-Nicasio., et. al, 2018, p. 224). Los procesos ARIMA se aplican a series estacionarias; es decir, a series de tiempo con media y varianza constante (Box y Jenkins, 1976). Sin embargo, el modelo ARIMA (p, d, q) se caracteriza por ser inicialmente no estacionarios, muchas series de tiempo no son estacionarias, por ejemplo, el Producto Nacional Bruto o la Producción Industrial. Para describir las observaciones debe ser diferenciadas d veces para eliminar las posibles fuentes de no estabilidad. (Rios, 2008; Ramírez et. al, 2021; Gallego-Nicasio, et. al, 2018).

Los modelos ARIMA son altamente precisos y destacados para la predicción en la actualidad, particularmente adecuados para series de tiempo de periodicidad cortas. Estas destacan porque se utilizan un número reducido como mínimo 50 datos para que el modelo sea confiable (Cedeño y Carpio, 2022; Box et. al, 2015, como se citó Rojas et. al, 2022).

En una competencia para pronosticar con el mejor modelo, los enfoques econométricos para el pronóstico se enfatizan cuando se utilizan datos anuales, mientras que los modelos de series temporales suelen mostrar ventaja para frecuencias más altas por ejemplos los datos mensuales (Kumar y Sharma, 2016, p. 108).

Por otro lado, Rosales (2022) destaca que los modelos ARIMA son favorecidos por su flexibilidad para diversos tipos de datos de series de tiempo y su precisión en la predicción. Esta precisión es fundamental para reducir la incertidumbre, como señalan Melo y Santana (2016), cuyo objetivo básico en el pronóstico es reducir el rango de incertidumbre en las decisiones que afectan el futuro de un negocio.

Los modelos Autorregresivos Integrados y de Medias Móviles (ARIMA) pueden ser vistos como una generalización de los modelos ARMA (Autorregresivos y de Medias Móviles)

(Ayala y Pacheco, 2020, p. 336). Sin embargo, el modelo ARIMA son para no estacionarias y el modelo ARMA son para series estacionarias (Gilbert, 2005).

Considerando el comportamiento temporal de la variable del modelo, su análisis se ve influido por mediciones previas de esa misma variable. Estas mediciones anteriores se incorporan al modelo mediante componentes autorregresivos (AR), así como por efectos aleatorios o perturbaciones, tantos pasados como recientes, que se reflejan en los términos de medias móviles (MA).

Para poder realizar adecuadamente el análisis de los modelos ARIMA es primordial tener fundamentos teóricos de la metodología. El diseño y ajuste de un modelo ARIMA se realiza en tres etapas sucesivas: la identificación, la estimación y la revisión diagnóstica (Box y Jenkins, 1976). Adicionalmente, contar con un software especializado resulta esencial para la ejecución de ciertos cálculos requeridos.

Proceso autorregresivo AR(p)

En términos matemáticos, un modelo autorregresivo (AR) calcula el valor de la variable y en el instante t. “Donde a y b son constantes propias de cada serie de tiempo y ϵ_t es el ruido blanco” (Páez et. al, 2016, p. 82). Cuando solamente los últimos p valores pasados de la serie afectan significativamente el valor presente, el modelo se denomina autorregresivo de orden p, AR (p) (Box et Jenkins, 1976; Guzman, 2003).

$$y_t = a + by_{t-1} + \epsilon_t$$

Proceso de medias móviles MA(q)

En el proceso de medias móviles, según lo señalado por Páez et al. (2016, p. 82), no solo se incluye un término que resume los ruidos de toda la serie (ϵ_t), sino que también se agrega el ruido correspondiente a cada observación (y_i) en el modelo. Este proceso es crucial en el análisis de series temporales ya que permite al modelo poder capturar de manera más precisa las fluctuaciones presentes en los datos.

$$y = a + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q}$$

2. Métodos

Especificación de diseño metodológico

La presente investigación adopta un enfoque cuantitativo, donde se emplea la recolección de datos como base fundamental para la comprobación de hipótesis. Esta metodología, descrita por Sampieri (2014, p. 4), se fundamenta en la medición numérica y el análisis estadístico, lo que proporciona un marco sólido para establecer pautas de comportamiento y poner a

prueba teorías. Además, es útil en campos como la ciencia, la economía, la psicología y la salud, donde es fundamental recopilar y analizar datos de manera rigurosa para comprender fenómenos complejos e identificar patrones y tendencias.

