

## Modelo del proceso de producción de energía en centrales de generación térmica considerando el perfil de funcionamiento.

Silvia Taipe Quilligana

[staipeq@uteq.edu.ec](mailto:staipeq@uteq.edu.ec)

Universidad Técnica Estatal de Quevedo  
Quevedo-Ecuador

Gary Ampuño Aviles

[gampuno@ups.edu.ec](mailto:gampuno@ups.edu.ec)

Universidad Politécnica Salesiana  
Guayaquil - Ecuador

### Resumen:

El presente trabajo se desarrolló a fin de predecir mediante un modelo, la producción neta de energía en una central termoeléctrica. Como caso de estudio, se analizó los datos del histórico de horas de operación de la Central Termoeléctrica Quevedo. Como descriptores primarios, se identificaron las variables de entrada como combustible pesado (HFO), diésel (DO) y lubricante (LO). Las predicciones de energía, se desarrollaron aplicando múltiples regresores de aprendizaje automático (por ejemplo, procesos Gaussianos, algoritmos de aumento de gradiente, bosques aleatorios, vectores de soporte y redes neuronales). Se empleó un total de 365 conjuntos de datos, para lo cual, primero se aleatorizaron los datos y se dividió en porciones de entrenamiento (80%) y pruebas (20%). Para evitar el sobreajuste, se aplicó una validación cruzada de cinco veces. Se encontró una eficiencia de generación de planta del  $15,52\% \pm 3,76$  con un índice de disponibilidad de alrededor del 84% que describe el funcionamiento normal de la misma. El descriptor HFO representa el factor principal para predecir la energía neta producida a través de un análisis de importancia de características. Las predicciones de energía obtenidas, al compararlas, muestran un 97,85% de precisión en comparación a los resultados medidos. Los algoritmos que muestran mayor precisión fueron redes neuronales multicapa, procesos Gaussianos y el regresor de vector de soporte lineal.

**Palabras clave:** Producción de energía, termoeléctrica, aprendizaje automático, importancia de las funciones, predicción.

Correspondencia: [staipeg@uteq.edu.ec](mailto:staipeg@uteq.edu.ec)

Artículo recibido: 15 julio 2022. Aceptado para publicación: 20 agosto 2022.

Conflictos de Interés: Ninguna que declarar.

Todo el contenido de **Ciencia Latina Revista Científica Multidisciplinar**, publicados en este sitio están disponibles bajo

Licencia [Creative Commons](https://creativecommons.org/licenses/by/4.0/) 

Como citar: Taípe Quilligana, S., & Ampuño Aviles, G. (2022). Modelo del proceso de producción de energía en centrales de generación térmica considerando el perfil de funcionamiento. *Ciencia Latina Revista Científica Multidisciplinar*, 6(4), 5541-5560. [https://doi.org/10.37811/cl\\_rcm.v6i4.3032](https://doi.org/10.37811/cl_rcm.v6i4.3032)

## Model of the energy production process in thermal generation plants considering the operating profile.

### Abstract:

The present work was developed in order to predict, through a model, the net production of energy in a thermoelectric power plant. As a case study, the data of the historical hours of operation of the Quevedo Thermoelectric Power Plant was analyzed. As primary descriptors, input variables such as heavy fuel oil (HFO), diesel (DO), and lubricant (LO) were identified. The energy predictions were developed by applying multiple machine learning regressors (eg, Gaussian processes, gradient boosting algorithms, random forests, support vectors, and neural networks). A total of 365 data sets were used, for which the data was first randomized and divided into training (80%) and testing (20%) portions. To avoid overfitting, a five-fold cross-validation was applied. A plant generation efficiency of  $15.52\% \pm 3.76$  was found with an availability index of around 84%, which describes its normal operation. The HFO descriptor represents the main factor to predict the net energy produced through a feature importance analysis. The energy predictions obtained, when compared, show a 97.85% accuracy compared to the measured results. The algorithms showing the highest accuracy were multilayer neural networks, Gaussian processes, and the linear support vector regressor.

