

# Modelo matemático para la predicción de consumo y generación de energía eléctrica por medio de grupos electrógenos que utilizan petróleo y diésel de la empresa Petroecuador

## Mathematical models for the prediction of consumption and generation of electrical energy through generator sets that use oil and diesel from the Petroecuador company

Paco Jovanni Vásquez Carrera<sup>1</sup> , Guillermo Edvin Machado Sotomayor<sup>1</sup> 

<sup>1</sup>Universidad Nacional de Chimborazo, Riobamba – Ecuador

Correo de correspondencia: paco.vasquez@unach.edu.ec, gmachado@unach.edu.ec

### Información del artículo

**Tipo de artículo:**  
Artículo original

**Recibido:**  
18/07/2024

**Aceptado:**  
11/09/2024

**Publicado:**  
05/10/2024

**Revista:**  
DATEH

OPEN ACCESS



### Resumen

Este estudio desarrolla un modelo matemático para predecir el consumo y la generación de energía eléctrica en los grupos electrógenos de Petroecuador que utilizan petróleo y diésel. Mediante la implementación de técnicas de aprendizaje automático, específicamente árboles de decisión y modelos ARIMA, se logró capturar las relaciones entre el consumo de combustibles y la producción de energía. El análisis de datos históricos reveló una fuerte relación lineal entre el consumo de crudo y la generación de potencia, mientras que el diésel mostró una relación no lineal y más débil. El modelo alcanzó un coeficiente de determinación de 0.97 en la validación con datos reales, demostrando una capacidad predictiva excepcional. Esta precisión se logró utilizando datos diarios detallados, subrayando la importancia de mantener registros frecuentes y minuciosos. El modelo desarrollado no solo permite predicciones precisas, sino que también ofrece una herramienta versátil para la planificación estratégica, la optimización de inventarios, la programación de mantenimiento y la mejora de la eficiencia energética global de Petroecuador. Este estudio establece una base sólida para futuras investigaciones en el campo de la predicción energética y la gestión eficiente de recursos en la industria petrolera y energética.

**Palabras clave:** predicción energética, aprendizaje automático, grupos electrógenos, eficiencia energética, Petroecuador

### Abstract

This study develops a mathematical model to predict electricity consumption and generation in Petroecuador's generator sets using oil and diesel. By implementing advanced machine learning techniques, specifically decision trees and ARIMA models, it was possible to capture the complex relationships between fuel consumption and energy production. Analysis of historical data revealed a strong linear relationship between crude oil consumption and power generation, while diesel showed a non-linear and weaker relationship. The model achieved a determination coefficient of 0.97 in validation with real data, demonstrating exceptional predictive capability. This precision was achieved using detailed daily data, underlining the importance of maintaining frequent and thorough records. The developed model not only allows accurate predictions but also offers a versatile tool for strategic planning, inventory optimization, maintenance scheduling, and improving Petroecuador's overall energy efficiency. This study establishes a solid foundation for future research in the field of energy prediction and efficient resource management in the oil and energy industry.

**Keywords:** energy prediction, machine learning, generator sets, energy efficiency, Petroecuador

**Forma sugerida de citar (APA):** López-Rodríguez, C. E., Sotelo-Muñoz, J. K., Muñoz-Venegas, I. J. y López-Aguas, N. F. (2024). Análisis de la multidimensionalidad del brand equity para el sector bancario: un estudio en la generación Z. Retos Revista de Ciencias de la Administración y Economía, 14(27), 9-20. <https://doi.org/10.17163/ret.n27.2024.01>.

### INTRODUCCIÓN

La predicción del consumo y generación de energía eléctrica se ha convertido en un tema de vital importancia en la actualidad, impulsado por el crecimiento constante de la demanda energética global y la necesidad imperante de optimizar los recursos disponibles para satisfacerla de

manera eficiente y sostenible (Sujesh & Ramesh, 2018). Para empresas como Petroecuador, que utilizan grupos electrógenos alimentados por petróleo y diésel en la generación de electricidad, contar con modelos matemáticos precisos y confiables que permitan predecir el consumo y la generación de energía es fundamental para

la toma de decisiones estratégicas y la planificación a corto, mediano y largo plazo (Veza et al., 2022).

En las últimas décadas, los modelos matemáticos aplicados a la predicción energética han experimentado un notable desarrollo, impulsado por los avances en técnicas de inteligencia artificial y aprendizaje automático (Zhang et al., 2022). Estos modelos permiten considerar una amplia gama de variables y factores que influyen en el consumo y la generación de electricidad, como las condiciones climáticas, el precio de los combustibles, la eficiencia de los equipos, la demanda histórica y las proyecciones de crecimiento económico y poblacional (van Ruijven et al., 2019).

La disponibilidad de datos históricos del consumo de diésel y petróleo para el funcionamiento de los generadores en Petroecuador brinda una oportunidad única para desarrollar modelos matemáticos más precisos y adaptados a las condiciones específicas de la empresa (Markiewicz & Muślewski, 2020). La capacidad de estos modelos para procesar grandes volúmenes de datos y detectar patrones complejos los convierte en herramientas valiosas para la predicción energética (Shih et al., 2019).

La aplicación de modelos matemáticos en la industria petrolera ha demostrado ser efectiva para optimizar la producción, el transporte y el uso de recursos energéticos (Krasnyuk et al., 2022). En el caso de Petroecuador, la implementación de estos modelos puede contribuir a mejorar la eficiencia energética de los grupos electrógenos, reducir los costos operativos asociados al consumo de combustibles y minimizar el impacto ambiental derivado de la generación de electricidad a partir de fuentes fósiles (Chen et al., 2024).