En esta investigación se sigue un diseño no experimental, siguiendo la metodología descrita por Sampieri (2014, p. 152). Esto implica que no se manipulan deliberadamente variables, sino que se observan los fenómenos en su ambiente natural para analizarlos.

Dentro del marco de este diseño, se adopta un enfoque descriptivo. Esto significa que el objetivo principal es especificar propiedades y características importantes en el estudio de la producción de petróleo. En la cual se busca describir en detalle cómo ha evolucionado la producción en el pasado, qué factores han influido en su variabilidad y cuáles podrían impactarla en el futuro.

Población y Muestra

Los datos que se presentó en esta investigación son datos del reporte del sector petrolero de las empresas públicas del país en el Banco Central del Ecuador que data del enero del año 2007 a octubre del año 2022, con un total de 190 observaciones que se utilizó para realizar el pronóstico.

Especificación de Recolección de datos

Tabla 1. *Matriz de operacionalización*

| Variable | Definición conceptual | Dimensiones | Indicadores | Ítem | Fuente del Ítem |
|-----------------|---|----------------------|------------------------|--|------------------------|
| Petróleo | La producción petrolera es la actividad de la industria que se encarga de las operaciones empleadas para traer a la superficie los hidrocarburos naturales, utilizando la energía natural del yacimiento (Galván et. al, 2007). | Barriles de petróleo | Producción de petróleo | ¿Cuánto es la producción de petróleo para los siguientes 10 meses? | (BCE, 2022) |

Fuente. Elaboración propia.

Resultados

Especificación de Análisis de Datos

El modelo estadístico utilizado para realizar el pronóstico se seleccionó tras llevar a cabo un exhaustivo análisis de la revisión literaria de las series temporales. Basándonos en los datos presentados y en la revisión bibliográfica realizada, se concluyó que la serie temporal en cuestión se ajusta a un modelo univariado.

Por lo tanto, se procedió a emplear el modelo ARIMA, dando a lugar a la siguiente expresión matemática:

$$X_t = \alpha + \rho_1 X_{t-1} + \dots + \rho_p X_{t-p} + \varepsilon_t + \varphi_1 \varepsilon_{t-1} + \dots + \varphi_q \varepsilon_{t-q}$$

La importancia del modelo ARIMA radica en su capacidad para trabajar con series de tiempo estacionarias. Si una serie de tiempo no es estacionaria, se puede convertir en estacionaria mediante la diferenciación, lo que facilita la aplicación de este modelo.

Para determinar si una serie es estacionaria, éstas tienen que pasar por la prueba de Dickey-Fuller que concluye con las siguientes hipótesis:

H0: La serie no es estacionaria $> .05$

H1: La serie es estacionaria $< .05$

Después de esto, se llevó a cabo el análisis de correlación y autocorrelación parcial, cuya finalidad es determinar el número de términos autorregresivos y de medias móviles que se emplearán en el modelo.

Para evaluar la calidad del modelo, se realizó la prueba del error estandarizados, y posteriormente se aplicó la prueba de Ljung – Box, que sirve para saber si existe o no los ruidos blancos, en la cual nos da las siguientes hipótesis:

H0: Hay ruido blanco $> .05$


H1: No hay ruido blanco $< .05$

Finalmente se realizó el pronóstico de la producción de petróleo.

Modelo estadístico

La producción de petróleo, de las empresas públicas del Ecuador, está presentada en este siguiente gráfico. En el cual se observó las cantidades de barriles de petróleo que se han producido y los meses de operación.

Figura 1. Producción de petróleo de las empresas públicas del Ecuador desde el año 2007 a 2022



Fuente. Elaboración propia usando R Studio.