**Keywords:** Energy production, thermoelectric, machine learning, importance of functions, prediction.

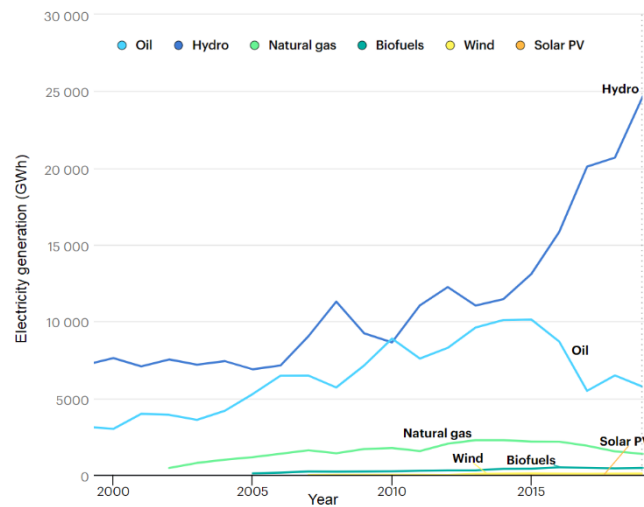
## INTRODUCCIÓN

Los suministros de petróleo y gas en los próximos 35 años se van a extinguir, mientras que la demanda de energía se encuentra en su nivel más alto (Shafiee & Topal, 2009),(Owusu & Asumadu-Sarkodie, 2016). Los gases de efecto invernadero, emitidos por el uso de los derivados del petróleo como combustible son motivo de gran preocupación. Por lo tanto, es importante enfocarse en el uso eficiente de nuestras reservas actuales. En los métodos convencionales de producción de energía, el calor residual de los motores primarios presenta pérdidas al medio ambiente. Como resultado, solo el 25-40% de la energía térmica total aportada por el combustible se convierte en energía útil (Ampuño et al., 2020). Por ello, es necesario optimizar los recursos en los sistemas de generación por combustible.

En términos medioambientales y de gestión de recursos, el suministro de energía requiere el estudio de nuevas tecnologías y el mejoramiento de los sistemas existentes (Khatri & Singh, 2017). En Ecuador, el Plan Nacional de Eficiencia Energética 2016-2035, presenta un plan intersectorial de eficiencia energética, transporte, industria, residencia, producción, generación y consumo energético. En 2013, también entró en vigor un nuevo esquema de tarifas de pago, para proyectos de energía renovable. La Corporación Eléctrica del Ecuador (CELEC EP) es un holding de propiedad estatal que se dedica a la generación, transmisión, distribución, comercialización e importación y exportación de energía eléctrica. Tiene una cartera de proyectos de energía hidroeléctrica, térmica y renovable (IRENA, 2017).


Según la Agencia Internacional de Energía (AIE) (EIA, 2017), la producción de energía ecuatoriana en 2018 fue de alrededor de 30 millones de toneladas de petróleo equivalente (Tep). El consumo eléctrico final fue de alrededor de 25 TWh con un total de 36 Mt de emisiones de CO<sub>2</sub>. La evolución de la generación de electricidad (GWh) por la fuente se describe en la Figura 1. Donde es posible observar que la generación hidroeléctrica es la principal fuente, seguida del petróleo, el gas natural y en menor proporción los biocombustibles, la solar y la eólica. La demanda de electricidad en Ecuador ha crecido rápidamente en los primeros años del siglo XXI. Es probable que la energía hidroeléctrica siga siendo la principal fuente de energía durante algún tiempo.

## Modelo del proceso de producción de energía en centrales de generación térmica considerando el perfil de funcionamiento.



**Figura 1.** Generación de electricidad por fuente (EIA, 2017).

Debido al alto crecimiento poblacional y diversos factores de impulso en la industria ecuatoriana, se espera un incremento sustancial en el consumo eléctrico debido al cambio en la matriz productiva. Después de la energía eléctrica generada por las centrales hidroeléctricas, la segunda fuente más importante para la generación de electricidad en el Ecuador es la termoeléctrica (Paredes et al., 2019). CELEC EP Termopichincha opera la Central Quevedo, la cual tiene una gran capacidad de generación de energía, alrededor de 102 MW. Una central termoeléctrica es una planta donde la energía mecánica necesaria para girar el rotor del generador, y obtener energía eléctrica, se logra a partir de la ignición de combustible pesado (HFO) (Figura 2). Una planta termoeléctrica está formada por una caldera y una turbina que mueve el generador eléctrico (Khatri & Singh, 2017). La caldera es el elemento principal, y en ella se produce la combustión de carbón, combustible pesado o gas.