La predicción precisa del consumo y la generación de energía permite a la empresa anticiparse a posibles escenarios de escasez o exceso de oferta, y tomar medidas preventivas para garantizar la continuidad del suministro eléctrico (Dźwigoł et al., 2019). Además, la incorporación de datos históricos del consumo de diésel y petróleo en los modelos matemáticos puede ayudar a identificar patrones estacionales, tendencias a largo plazo y anomalías en el funcionamiento de los generadores, lo que permite optimizar las estrategias de mantenimiento y reemplazo de equipos (Khairi et al., 2021).

De igual manera, se discute la aplicabilidad de estos modelos en el contexto específico de Petroecuador, teniendo en cuenta las características técnicas de sus grupos electrógenos, la disponibilidad de datos históricos y las condiciones operativas particulares. En particular, se enfoca en el proceso de generación eléctrica mediante un generador Wartsila, utilizando datos estadísticos anuales

(2019-2023) de variables principales como el consumo de combustibles (diésel y crudo en barriles), potencia (MW) y energía (MWh) generadas, indicadores clave de desempeño (KPIs), tasa de calor (btu/kWh), eficiencia térmica, factor de capacidad, confiabilidad y disponibilidad.

Para establecer las relaciones funcionales entre las entradas y salidas del sistema, se desarrolla un modelo descriptivo de regresión multivariada (Keith, 2019). Se emplean métodos numéricos de validación estadística para garantizar la precisión del modelo e identificar los óptimos de operación en términos de minimización del consumo energético y emisiones contaminantes (Gao et al., 2019).

Este enfoque permite obtener una comprensión detallada del rendimiento del generador Wartsila y proporciona una base sólida para la toma de decisiones informadas sobre la optimización de su funcionamiento (Yusif Mahmoud Ahmed, 2023).

La incorporación de datos históricos de cinco años (2019-2023) en el análisis permite determinar patrones, variaciones estacionales y posibles anomalías en el desempeño del generador. Además, la consideración de múltiples variables, como el consumo de combustibles, la potencia y energía generadas, y los indicadores de desempeño, proporciona una visión integral del sistema y permite identificar las relaciones más significativas entre estos factores.

El uso de modelos numéricos y de validación estadística garantiza la robustez y confiabilidad de los modelos desarrollados. Esto es especialmente importante en el contexto de Petroecuador, donde la precisión de las predicciones y la identificación de los óptimos de operación son fundamentales para la toma de decisiones estratégicas y la planificación a largo plazo.

En el campo de la predicción energética, diversos investigadores han desarrollado nuevos modelos utilizando técnicas de aprendizaje automático. Pachauri & Ahn (2022) propusieron un modelo para predecir la generación eléctrica basado en el consumo de gas y vapor.

Implementaron varios algoritmos, incluyendo regresión lineal (LR), regresión de procesos gaussianos (GPR), redes neuronales perceptrón multicapa (MLP), regresión de vectores de soporte (SVR), árboles de decisión (DT) y árboles agregados por bootstrap (BBT).

Al aplicar un modelo aditivo generalizado (GAM) a estos algoritmos, lograron mejoras significativas en la raíz del error cuadrático medio (RMSE), con reducciones que

oscilaron entre el 17.3% y el 74% para los diferentes modelos.

En el ámbito del manejo energético, Khan et al. (2020) desarrollaron un modelo predictivo de consumo de electricidad basado en redes neuronales convolucionales. Su enfoque resultó en tasas de error notablemente bajas, con un RMSE del 5% y errores cuadráticos medios (MSE) y errores absolutos medios (MAE) del 4%, demostrando la eficacia de las redes neuronales en este contexto.

Pierre et al. (2023) abordaron el desafío de pronosticar los picos de consumo de energía eléctrica, importante en la planificación efectiva de la producción y distribución. Desarrollaron modelos híbridos que combinaban redes neuronales LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) con el modelo ARIMA para capturar tendencias. Sus resultados mostraron RMSE de 7.35 y 9.60 respectivamente, ilustrando el potencial de los enfoques híbridos en la predicción energética.

En la búsqueda de optimizar la venta de energía al consumidor final, Vasar et al. (2018) propusieron un estudio comparativo de modelos de redes neuronales. Implementaron redes tipo Elman y feed-forward, incorporando técnicas de preprocesamiento lineal y no lineal de datos para mejorar la precisión de las predicciones. Este enfoque destaca la importancia del tratamiento de datos en la eficacia de los modelos predictivos.

Zhang et al. (2019) enfatizaron la importancia del análisis del consumo para el ahorro energético. Su investigación comparó varios modelos, incluyendo regresión lineal, máquinas de vectores de soporte (SVM), Random Forest y XGBoost. Sus resultados indicaron que XGBoost proporcionó los mejores resultados, subrayando el potencial de los algoritmos de boosting en la predicción del consumo energético.

## MATERIALES Y MÉTODOS

Este estudio se centra en el desarrollo de un modelo matemático para predecir el consumo y la generación de energía eléctrica en los grupos electrógenos de Petroecuador que utilizan petróleo y diésel. La metodología empleada comprende varias etapas, desde la recopilación de datos hasta la implementación y validación de los modelos predictivos.

### Recopilación y Preprocesamiento de Datos

Se obtuvieron datos históricos detallados del consumo de combustibles (petróleo y diésel) y de la generación de potencia y energía eléctrica en MW y MWh, respectivamente, de los grupos electrógenos de Petroecuador. El conjunto de datos abarca un período de

cinco años, desde 2019 hasta 2023, y fue proporcionado por los registros internos de la empresa.