Además, para poder saber si la producción de petróleo de las empresas públicas del país fue una serie estacionaria se realizó la prueba de estacionalidad de Dickey-Fuller. En la cual el p-value es mayor a .05, por lo que se acepta la hipótesis nula y se rechaza la hipótesis alternativa, entonces la serie presentada no es estacionaria.

Tabla 2. Prueba de hipótesis de la estacionalidad de la serie Dickey-Fuller

Producción de petróleo

Dickey-Fuller: -1.9278

Lag order: 5

p-value: 0.6064

Fuente. Elaboración propia

Por otro lado, para que una serie fuera estacionaria, se transformó mediante el método de diferenciación. Posteriormente, se procedió a realizar nuevamente la prueba de estacionalidad de Dickey-Fuller. En esta instancia, se observa un valor de p inferior a 0.05, por lo tanto, se acepta la hipótesis alternativa y se rechaza la hipótesis nula. En consecuencia, se clasifica la serie como estacionaria.

Tabla 3. Prueba de hipótesis de la estacionalidad de la serie Dickey-Fuller

Producción de petróleo

Dickey-Fuller: -8.7637


Lag order: 5

p-value: 0.01

Fuente. Elaboración propia

Tras aplicar el método de diferenciación y la prueba de estacionalidad de Dickey Fuller, el resultado se representó de la siguiente manera:

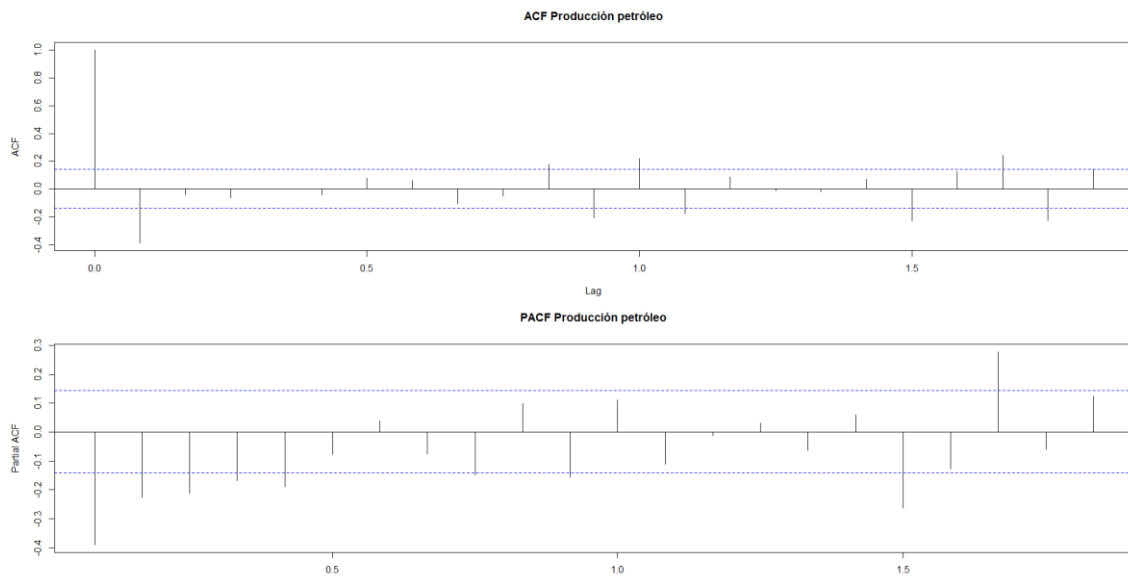
Figura 2. Producción de petróleo de las empresas públicas del Ecuador desde el año 2007 a 2022 después de haber realizado el método de diferenciación.



Fuente. Elaboración propia usando R Studio.

Las funciones del ACF y PACF son importante para determinar el tipo de modelo ARIMA a emplear. “La función ACF es usada para identificar el proceso de media móvil (MA) en un modelo ARIMA; mientras que la función PACF es usada para identificar los valores de la parte del proceso autorregresivo (AR)” (Finanzas Zone, 2018).

Figura 3. ACF Y PACF de la producción de petróleo



Fuente. Elaboración propia usando R Studio.