**Figura 2.** Modelo simplificado de la central de generación (Khatri & Singh, 2017).

Durante este proceso se generan varios gases que se llevan a una caldera para producir vapor. El mismo, tiene una alta presión y se utiliza en plantas de tratamiento de combustible. El consumo de combustibles fósiles motiva la búsqueda constante de procesos de tratamiento y sistemas de recuperación de combustible (Muentes & Jaramillo, 2014), (Murillo & Pincay, 2020), el estudio de técnicas alternativas para la recuperación del calor residual producido en los tubos de escape de los generadores (ECHEVERRÍA, 2017), e incluso pensar en hibridar las plantas con sistemas fotovoltaicos y eólicos (Muñoz Marcillo & Chávez Fuentes, 2016).

Se han desarrollado varios trabajos para mejorar la generación de energía. Ankush Singh y Kamal Kishore Khatri (Singh & Khatri, 2016), (Khatri & Singh, 2017), en sus estudios proponen modelar generadores con combustibles fósiles e implementarlos en sistemas de cogeneración. La hibridación de los sistemas de generación de combustible de biomasa es otra alternativa para reducir la huella de CO<sub>2</sub>, donde plantas específicas se cosechan como biomasa (Marcos Martín, 2016). Otra alternativa es hibridar los generadores con energías renovables (Das et al., 2012). Antes de implementar una solución en sistemas de generación real, varios autores proponen modelar las plantas para ahorrar tiempo en pruebas de campo o daños innecesarios a los equipos que acortan la vida útil de los generadores (Khatri & Singh, 2017), (Technology & Science, 2011).

Para establecer un modelado a través de los principios de funcionamientos son empleadas las ecuaciones (1) a (4)

La potencia térmica  $\dot{Q}_{th}$  y el flujo másico están dados por la ecuación 1

$$\dot{Q}_{th} = C_s \cdot P_R \cdot PCI \quad (1)$$

$$\dot{m} = C_s \cdot P_R \quad (2)$$

Donde  $C_s$  es el consumo específico en kg.kWh<sup>-1</sup>,  $P_R$  es la potencia nominal en kW y  $PCI$  es el poder calorífico inferior del combustible en kJ.kg<sup>-1</sup>.

La eficiencia  $\eta$  está dada por la ecuación (3)


$$\eta = \frac{E_o}{E_i} \quad (3)$$

Donde  $E_o$  es la energía de salida en kW y  $E_i$  es la energía de entrada también en kW

El balance energético se basa en la potencia total entregada  $Q_{total}$  en MW versus el consumo de combustible  $\dot{m}$  en  $\text{kg}\cdot\text{s}^{-1}$  del número de generadores  $n$  que trabajan en un periodo de tiempo siendo

$$Q_{total} = PCI \cdot \dot{m} \cdot n \quad (4)$$

Debido a la necesidad de optimizar los recursos en los sistemas de generación de combustible y, gracias al aumento de la potencia computacional, los algoritmos de aprendizaje automático *Machine learning* (ML), se han aplicado recientemente a la predicción de energía. En la Figura 3, los algoritmos ML emplean métodos computacionales para aprender información directamente de los datos sin depender de una ecuación o modelo predeterminados (Chelly & Denis, 2001). ML intenta obtener inteligencia aprendiendo de la experiencia (G. O. Barrionuevo et al., 2022). El objetivo de un algoritmo supervisado es aprender una función que mapea el espacio de entrada ( $x$ ) en los valores deseados del espacio de salida ( $y$ ) y describe una relación entre entrada y salida.



**Figura 3.** Aprendizaje automático (Chelly & Denis, 2001).

Algunos de los algoritmos ML comúnmente empleados para tareas de regresión incluyen perceptrón multicapa (PM) (Goodfellow et al., 2016), árboles de decisión (AD) (Gianey & Choudhary, 2018), máquinas de vectores de soporte (MVS) (Sun et al., 2019), métodos de ensamble (ME), entre otros. Los ME, crean varios modelos y luego los combinan para producir mejores resultados y reducir el riesgo de sobreajuste (Duffy & Helmbold, 2002), (Prieditis & Sapp, 2013). Por lo general, se distinguen dos familias de métodos de conjunto: métodos de promediado y métodos de refuerzo. Los métodos de promediado incluyen bosques aleatorios (BA) (Singh et al., 2016) y métodos de ensacado. Dentro de los métodos de impulso, AdaBoost y regresores de impulso de gradiente (Sagi & Rokach,

2018) destacan. Los algoritmos de impulso brindan nuevas oportunidades para optimizar la producción de energía, convertir algoritmos débiles en fuertes y reducir el sesgo y la varianza (Zhou, 2014).