El preprocesamiento de los datos incluyó la limpieza para eliminar anomalías, la gestión de valores faltantes, la identificación y corrección de valores atípicos, y la estandarización de las unidades de medición para asegurar coherencia y precisión (Drouven et al., 2023). Este proceso fue vital para garantizar la calidad de los datos de entrada para los modelos predictivos.

### Herramientas de Software y Análisis de Datos

Para el análisis de datos y el desarrollo de los modelos, se utilizó el lenguaje de programación Python, aprovechando diversas bibliotecas especializadas:

- NumPy: Para operaciones con matrices y arreglos.
- Pandas: Para el manejo y análisis de los datos históricos.
- Matplotlib y Seaborn: Para la visualización y representación gráfica de los datos.
- Scikit-learn: Para el desarrollo y validación de los modelos de aprendizaje automático (García Vázquez et al., 2024).

### Desarrollo de Modelos Matemáticos

Se implementaron dos enfoques principales para el modelado predictivo:

#### Modelos de Aprendizaje Automático para Predicción

**Multivariante:** Se desarrollaron varios tipos de algoritmos para identificar el más adecuado para predecir la variable de salida (generación de potencia) en función de las variables de entrada (consumo de combustibles). Los modelos considerados incluyeron:

- Regresión Lineal y Polinómica
- Árboles de Decisión
- Random Forest
- Gradient Boosting

Los datos se dividieron en conjuntos de entrenamiento y prueba en una proporción de 80% y 20%, respectivamente, para una evaluación adecuada de los modelos (Benajes et al., 2016; Geed & Verma, 2024).

#### Modelos de Series Temporales para Predicción

**Univariante:** Para predecir las variables de entrada (consumo de combustibles) se implementaron modelos de series temporales, específicamente:

- ARIMA (AutoRegressive Integrated Moving Average)

Este modelo se ajustó iterativamente para capturar las tendencias y patrones estacionales en los datos históricos de consumo de combustibles.

### Evaluación y Validación de Modelos

La evaluación del rendimiento de los modelos de aprendizaje automático se realizó utilizando diversas métricas:

- Error Cuadrático Medio (MSE)
- Error Absoluto Medio (MAE)
- Coeficiente de Determinación ( $R^2$ )

Estas métricas proporcionaron una visión cuantitativa de la precisión de los modelos en la predicción del consumo de combustible y la generación de energía eléctrica. Además, se realizaron pruebas de robustez para asegurar que los modelos pudieran manejar diferentes condiciones operativas y variabilidad en los datos sin perder precisión significativamente (Benajes et al., 2016; Drouven et al., 2023).

Para los modelos de series temporales, la evaluación consistió en ajustar sus parámetros hasta encontrar una respuesta similar a la respuesta histórica de las variables.

### Implementación y Validación Final

Una vez desarrollados y evaluados, los modelos de series temporales se implementaron para predecir el consumo de petróleo y diésel. Estos datos predichos se utilizaron como entrada para los modelos de aprendizaje automático para predecir la generación de potencia. Se realizaron simulaciones que permitieron analizar cómo los modelos predecían en diversas situaciones, comparando los resultados con datos reales no utilizados en el entrenamiento. Este proceso de validación ayudó a ajustar y optimizar los modelos, asegurando que sus predicciones fueran lo más precisas y fiables posible (Benajes et al., 2016; Ismail et al., 2022).

La metodología descrita permitió desarrollar un modelo integral y robusto para la predicción del consumo y generación de energía eléctrica en los grupos electrógenos de Petroecuador, proporcionando una poderosa herramienta para la optimización de sus operaciones y la planificación energética.

## RESULTADOS Y DISCUSIÓN

El análisis de los datos históricos y la implementación de los modelos predictivos arrojaron resultados significativos sobre el consumo de combustibles y la generación de energía eléctrica en los grupos electrógenos de Petroecuador.

### Análisis de Relaciones entre Variables

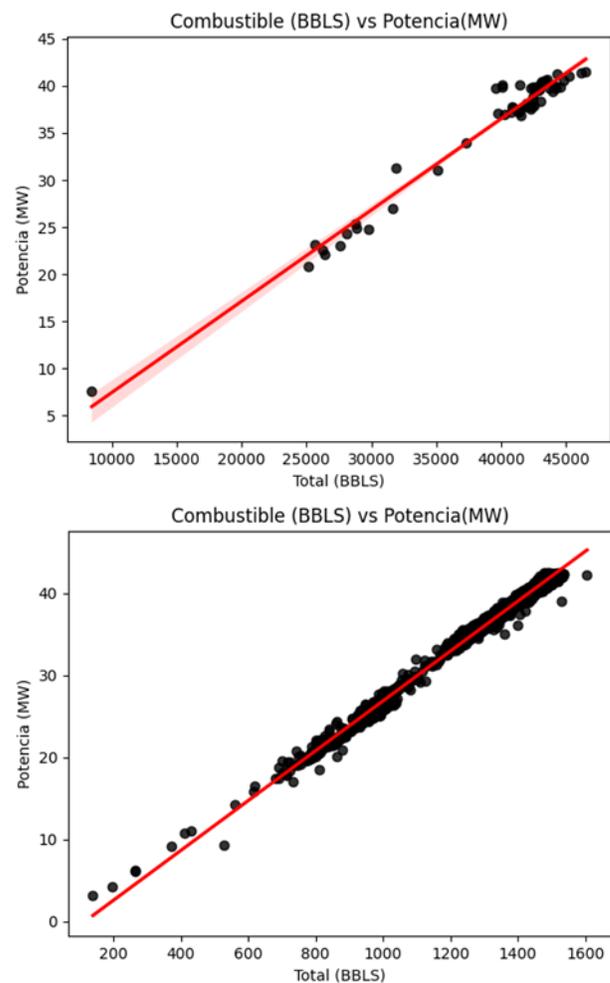
El estudio reveló una relación predominantemente lineal entre la cantidad total de combustible consumido (en barriles de petróleo equivalente) y la potencia eléctrica generada (en MW). Esta relación se observó en ambos conjuntos de datos analizados:

#### Dataset mensual (60 observaciones):

- Ecuación lineal:  $y = 0.0009683x - 2.2542$
- Coeficiente de determinación ( $R^2$ ): 0.9696

#### Dataset diario (1783 observaciones):

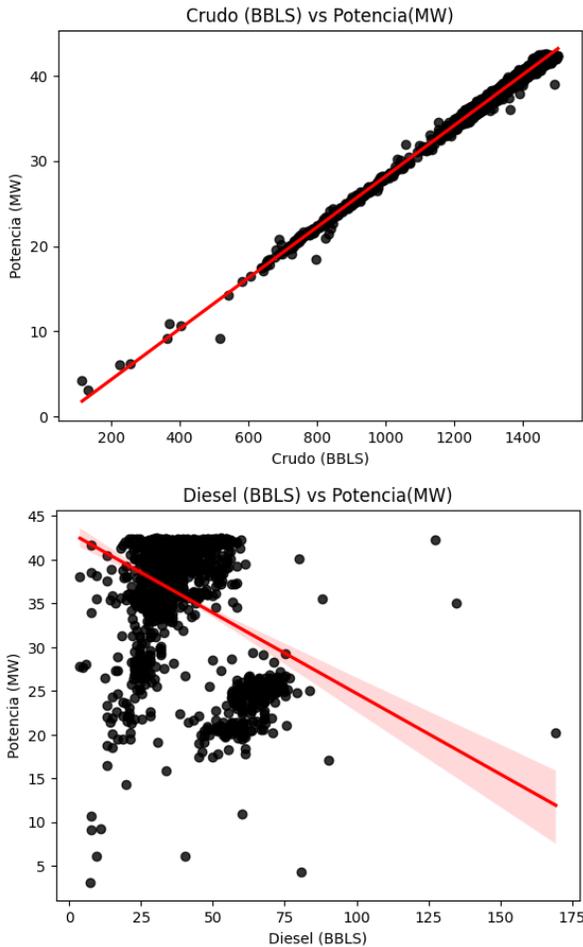
- Ecuación lineal:  $y = 0.0303792x - 3.5193$
- Coeficiente de determinación ( $R^2$ ): 0.9928



**Figura 1.** Gráfica de generación de potencia eléctrica en función del combustible consumido. (a) Datos mensuales, (b) Datos diarios.

El análisis multivariante reveló que la relación entre la potencia generada y el consumo de crudo es altamente lineal ( $R^2 = 0.9957$ ), mientras que la relación entre la

potencia y el consumo de diésel es no lineal y mucho más débil ( $R^2 = 0.1387$ ). Esto sugiere que el crudo es el principal determinante en la generación de potencia, mientras que el diésel juega un papel secundario y más variable.



**Figura 2.** Análisis multivariante de la generación de potencia eléctrica. (a) Relación potencia-crudo, (b) Relación potencia-diésel.

**Rendimiento de los Modelos Predictivos**

Se evaluaron modelos de árboles de decisión con diferentes conjuntos de datos:

**Modelo entrenado con 48 registros mensuales (2020-2023):**

- Error Cuadrático Medio (MSE): 4 MW
- Error Absoluto Medio (MAE): 1.05 MW
- Coeficiente de determinación ( $R^2$ ): 0.78

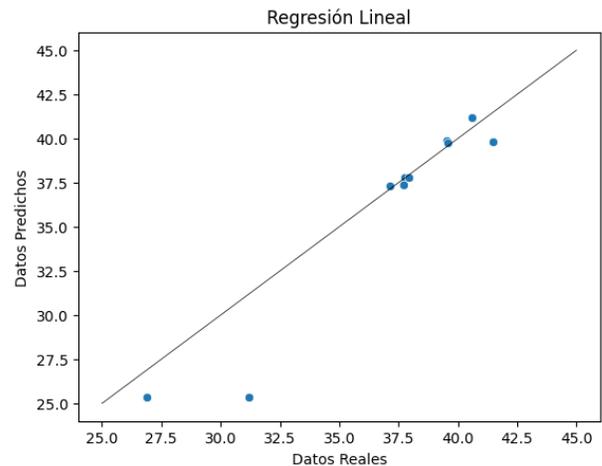
**Modelo entrenado con 60 registros mensuales (2019-2023):**

- MSE: 1.1 MW

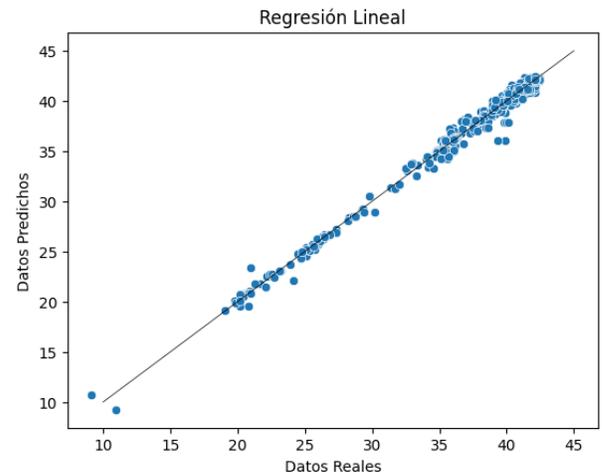
- MAE: 0.81 MW
- $R^2$ : 0.97

**Modelo entrenado con registros diarios (1783 observaciones):**

- MSE: 0.4 MW
- MAE: 0.43 MW
- $R^2$ : 0.99



**Figura 3.** Comparación de datos mensuales reales de potencia eléctrica versus datos predichos por el modelo del árbol de decisión.