Asimismo, para que un modelo ARIMA fuera óptimo y eficiente se utilizó el criterio de información de Aikake (AIC), que permitió la estimación de los diferentes valores de (p, d, q) para encontrar el modelo adecuado (Ramírez et. al, 2021).

Según los resultados obtenidos mediante la función Auto.Arima en R Studio, la cual permite identificar automáticamente el modelo ARIMA óptimo para la serie de tiempo, se determinó que el modelo óptimo para la serie de producción de petróleo es ARIMA (0,1,2) (0,1,1). Por consiguiente, se empleó este modelo para pronosticar la producción de petróleo.


Tabla 4 Resultado ARIMA para la producción de petróleo

| Coeficientes | |
|------------------|---------------------------|
| ma1 | ma2 |
| -0.6183 | -0.1290 |
| 0.0695 | 0.0672 |
| sigma^2 = 874322 | log likelihood = -1560.08 |
| AIC=3128.15 | BIC=3141.12 |

Fuente. Elaboración propia usando R Studio.

En esta prueba de Ljung-Box se observó que los puntos se sitúan delante de la línea azul que es el valor p 0.05 la cual significa que es mayor. Por lo tanto, se aceptó la hipótesis nula y se rechaza la alternativa, por lo que si hay ruido blanco en el modelo y el modelo ARIMA se ajustó bien.

Figura 4. Box-Ljung Test



Fuente. Elaboración propia usando R Studio.


Tabla 5 Resultado de la prueba Box-Ljung

| Box-Ljung Test | |
|------------------------|--------|
| X-squared = 0.00072661 | df = 1 |
| P value = 0.9785 | |

Fuente. Elaboración propia usando R studio

Para finalizar, se realizó un pronóstico de la producción de petróleo para los siguientes 10 meses.

Figura 5. Pronóstico de producción de petróleo para los siguientes 10 meses



Fuente. Elaboración propia usando R Studio.

Discusión

Los resultados obtenidos con la aplicación del modelo estadístico ARIMA permitieron analizar la situación de la producción de petróleo en Ecuador durante el período de enero de 2007 a octubre 2022. Se observó que la producción de petróleo experimentará una ligera disminución en los siguientes 10 meses.

Para esta investigación se utilizó el modelo de la serie ARIMA (0,1,2) (0,0,1). En la cual, nos demostró ser el modelo adecuado para el pronóstico de la producción del petróleo según el criterio de información de Aikake (AIC).

Los resultados y metodologías del estudio pueden ser aplicables y adaptados a otros contextos similares en países con industrias petroleras comparables. Esto amplía la utilidad y relevancia del modelo ARIMA en la predicción de la producción de petróleo.

La aplicación del modelo ARIMA expone que este modelo estadístico se puede utilizar para todo tipo de producción de cualquier sector del país, así también lo expresa Sánchez et al., (2013) “la aplicación de esta metodología puede ser también aprovechada por las organizaciones de productores” (p. 323).

Conclusión

La producción del petróleo para el Ecuador es una de las fuentes más importante de ingresos económicos para el país. Por ende, existe una relación de dependencia del sector petrolero con la economía ecuatoriana, lo cual conlleva a considerar de manera crucial como un sector fundamental que tiene que ser tratado constantemente para los estudios a futuro.

La aplicación del modelo estadístico ARIMA mediante un modelo eficiente y óptimo, permitió analizar el pronóstico de la producción de petróleo a corto plazo. Es de vital importancia que estos modelos tengan un patrón estacionario, ya que esto ayuda a presentar resultados adecuados. Adicionalmente, la aplicación de este modelo es bastante útil para las empresas públicas del sector petrolero para darle un breve análisis a la situación futura de las producciones de petróleo para realizar adecuadamente las tomas de decisiones.

La aplicación de series temporales en el sector petrolero es esencial para poder realizar predicciones precisas y tomar decisiones fundamentadas en un escenario que no siempre es lineal o constante, ya que estas pueden detectar anomalías o patrones atípicos en los datos, como alzas o caídas de la producción de petróleo en determinado período. Estas técnicas permiten identificar problemas u oportunidades, permitiéndoles prever y diseñar estrategias de ajuste frente a las oscilaciones que se presentan con el transcurso del tiempo.