Se desarrolló un modelo del proceso de producción de energía a través del análisis del perfil de funcionamiento y datos reales. Se identificó las variables de entrada y salida que gobiernan a los termogeneradores recopilando información, para desarrollar un modelo de la producción de electricidad. Finalmente se comparó el modelo propuesto con los resultados reales obtenidos, los cuales fueron validados.

El presente artículo describe modelos que permiten describir la producción de energía en centrales similares. Se ha realizado una toma de datos en la planta de generación. Con los mismos se entrenaron y probaron varios regresores de ML con la motivación de predecir la producción neta de energía. Posteriormente se aplicó un análisis de importancia de características para determinar qué descriptor representa un mejor objetivo. Finalmente, se optimizaron los algoritmos que presentan mayor precisión para aumentar la precisión de la predicción.

## **2. ESTRATEGIAS METODOLÓGICAS O MATERIALES Y MÉTODOS**

### *A. Descripción de generadores térmicos*

Los generadores empleados en la Central Termoeléctrica Quevedo son de la marca HYUNDAI modelo 9H21/32 y trabajan con HFO (Hyundai Heavy Industries, 2013). En la Tabla 1 se muestran las especificaciones técnicas de los generadores.

**Tabla 1.** Datos técnicos del motor Hyundai

Modelo de motor	9H21/32
Potencia nominal [kW]	1800
Potencia del generador [kW]	1710
Peso total [t]	50
Sistema de refrigeración	Radiador
Combustible	Gasolina No. 6
Velocidad [rpm]	900
Consumo específico de combustible [g.kWh <sup>-1</sup> ]	183
Poder calorífico del combustible (LCV)	42700 kJ/kg

Esta información permite al ML iniciar de las características de los motores del generador para lograr adaptar los modelos a las condiciones reales de funcionamiento.

*B. Recopilación de datos*

Como se menciona en el anteproyecto, se recopiló un total de 365 conjuntos de datos a partir del informe operativo de la central térmica de Quevedo. Los parámetros de entrada (HFO, DO, LO, R y D). R es la eficiencia de la planta y D es la disponibilidad de la misma. Todos los parámetros se informan en la Tabla 2. Se puede distinguir la media y la desviación estándar para cada entrada y salida de energía (EN).



Tabla 2. Descriptores empleados para el entrenamiento y pruebas de aprendizaje

	EN (Mw)	HFO (Gal)	DO (Gal)	LO (Gal)	R (%)	D (%)
Count	365	365	365	365	365	365
Mean	1415,46	81360,74	9316,59	390,68	15,52	83,86
Std	609,09	38003,30	6280,35	473,59	3,76	15,00
Min	0	0	0	0	0	0
25%	938,65	49396,9	5025,3	65,78	16,19	79,32
50%	1777,72	101593,3	8042,4	249,79	16,47	88,58
75%	1827,13	109785,5	12294,2	546,51	16,65	91,34
Max	2034,31	123914,7	35895,4	3234,09	17,7	97,11

Como se muestra en la Figura 2, los parámetros de entrada fueron combustible pesado, diésel, aceite lubricante, eficiencia e índice de disponibilidad.

### C. Algoritmos de aprendizaje automático

Para la obtención del modelo, ML se utiliza principalmente para tareas de clasificación y regresión (Gianey & Choudhary, 2018). La regresión se emplea para estimar las relaciones entre una variable dependiente y una o más variables independientes (Kostopoulos et al., 2018). Por tanto, es una herramienta matemática apropiada para predecir la generación neta de energía. En este estudio se utilizaron varios de los algoritmos más populares. El árbol de decisión, el bosque aleatorio, el aumento de gradiente, procesos Gaussianos y el perceptrón multicapa, los cuales se detallan con precisión en (G. Barrionuevo et al., 2021).

El conjunto de datos reunido se aleatorizó y luego se dividió en porciones de entrenamiento (80%) y pruebas (20%). Antes de iniciar el proceso de entrenamiento, el conjunto de datos fue escalado usando media cero y varianza unitaria. Los algoritmos ML empleados para evaluar la generación de energía se ejecutaron en el entorno Google Colaboratory (Colab) utilizando las bibliotecas *Scikit-learn* y *XGBoost* (Pedregosa et al.,

2011), en una CPU Intel® Core™ i7-7700HQ a 2.8 GHz, con 12 Gb de RAM instalados. Los hiperparámetros empleados se resumen en la Tabla 3.