**Figura 4.** Comparación de datos diarios reales de potencia eléctrica versus datos predichos por el modelo del árbol de decisión.

Estos resultados demuestran una mejora significativa en la precisión del modelo al aumentar la cantidad de datos de entrenamiento, con el modelo basado en datos diarios mostrando el mejor rendimiento.

**Predicción de Variables Independientes**

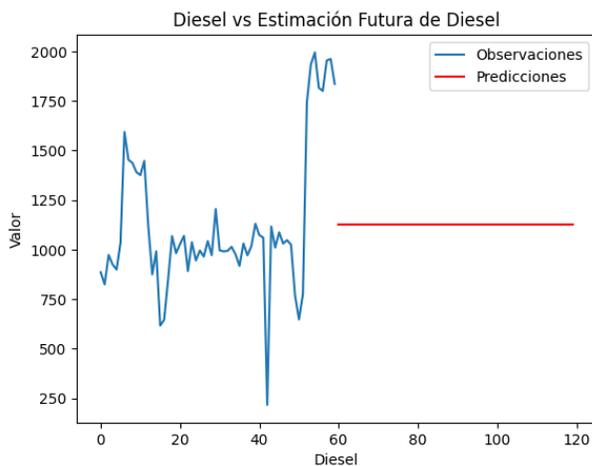
Se implementó el modelo ARIMA para predecir el consumo de crudo y diésel. El modelo demostró flexibilidad para ajustarse a diferentes escenarios predictivos:

**Predicción de valor constante (promedio histórico):**

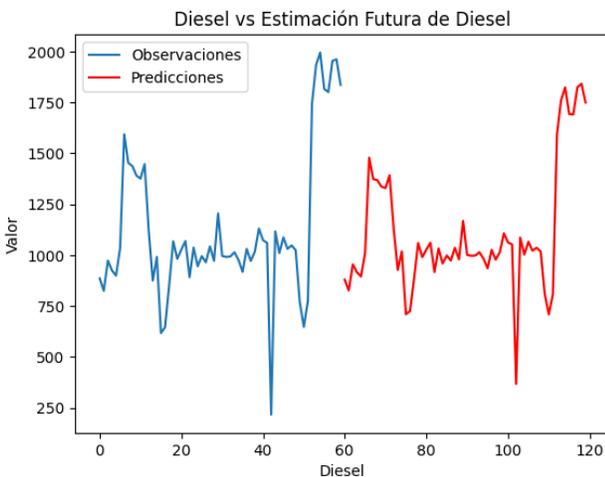
- Parámetros ARIMA:  $p=0, d=0, q=0$

**Predicción que sigue de cerca el comportamiento histórico:**

- Parámetros ARIMA:  $p=1, d=1, q=1$

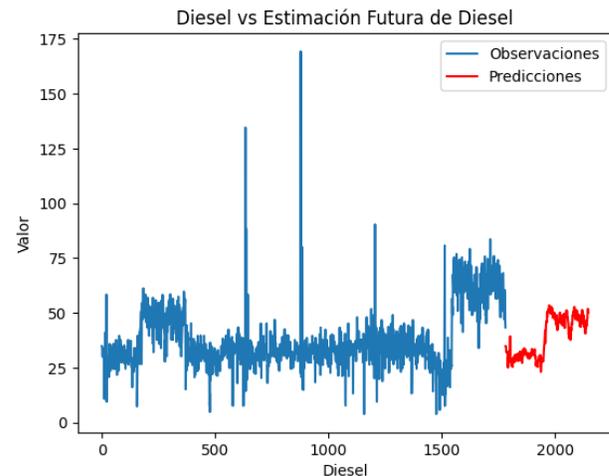


**Figura 5.** Predicción de la variable diésel para el dataset mensual con modelo ARIMA (0,0,0).

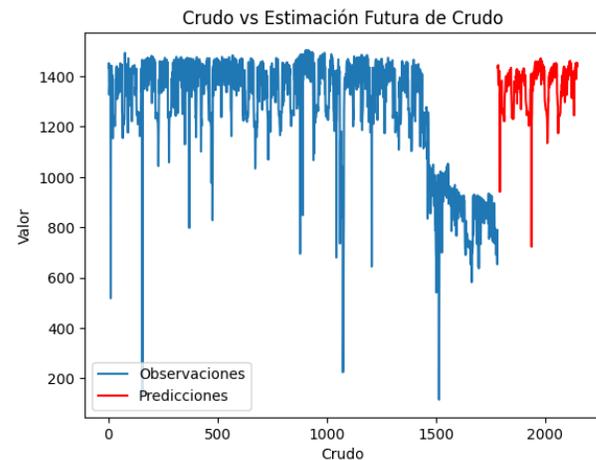


**Figura 6.** Predicción de la variable diésel para el dataset mensual con modelo ARIMA (1,1,1).

Se realizaron predicciones para el año 2024 (366 días) tanto para el consumo de diésel como de crudo.