3. Referencias bibliográficas

- Botero Botero, S., & Cano Cano, J. A. (2008). Análisis de series de tiempo para la predicción de los precios de la energía en la bolsa de Colombia. *Cuadernos de Economía*, 174-208.
- Box, G. E. (1976). *Time series analysis: Forecasting and control*. Okland.
- Box, J. G., GC, R., & GM, L. (2015). *Time Series Analysis: Forecasting and Control*. Hoboken.
- Casimiro. (2016). Analisis de Series Temporales: Modelos ARIMA. *Vasco: Enpresal-Zientzien*.
- Cesar A. Hernandez, L. F. (2008). Aplicaciones de las series de tiempo en modelos de tráfico para una red de datos. *Scientia et Technica*.
- Diebold, F. (2001). *Element of forecasting*. Australia: South Western College Publishing.
- Erik Giovany Montes Páez, F. E. (2016). Aplicación de series de tiempo en la realización de pronósticos de producción. *Revista Fuentes: El Reventón Energético*, 79-88.
- Finanzas Zone*. (23 de Marzo de 2018). Obtenido de Finanzas Zone: [https://finanzaszone.com/analisis-y-prediccion-de-series-temporales-con-r-iii-autocorrelacion/#:~:text=La%20funci%C3%B3n%20ACF%20es%20usada,del%20proceso%20autoregresivo%20\(AR\)](https://finanzaszone.com/analisis-y-prediccion-de-series-temporales-con-r-iii-autocorrelacion/#:~:text=La%20funci%C3%B3n%20ACF%20es%20usada,del%20proceso%20autoregresivo%20(AR).).

- Francisco Cedeño Troya, F. C. (2022). Modelos predictivos de sistemas de información en la gestión de abastecimientos de sector ferretero. *Revista Ciencia y Tecnología*, 27-38.
- Gallego-Nicasio Moraleda JA., R. A. (2018). Modelos ARIMA para la predicción del gasto conjunto de oxígeno de vuelo y otros gases en el Ejército del Aire. *Sanidad mil*, 223-229.
- Galván Rico, L. R. (2007). Los macroprocesos de la industria petrolera y sus consecuencias ambientales. *Universidad, Ciencia y Tecnología*, 91-97.
- Gilbert, K. (2005). An ARIMA Supply Chain Model. *Management Science*, 305-310.
- GitHub. (2020). *GitHub*. Obtenido de [https://github.com/FrancisArgnR/SeriesTemporalesEnCastellano#arima-\(autoregressive-integrated-moving-average\)](https://github.com/FrancisArgnR/SeriesTemporalesEnCastellano#arima-(autoregressive-integrated-moving-average))
- Gloria Amaris, H. Á. (2017). Aplicación de modelo ARIMA para el análisis de series de volúmenes anuales en el río Magdalena. *Revista Tecnura*, 88-101.
- Guerrero Guzman, V. M. (2003). *Análisis de series de tiempo económicas*. México: Editorial Thomson.
- Joaquín Murrillos, A. T. (2003). Estudio del pronóstico de la demanda de energía eléctrica, utilizando modelos de series de tiempo. *Scientia et Technica*.
- Juan Pablo Mateo, S. G. (2014). El sector petrolero en Ecuador. *Revista Problema del Desarrollo*, 113-139.
- M, A. (2001). *Introducción al análisis clásicos de series de tiempo*.
- Malpartida, J. Y. (2022). Predicción de la contaminación atmosférica generada por las emisiones del CO₂ en el Perú utilizando los métodos ARIMA y Redes Neuronales. *TecnoHumanismo*, 114-125.
- Manoj Kumar, S. S. (2016). Forecasting tourist in-flow in South East Asia: A case of Singapore. *Tourism and Management Studies*, 107-119.
- Melo-Morín, J. (2016). Minado de series de tiempo utilizando la metodología ARIMA. *Revista de Investigación y Desarrollo*, 21-31.
- Minchón Medina, C. A., & Vizconde Osorio, T. A. (2011). Modelo SARIMA para la llegada mensual de visitantes extranjeros por el Aeropuerto Internacional "Jorge Chávez". *Scientia*.
- Muñoz-Santiago, A., Urquijo-Vanstrahlengs, J., Castro-Otero, A., & Lombana, J. (2017). Pronóstico del precio de la energía en Colombia utilizando modelos ARIMA con IGARCH. *Revista de Economía del Rosario*, 127-161.