**Tabla 3.** Selección de hiperparámetros para la implementación de algoritmos

Algoritmos ML	Hiperparámetros
DTR	Profundidad máxima = 20
RFR	Número de árboles en el bosque = 2000 Profundidad máxima = 20
GBR	Número de árboles = 2000 Tasa de aprendizaje = 0.1
XGBR	Número de árboles = 2000 Profundidad máxima = 20 Tasa de aprendizaje = 0.1
GPs	Kernel = Radial based function (RBF) Nivel de ruido $\alpha = 0.001$ Número de optimizadores = 9
MLP	Capas ocultas = 4 Función de activación = relu Numero de iteraciones = 2000

#### *D. Evaluación de la precisión de las predicciones*

Se empleó validación cruzada (5k-CV) para determinar cuándo se produce el sobreajuste comparando con los datos de la prueba (Prieditis & Sapp, 2013). En este método, k representa el número de partes en las que se dividen los datos. Los subconjuntos k-1 se utilizan para el entrenamiento y el subconjunto restante se usa para probar el modelo (Baturynska & Martinsen, 2020). En el presente trabajo se aplicó CV 5 veces. Según Barrionuevo et al. (G. Barrionuevo et al., 2021), el rendimiento de los algoritmos ML es más precisos cuando se aplican múltiples métricas o una combinación de ellas. Aplicaron una métrica personalizada en forma de Ecuación (1) para medir este rendimiento:

$$IM = \sqrt{(1 - R^2)^2 + MSE + (MAE)^2} \quad (5)$$

Donde  $R^2$  es el coeficiente de determinación,  $MSE$  *mean squared error*, es el error cuadrático medio y  $MAE$  *mean absolute error*, es el error absoluto medio determinado por las ecuaciones (2), (3) y (4), respectivamente.

$$R^2 = 1 - \frac{\sum_i^N (y_i - \hat{y}_i)^2}{\sum_i^N (y_i - \bar{y})^2} \quad (6)$$

$$MSE = \frac{1}{N} \sum_i^N (y_i - \hat{y}_i)^2 \quad (7)$$


$$MAE = \frac{1}{N} \sum_i^N |y_i - \hat{y}_i| \quad (8)$$

Este índice de mérito (IM) evalúa la precisión de las predicciones; a medida que la magnitud del índice se aproxima a cero, menor es el error.

Una vez identificado qué algoritmo presenta la mayor precisión, se empleó el análisis de importancia de características (IC). El mismo, asigna una puntuación a las características de entrada en función de su utilidad para predecir una variable objetivo (VO). Además, IC proporciona puntuaciones que nos ayudan a obtener información sobre los datos y el modelo puede mejorar la eficiencia de un modelo predictivo sobre las predicciones.

### 3. RESULTADOS Y DISCUSIÓN


En la Figura 4 es posible inspeccionar visualmente las posibles relaciones entre los parámetros de entrada de combustible y la energía generada. Además, es posible observar histogramas a lo largo de la diagonal, lo que permite observar las tendencias de las muestras dentro del espectro de valores posibles. Al analizar la matriz de dispersión, es posible determinar una relación lineal entre HFO y EN.



**Figura 4.** Matriz de dispersión para mostrar una posible correlación entre descriptores (HFO, DO, LO) y la energía generada.

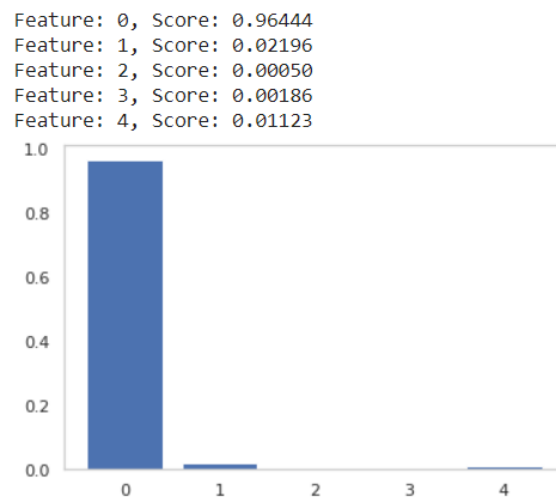
La Figura 5, muestra el modelo obtenido, mismo que logró un factor de correlación del 97,85%. Así, la energía generada podría calcularse mediante la ecuación 9:

$$EN = 0.0159 \text{ HFO} + 125.56 \quad (9)$$



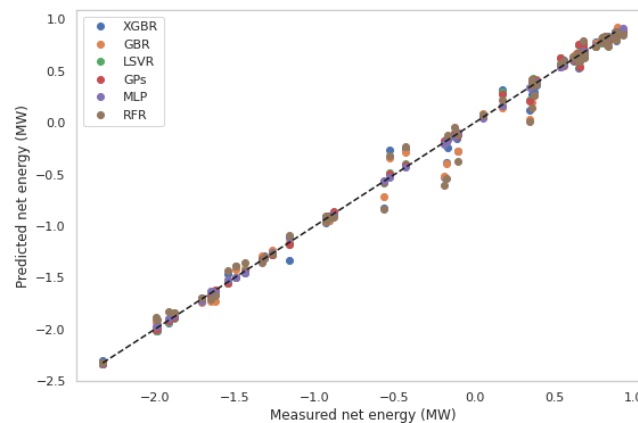
**Figura 5.** Relación lineal entre el HFO y la energía generada

La Figura 6 muestra el análisis de importancia de características, donde el HFO representa el factor principal para predecir la EN. Se puede observar el parámetro más significativo, con una puntuación superior al 96% (Característica 0). Las características 1 (DO), 2 (LO), 3 (R), 4 (D) apenas afectan la predictividad del modelo.



**Figura 6.** Análisis de la importancia de las características de los parámetros de procesamiento en el modelo de predicción de energía

La Figura 7 ilustra el comportamiento de los algoritmos ML para predecir la EN; el eje vertical muestra el valor predicho y el eje horizontal del valor medido; ambos fueron escalados a cero medias.



**Figura 7.** Gráfico de dispersión para comparar la precisión de los regresores ML en la predicción de energía neta

En la Tabla 4 se reportan las métricas obtenidas para el procedimiento de CV. Para el CV, MLP aparece como el algoritmo más preciso con el R más alto, el RMSE más bajo, MAE y el IM más bajo correspondiente. Los datos también muestran un buen rendimiento con un IM bajo. Los algoritmos restantes muestran un R más bajo que MLP y GP y un RMSE y MAE más altos, con IM superiores a 0.06.

Tabla 4. Desempeño de los algoritmos ML empleados para predecir la energía neta durante el procedimiento CV

Algorithm	R <sup>2</sup>	MSE	MAE	IM
MLP	0.9998	0.0002	0.0069	0.0144
GPs	0.9991	0.0009	0.0198	0.0353
LSVR	0.999	0.001	0.0217	0.0384
GBR	0.9964	0.0034	0.0366	0.0687
XGBR	0.9957	0.0041	0.0403	0.0758
RFR	0.993	0.0065	0.046	0.0933

La Figura 8 muestra el rendimiento durante el entrenamiento y la prueba del algoritmo MLP. Esta observación proporciona información sobre el excelente rendimiento del algoritmo para la predicción de energía neta en centrales termoeléctricas.




Figura 8. Gráfico de dispersión para la evaluación de la precisión del rendimiento del algoritmo MLP en la predicción de energía neta

#### 4. CONCLUSIÓN O CONSIDERACIONES FINALES

Este artículo evalúa varios regresores de aprendizaje automático para desarrollar un modelo capaz de predecir la energía neta producida en la Central Termoeléctrica Quevedo. Se pueden sacar las siguientes conclusiones:

## Modelo del proceso de producción de energía en centrales de generación térmica considerando el perfil de funcionamiento.

---

Se obtuvo un modelo del proceso de producción de energía a través del análisis del perfil de funcionamiento y datos reales para la Central Termoeléctrica Quevedo, mismo que permitirá evitar cuellos de botella en la transmisión y optimizar los flujos de energía.

- Se identificó todas las variables de entrada (HFO, DO, LO, R y D) y la variable de salida potencia generada (EN). Las mismas que sirvieron para desarrollar un modelo de producción de electricidad.
- Los algoritmos que mejor se desempeñan en el modelo de predicción de la energía neta fueron el perceptrón multicapa y el regresor del proceso gaussiano, que muestran el mayor coeficiente de determinación, el error cuadrático medio más bajo y el error absoluto promedio más bajo.
- La precisión de los algoritmos de ML se examinó a través del índice de mérito (IM), que aparece como un estimador robusto ya que agrupa tres métricas en una. Cuanto menor sea el IM, más preciso será el algoritmo para predecir el EN.
- Se obtuvo un modelo que explica el 97,85% de la variación de energía producida, lo que denota la importancia del manejo del fuelóleo pesado en la generación. Es importante señalar que esta relación empírica solo representa esta central termoeléctrica en particular y que ha sido validada.