**Figura 7.** Predicción para el año 2024 del consumo de diésel en barriles (BBLs).



**Figura 8.** Predicción para el año 2024 del consumo de crudo en barriles (BBLs).

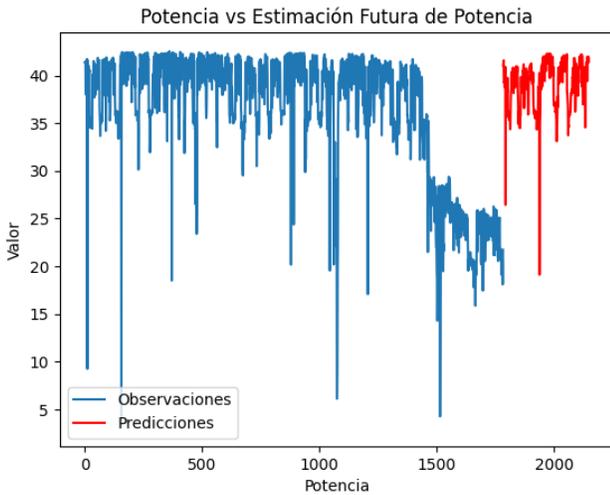
**Validación del Modelo con Datos Reales**

Se realizó una validación del modelo utilizando datos reales proporcionados por Petroecuador para el período del 1 de enero al 17 de junio de 2024. Los resultados de esta validación fueron:

- Error Absoluto Medio: 0.3 MW
- Error Cuadrático Medio: 0.19 MW
- Coeficiente de Determinación: 0.97

**Predicción de Potencia Eléctrica para 2024**

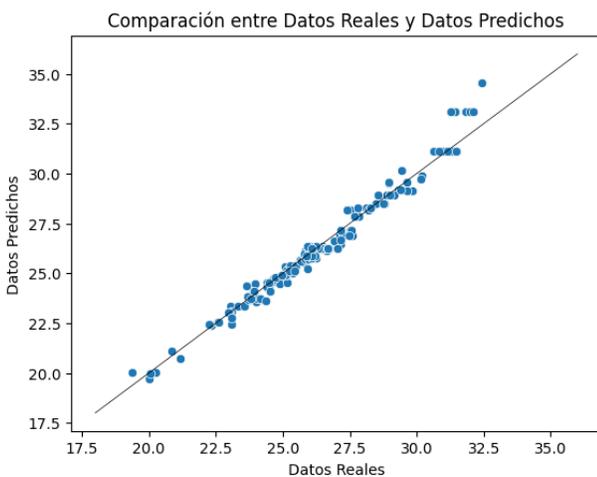
Utilizando los datos predichos de consumo de diésel y crudo para el año 2024 como entradas para el modelo de árbol de decisión, se obtuvo una predicción de la generación de potencia eléctrica para ese año.



**Figura 9.** Predicción para el año 2024 de la generación de potencia eléctrica en megavatios (MW).

Esta figura muestra la predicción diaria de generación de potencia eléctrica para todo el año 2024, basada en las predicciones de consumo de combustible. La gráfica permite visualizar las fluctuaciones esperadas en la producción de energía a lo largo del año, lo que puede ser importante en la planificación operativa y estratégica de Petroecuador.

La inclusión de esta figura en la sección de Resultados y Discusión proporciona una visión completa del proceso predictivo, desde el consumo de combustibles hasta la generación final de energía eléctrica, demostrando la capacidad del modelo para proyectar el rendimiento futuro de los grupos electrógenos.



**Figura 10.** Comparación entre datos reales de potencia eléctrica para el año 2024 y datos generados por el modelo de predicción en megavatios (MW).

Estos resultados indican una alta precisión del modelo en la predicción de la generación de potencia eléctrica, con un coeficiente de determinación de 0.97, lo que sugiere que el modelo explica el 97% de la variabilidad en los datos reales.

### Discusión

Los resultados de este estudio revelan un modelo altamente preciso para predecir la generación de energía eléctrica en los grupos electrógenos de Petroecuador, especialmente al utilizar datos diarios detallados. Esta mejora en la precisión subraya la importancia de mantener registros frecuentes y minuciosos para optimizar las predicciones energéticas.

La fuerte relación lineal entre el consumo de crudo y la generación de potencia ( $R^2 = 0.9957$ ) indica que el crudo es el factor determinante en la producción eléctrica. Esta linealidad sugiere una eficiencia constante en la conversión de crudo a electricidad, lo cual puede ser aprovechado para optimizar el suministro de combustible y la programación de generación. Por otro lado, la relación no lineal y menos correlacionada entre el consumo de diésel y la potencia generada ( $R^2 = 0.1387$ ) apunta a un uso más específico o complementario del diésel. Este comportamiento errático plantea varias hipótesis: podría estar siendo utilizado en picos de demanda, como respaldo, o su uso podría estar influenciado por factores externos como disponibilidad o precio. Estas observaciones sugieren oportunidades para optimizar el uso del diésel, ya sea mediante una mejor planificación de su uso complementario o mejoras en la eficiencia de los generadores que lo utilizan.

El modelo ARIMA demostró ser una herramienta versátil para predecir el consumo de combustibles, adaptándose tanto a tendencias generales como a fluctuaciones a corto plazo. Esta flexibilidad es primordial en un entorno energético dinámico, permitiendo ajustes rápidos a condiciones cambiantes.

La validación con datos reales de 2024, que arrojó un coeficiente de determinación de 0.97, confirma la robustez y precisión del modelo. Esta alta precisión en predicciones futuras proporciona a Petroecuador una herramienta confiable para la planificación a mediano y largo plazo. Sin embargo, es esencial mantener el modelo actualizado con nuevos datos para asegurar su precisión continua.