- Olver Hernández N., J. D. (2005). Modelos ARIMA y estructural de la serie de precios promedio de los contratos en el Mercado Mayorista de Energía Eléctrica en Colombia. *Revista del Institute de Energía, Facultad de Minas*, 5-10.
- Orozco, M. (23 de Diciembre de 2021). *Primicias*. Obtenido de Primicias: <https://www.primicias.ec/noticias/economia/produccion-petrolera-volvera-nivel-normal-febrero-ecuador/>
- Orozco, M. (4 de Marzo de 2022). *Primicias*. Obtenido de Primicias: <https://www.primicias.ec/noticias/economia/produccion-petroleo-petroecuador-ecuador/#:~:text=Pese%20a%20que%20las%20metas,y%20Recursos%20Naturales%20No%20Renovables.>
- Ramírez Castañeda, L. N., Cristancho Cruz, S. L., & José-Alejandro, C.-L. (2021). Modelos de fluctuaciones de precios agrícolas: Estudio comparativo de frutas tropicales frescas en Colombia. *Revista de Ciencias Sociales*, 197-212.
- Rey Francisco Ayala Castrejón, C. B. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. *Revista Mexicana de Economía y Finanzas Nueva Época*, 331-354.
- Ríos, G. (2008). *Series de Tiempo*. Obtenido de https://www.u-cursos.cl/ingenieria/2010/1/CC52A/1/material_docente/bajar?id_material=296003
- Roberto Hernández Sampieri, C. F. (2014). *Metodología de la investigación*. México D.F.: McGraw Hill Education.
- Samuel Luis-Rojas, R. C. (2022). Modelo de intervención y pronóstico de precios pagados al producto de la miel de abeja (*Apis mellifera* L.) en México. *Agrociencia*, 638-668.
- Sánchez, L., Cabanas, G., Abad, Y., & Torres, V. (2014). Utilización de modelos ARIMA para la predicción de la producción de leche. Estudio de caso en la UBPC "Maniabo", Las Tunas. *Revista Cubana de Ciencia Agrícola*, 213-218.
- Susan Elsa Cancino, G. O. (2022). Un Modelo Box Jenkins ARIMA para modelar y pronosticar la producción de mora de castilla en Colombia. *Económicas CUC*.
- Víctor Solórzano Méndez, C. S. (2016). El petróleo en el Ecuador: Un Análisis del costo de agotamiento, aplicación del modelo Hotelling. *Revista Científica y Tecnológica UPSE*, 48-58.
- Vogelvang. (2005). *Theory and application with Eviews*. Pearson Education Limited.
- Box, G., Jenkins, G. (1976). *Time Series Analysis: Forecasting and Control*. Okland, California, USA.