## 5. LISTA DE REFERENCIAS

- Ampuño, G., Lata-Garcia, J., & Jurado, F. (2020). Evaluation of energy efficiency and the reduction of atmospheric emissions by generating electricity from a solar thermal power generation plant. *Energies*, 13(3), 1–20. <https://doi.org/10.3390/en13030645>
- Barrionuevo, G. O., Mullo, J. L., & Ramos-Grez, J. A. (2021). Predicting the ultimate tensile strength of AISI 1045 steel and 2017-T4 aluminum alloy joints in a laser-assisted rotary friction welding process using machine learning: a comparison with response surface methodology. *International Journal of Advanced Manufacturing Technology*, 116(3–4), 1247–1257. <https://doi.org/10.1007/s00170-021-07469-6>
- Barrionuevo, G. O., Sequeira-Almeida, P. M., Ríos, S., Ramos-Grez, J. A., & Williams, S. W. (2022). A machine learning approach for the prediction of melting efficiency in wire arc additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 0123456789. <https://doi.org/10.1007/s00170-022-08966-y>
- Barrionuevo, G., Ramos-Grez, J., Walczak, M., & Betancourt, C. (2021). Comparative evaluation of supervised machine learning algorithms in the prediction of the relative density of 316L stainless steel fabricated by selective laser melting. *The International Journal of Advanced Manufacturing Technology*. <https://doi.org/https://doi.org/10.1007/s00170-021-06596-4>
- Ampuño, G., Lata-Garcia, J., & Jurado, F. (2020). Evaluation of energy efficiency and the reduction of atmospheric emissions by generating electricity from a solar thermal power generation plant. *Energies*, 13(3), 1–20. <https://doi.org/10.3390/en13030645>
- Barrionuevo, G. O., Mullo, J. L., & Ramos-Grez, J. A. (2021). Predicting the ultimate tensile strength of AISI 1045 steel and 2017-T4 aluminum alloy joints in a laser-assisted rotary friction welding process using machine learning: a comparison with response surface methodology. *International Journal of Advanced*



- Manufacturing Technology, 116(3–4), 1247–1257.  
<https://doi.org/10.1007/s00170-021-07469-6>
- Barrionuevo, G. O., Sequeira-Almeida, P. M., Ríos, S., Ramos-Grez, J. A., & Williams, S. W. (2022). A machine learning approach for the prediction of melting efficiency in wire arc additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 0123456789. <https://doi.org/10.1007/s00170-022-08966-y>
- Barrionuevo, G., Ramos-Grez, J., Walczak, M., & Betancourt, C. (2021). Comparative evaluation of supervised machine learning algorithms in the prediction of the relative density of 316L stainless steel fabricated by selective laser melting. *The International Journal of Advanced Manufacturing Technology*. <https://doi.org/https://doi.org/10.1007/s00170-021-06596-4>
- Baturynska, I., & Martinsen, K. (2020). Prediction of geometry deviations in additive manufactured parts: comparison of linear regression with machine learning algorithms. *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-020-01567-0>
- Chelly, S. M., & Denis, C. (2001). Introducing Machine Learning. *Medicine and Science in Sports and Exercise*, 33(2), 326–333.  
<http://www.ncbi.nlm.nih.gov/pubmed/11224825>
- Das, D. C., Roy, A. K., & Sinha, N. (2012). GA based frequency controller for solar thermal-diesel-wind hybrid energy generation/energy storage system. *International Journal of Electrical Power and Energy Systems*, 43(1), 262–279.  
<https://doi.org/10.1016/j.ijepes.2012.05.025>
- Duffy, N., & Helmbold, D. (2002). Boosting Methods for Regression. *Theoretical Computer Science*, 284(1), 67–108. [https://doi.org/10.1016/S0304-3975\(01\)00083-4](https://doi.org/10.1016/S0304-3975(01)00083-4)
- ECHEVERRÍA, B. H. (2017). Estudio de las alternativas técnicas y económicas para la recuperación de calor residual en la Termoeléctrica Quevedo II tomando en cuenta aspectos de mitigación del cambio climático. Escuela Politécnica Nacional.