Las implicaciones de este modelo para Petroecuador son significativas. Permite una optimización del inventario de combustible, reduciendo costos de almacenamiento y riesgos de escasez. Facilita la planificación de mantenimiento, programando actividades en períodos de menor demanda. Mejora la eficiencia energética al

proporcionar una comprensión más profunda de la relación entre consumo de combustible y generación de energía. Además, contribuye a una mejor gestión ambiental y planificación financiera, permitiendo previsiones más precisas de producción y consumo.

No obstante, es importante reconocer las limitaciones del estudio. El modelo actual no incorpora explícitamente factores externos como condiciones climáticas, cambios en la demanda energética nacional o fluctuaciones en los precios de los combustibles. La inclusión de estas variables en futuras iteraciones podría mejorar aún más su precisión y utilidad. Además, mientras el modelo muestra un excelente rendimiento a corto y mediano plazo, su precisión a largo plazo (más allá de un año) debería ser objeto de estudios adicionales, considerando factores como el envejecimiento de equipos o cambios en políticas energéticas.

## CONCLUSIONES

La implementación de técnicas de aprendizaje automático, en particular los árboles de decisión, combinadas con modelos de series temporales ARIMA, ha demostrado ser altamente efectiva para capturar las complejas relaciones entre el consumo de combustibles y la producción de energía. El modelo alcanzó un notable coeficiente de determinación de 0.97 en la validación con datos reales, lo que indica una capacidad predictiva excepcional. Esta precisión se logró gracias al uso de datos diarios detallados, subrayando la importancia de mantener registros frecuentes y minuciosos para optimizar las predicciones energéticas.

Un hallazgo del estudio es la identificación de una fuerte relación lineal entre el consumo de crudo y la generación de potencia, contrastando con una relación más débil y no lineal en el caso del diésel. Esta distinción proporciona perspectivas valiosas sobre la eficiencia y el papel de cada tipo de combustible en el proceso de generación eléctrica. El modelo desarrollado no solo permite predicciones precisas, sino que también ofrece una herramienta versátil para la planificación estratégica, la optimización de inventarios, la programación de mantenimiento y la mejora de la eficiencia energética global de Petroecuador. La capacidad del modelo para adaptarse a diferentes horizontes temporales lo convierte en un activo invaluable para la toma de decisiones tanto a corto como a largo plazo.

Sin embargo, es importante reconocer las limitaciones del estudio y las áreas de mejora para futuras investigaciones. La incorporación de variables externas como condiciones climáticas, fluctuaciones en la demanda energética y variaciones en los precios de los combustibles podría mejorar aún más la precisión y aplicabilidad del modelo.

Además, se recomienda un monitoreo continuo y actualizaciones periódicas para mantener la relevancia y precisión del modelo a lo largo del tiempo. En conclusión, este estudio no solo proporciona a Petroecuador una herramienta poderosa para la optimización de sus operaciones, sino que también establece una base sólida para futuras investigaciones en el campo de la predicción energética y la gestión eficiente de recursos en la industria petrolera y energética.

## CONTRIBUCIÓN DE LOS AUTORES

Paco Giovanni Vásquez Carrera desarrolló el modelo matemático en integración con el algoritmo de los árboles de decisión a través de Python para el análisis y entrenamiento de este modelo matemático destinado a la predicción del consumo y generación de energía eléctrica. También se encargó de la redacción del escrito. Guillermo Edwin Machado Sotomayor se encargó de realizar las correcciones en la redacción y evaluación del modelo matemático.

## AGRADECIMIENTOS

Los autores expresan su sincero agradecimiento a Petroecuador por su valiosa colaboración al proporcionar los datos históricos de lecturas mensuales de crudo, diésel y potencia eléctrica para el período 2019-2023. Esta información fue crucial para el desarrollo y validación del modelo predictivo presentado en este estudio.

De igual manera, extendemos nuestro reconocimiento al cuerpo de ingenieros de la Universidad Técnica de Cotopaxi, extensión La Maná. Sus experiencias prácticas y criterios técnicos fueron instrumentales en el refinamiento del modelamiento matemático para la predicción del consumo y generación de energía eléctrica mediante grupos electrógenos. Su contribución enriqueció significativamente la aplicabilidad y precisión del modelo desarrollado.

## REFERENCIAS BIBLIOGRÁFICAS

- Chen, W., Alharthi, M., Zhang, J., & Khan, I. (2024). The need for energy efficiency and economic prosperity in a sustainable environment. *Gondwana Research*, 127, 22–35. <https://doi.org/10.1016/J.GR.2023.03.025>
- Dźwigoł, H., Dźwigoł-Barosz, M., & Bogdanivna Zhyvko, Z. (2019). Evaluation of the energy security as a component of national security of the country. *Article in Journal of Security and Sustainability Issues*. [https://doi.org/10.9770/jssi.2019.8.3\(2\)](https://doi.org/10.9770/jssi.2019.8.3(2))
- Gao, J., Chen, H., Li, Y., Chen, J., Zhang, Y., Dave, K., & Huang, Y. (2019). Fuel consumption and exhaust emissions of diesel vehicles in worldwide harmonized light vehicles test cycles and their