Apéndice

Datos de la producción de petróleo de las empresas públicas del Ecuador

| | | | | |
|-----------------|----------------|----------------|----------------|----------------|
| BARRILES | 805.329.048 | 774.417.343 | 10.814.678 | 1.172.207.116 |
| 810.272.652 | 8.268.730.953 | 879.249.907 | 11.212.822 | 1.237.706.412 |
| 712.295.161 | 801.505.888 | 854.529.276 | 1.123.385.418 | 1.266.566.743 |
| 784.845.762 | 830.221.997 | 870.602.581 | 1.049.391.598 | 1.226.161.858 |
| 752.841.559 | 828.439.788 | 859.157.588 | 1.110.013.581 | 1.279.308.344 |
| 780.470.895 | 878.310.264 | 889.560.111 | 10.789.083.729 | 1.255.493.366 |
| 765.658.191 | 881.699.898 | 972.871.515 | 1.109.448.201 | 1.309.507.272 |
| 788.008.556 | 787.462.772 | 955.071.938 | 1.089.377.756 | 1.320.858.058 |
| 804.148.859 | 8.667.361 | 1.012.467.788 | 1.151.644.513 | 1.195.017.587 |
| 786.403.186 | 8.474.290.958 | 10.033.555.009 | 11.587.123.528 | 1.342.472.837 |
| 813.583.535 | 883.980.269 | 1.075.214.545 | 1.111.984.349 | 1.311.369.961 |
| 789.389.755 | 865.065.608 | 1.100.172.041 | 1.140.776.861 | 1.334.916.548 |
| 845.525.652 | 876.464.699 | 1.109.172.386 | 1.106.673.293 | 12.960.885.581 |
| 824.236.428 | 868.302.001 | 1.075.062.346 | 1.135.291.918 | 1.350.974.878 |
| 773.092.767 | 840.114.496 | 1.107.756.936 | 1.159.008.408 | 1.347.632.298 |
| 821.169.705 | 86.148.168 | 1.068.181.526 | 106.111.494 | 1.287.235.412 |
| 785.261.202 | 838.872.124 | 1.107.711.157 | 1.164.694.682 | 1.346.888.344 |
| 80.395.875 | 859.179.627 | 1.058.294.583 | 1.151.594.074 | 1.312.356.925 |
| 778.715.508 | 847.904.142 | 1.109.475.844 | 1.208.780.466 | 1.352.240.381 |
| 1.352.941.543 | 1.269.133.728 | 1.144.238.989 | | |
| 1.294.468.275 | 1.165.204.719 | 1.170.500.961 | | |
| 1.326.710.131 | 1.291.831.826 | 1.142.977.129 | | |
| 13.357.514.731 | 1.248.838.361 | 588.281.877 | | |
| 1.326.268.707 | 1.294.972.445 | 1.100.706.332 | | |
| 1.358.210.061 | 1.249.116.925 | 1.042.360.187 | | |
| 1.292.156.768 | 13.241.712.609 | 120.178.419 | | |
| 1.337.305.277 | 13.571.756.723 | 1.161.294.316 | | |
| 1.323.903.215 | 13.030.017.076 | 1.199.140.175 | | |

| | | | | |
|----------------|----------------|---------------|--|--|
| 1.189.374.276 | 11.579.630.626 | 953.763.337 | | |
| 1.300.573.538 | 12.987.250.759 | 1.160.881.579 | | |
| 1.249.970.545 | 13.256.690.256 | 1.194.660.139 | | |
| 1.306.642.849 | 1.308.105.586 | 1.148.101.814 | | |
| 1.270.515.821 | 1.228.725.293 | 1.196.624.184 | | |
| 1.310.045.255 | 1.329.767.843 | 1.337.073.996 | | |
| 1.299.356.163 | 477.609.026 | 1.188.307.314 | | |
| 1.241.065.836 | 808.034.942 | | | |
| 1.267.074.208 | 1.247.712.513 | | | |
| 1.206.814.855 | 1.295.366.878 | | | |
| 1.243.874.973 | 1.280.740.146 | | | |
| 1.222.642.059 | 1.228.543.016 | | | |
| 1.104.669.174 | 1.264.630.834 | | | |
| 1.229.039.894 | 1.223.861.533 | | | |
| 1.200.816.474 | 127.199.198 | | | |
| 1.236.501.808 | 1.262.339.984 | | | |
| 11.967.882.927 | 1.114.176.305 | | | |
| 1.258.797.129 | 1.231.210.591 | | | |
| 1.280.463.149 | 1.179.644.387 | | | |
| 1.207.814.845 | 1.219.950.295 | | | |
| 1.235.595.502 | 1.168.830.985 | | | |
| 120.267.976 | 1.197.942.466 | | | |
| 1.259.529.729 | 11.797.999.417 | | | |

Fuente: elaboración propia