- sensitivities to eco-driving factors. *Energy Conversion and Management*, 196, 605–613. <https://doi.org/10.1016/J.ENCONMAN.2019.06.038>
- Keith, T. Z. (2019). Multiple regression and beyond: An introduction to multiple regression and structural equation modeling. *Multiple Regression and Beyond: An Introduction to Multiple Regression and Structural Equation Modeling*, 1–639. <https://doi.org/10.4324/9781315162348/MULTIPLE-REGRESSION-BEYOND-TIMOTHY-KEITH>
- Khairi, D. M., Abas, M. A., Muhamad, S. F., & Wan Salim, W. S.-I. (2021). *View of Fuel consumption mathematical models for road vehicle – A review*. Progress in Energy and Environment. <https://akademiarbaru.com/submit/index.php/progee/article/view/3392/2799>
- Krasnyuk, M., Hrashchenko, I. S., Goncharenko, S., & Krasniuk, S. (2022). Hybrid application of decision trees, fuzzy logic and production rules for supporting investment decision making (on the example of an oil and gas producing company). *ACCESS Journal: Access to Science, Business, Innovation in Digital Economy*, 3(3), 278–291. [https://doi.org/10.46656/ACCESS.2022.3.3\(7\)](https://doi.org/10.46656/ACCESS.2022.3.3(7))
- Markiewicz, M., & Muślewski, Ł. (2020). Survey performance and emission parameters of diesel engine powered by diesel oil and fatty acid methyl esters using fuzzy logic techniques. *Fuel*, 277, 118179. <https://doi.org/10.1016/J.FUEL.2020.118179>
- Shih, S. Y., Sun, F. K., & Lee, H. yi. (2019). Temporal pattern attention for multivariate time series forecasting. *Machine Learning*, 108(8–9), 1421–1441. <https://doi.org/10.1007/S10994-019-05815-0/TABLES/4>
- Van Ruijven, B. J., De Cian, E., & Sue Wing, I. (2019). Amplification of future energy demand growth due to climate change. *Nature Communications* 2019 10:1, 10(1), 1–12. <https://doi.org/10.1038/s41467-019-10399-3>
- Veza, I., Afzal, A., Mujtaba, M. A., Tuan Hoang, A., Balasubramanian, D., Sekar, M., Fattah, I. M. R., Soudagar, M. E. M., EL-Seesy, A. I., Djamari, D. W., Hananto, A. L., Putra, N. R., & Tamaldin, N. (2022). Review of artificial neural networks for gasoline, diesel and homogeneous charge compression ignition engine. *Alexandria Engineering Journal*, 61(11), 8363–8391. <https://doi.org/10.1016/J.AEJ.2022.01.072>
- Yusif Mahmoud Ahmed, J. (2023). Optimized Fuel Efficiency and Management of Diesel-Powered Thermal Plants for Power Generation Stations in Freetown. *SSRN Electronic Journal*. <https://doi.org/10.2139/SSRN.4401128>
- Zhang, Y., Vand, B., & Baldi, S. (2022). A Review of Mathematical Models of Building Physics and Energy Technologies for Environmentally Friendly Integrated Energy Management Systems. *Buildings* 2022, Vol. 12, Page 238, 12(2), 238. <https://doi.org/10.3390/BUILDINGS12020238>
- X. Han and G. Hou, "Application of Predictive Algorithms in Informational Learning," 2023 2nd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDACA), Zakopane, Poland, 2023, pp. 502-508, doi: 10.1109/ICDACA59742.2023.00101.
- K. Rao, P. R. Gopal and K. Lata, "Computational Analysis of Machine Learning Algorithms to Predict Heart Disease," 2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence), Noida, India, 2021, pp. 960-964, doi: 10.1109/Confluence51648.2021.9377185.
- Schober P, Vetter TR. Logistic Regression in Medical Research. *Anesth Analg*. 2021 Feb 1;132(2):365-366. doi: 10.1213/ANE.0000000000005247. PMID: 33449558; PMCID: PMC7785709.
- A. Pandey and A. Jain, "Detection of Compromised Accounts using Machine Learning Based Boosting Algorithms- AdaBoost, XGBoost, and CatBoost," 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), Delhi, India, 2023, pp. 1-6, doi: 10.1109/ICCCNT56998.2023.10307557.
- N. S. S. V. S. Rao and S. J. J. Thangaraj, "Flight Ticket Prediction using Random Forest Regressor Compared with Decision Tree Regressor," 2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICONSTEM), Chennai, India, 2023, pp. 1-5, doi: 10.1109/ICONSTEM56934.2023.10142260.
- N. Pachauri and C. W. Ahn, "Electrical Energy Prediction of Combined Cycle Power Plant Using Gradient Boosted Generalized Additive Model," in *IEEE Access*, vol. 10, pp. 24566-24577, 2022, doi: 10.1109/ACCESS.2022.3153720.
- Khan, Z.A.; Ullah, A.; Ullah, W.; Rho, S.; Lee, M.; Baik, S.W. Electrical Energy Prediction in Residential Buildings for Short-Term Horizons Using Hybrid Deep Learning Strategy. *Appl. Sci.* 2020, 10, 8634. <https://doi.org/10.3390/app10238634>
- Pierre AA, Akim SA, Semenyio AK, Babiga B. Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches. *Energies*. 2023;

16(12):4739.

<https://doi.org/10.3390/en16124739>

Zhang, T., Liao, L., Lai, H., Liu, J., Zou, F., Cai, Q. (2019). Electrical Energy Prediction with Regression-Oriented Models. In: Krömer, P., Zhang, H., Liang, Y., Pan, JS. (eds) Proceedings of the Fifth Euro-China Conference on Intelligent Data Analysis and Applications. ECC 2018. Advances in Intelligent Systems and Computing, vol 891. Springer, Cham. [https://doi.org/10.1007/978-3-030-03766-6\\_16](https://doi.org/10.1007/978-3-030-03766-6_16)