- EIA. (2017). Country Analysis Brief: Ecuador. Eia U.S. Energy Information Administration, 2016 (Figure 2), 1–12. <https://www.connaissancedesenergies.org/sites/default/files/pdf-pt-vue/ecuador.pdf>
- Gianey, H. K., & Choudhary, R. (2018). Comprehensive Review On Supervised Machine Learning Algorithms. Proceedings - 2017 International Conference on Machine Learning and Data Science, MLDS 2017, 2018-Janua, 38–43. <https://doi.org/10.1109/MLDS.2017.11>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning Adaptive Computation and Machine Learning. In The MIT Press (Vol. 1). <https://doi.org/10.2172/1462436>
- Hyundai Heavy Industries. (2013). Globalization with green technology. Engine and Machinery Division, 1–55.
- IRENA. (2017). Energy Profile Ecuador. <https://irena.org/Statistics/Statistical-Profiles>
- Khatri, K. K., & Singh, A. K. (2017). Energy and exergy analysis of a CI engine based micro-trigeneration systems fueled by alternate fuel blends. Journal of Renewable and Sustainable Energy, 9(4). <https://doi.org/10.1063/1.4991401>
- Kostopoulos, G., Karlos, S., Kotsiantis, S., & Ragos, O. (2018). Semi-supervised regression: A recent review. Journal of Intelligent and Fuzzy Systems, 35(2), 1483–1500. <https://doi.org/10.3233/JIFS-169689>
- Marcos Martín, F. (2016). Sistema híbrido termosolar – biomasa para generar energía eléctrica. Energética XXI, 156, 27–33.
- Muentes, A., & Jaramillo, M. (2014). Mejora del proceso de tratamiento de combustible En la unidad de negocio Termopichincha-Central Quevedo aplicando Pmbok (Project Management Body of Knowledge). Universidad de las Fuerzas Armadas.
- Muñoz Marcillo, J., & Chávez Fuentes, F. (2016). Determinación de áreas óptimas para instalaciones de energía solar y eólica en Quevedo, provincia de Los Ríos, aplicando sistemas de información geográfica. RIAT: Revista Interamericana de Medioambiente y Turismo, 12(2), 129–138. <https://doi.org/10.4067/351>

- Murillo, J., & Pincay, F. (2020). Diseño de un sistema de recuperación de fuel oil a partir de los residuos obtenidos del proceso de filtración para ser reutilizados en la central Termoeléctrica Quevedo II. Universidad Técnica Estatal de Quevedo.
- Owusu, P. A., & Asumadu-Sarkodie, S. (2016). A review of renewable energy sources, sustainability issues and climate change mitigation. *Cogent Engineering*, 3(1), 1–14. <https://doi.org/10.1080/23311916.2016.1167990>
- Paredes, L. A., Cáceres, M., Busso, A., Vera, L., Firman, A., Leiva, G., Luque, L., Nacional, T., ARCONEL, No, N. L., Oficial, R., & Suplemento, N. (2019). Estadísticas Anuales Y Multianual Del Sector Eléctrico Ecuatoriano 2018. *Revista Brasileira de Energia Solar*, 16(I), 47–54. <https://www.regulacionelectrica.gob.ec/wp-content/uploads/downloads/2019/08/EstadísticaAnualMultianual2018.pdf%0Ahttp://revistaenergia.cenace.org.ec/index.php/cenace/article/view/340%0Ahttp://www.ambiente.gob.ec/wp-content/uploads/downloads/2018/09/Consti>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Buitinck, L., Louppe, G., Grisel, O., & Mueller, A. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 19(1), 29–33. <https://doi.org/10.1145/2786984.2786995>
- Prieditis, A., & Sapp, S. (2013). Lazy overfitting control. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7988 LNAI, 481–491. [https://doi.org/10.1007/978-3-642-39712-7\\_37](https://doi.org/10.1007/978-3-642-39712-7_37)
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), 1–18. <https://doi.org/10.1002/widm.1249>
- Shafiee, S., & Topal, E. (2009). When will fossil fuel reserves be diminished? *Energy Policy*, 37(1), 181–189. <https://doi.org/10.1016/j.enpol.2008.08.016>
- Singh, A., & Khatri, K. K. (2016). Modelling and simulation of multi-generation systems based on a biogas operated IC Engine. *SCIENCE & TECHNOLOGY*, 2, 319–324.

- Singh, A., Thakur, N., & Sharma, A. (2016). A review of supervised machine learning algorithms. Proceedings of the 10th INDIACom; 2016 3rd International Conference on Computing for Sustainable Global Development, INDIACom 2016, 1310–1315.
- Sun, S., Cao, Z., Zhu, H., & Zhao, J. (2019). A Survey of Optimization Methods From a Machine Learning Perspective. IEEE Transactions on Cybernetics, 1–14. <https://doi.org/10.1109/tcyb.2019.2950779>
- Technology, I. J. I., & Science, C. (2011). The Control and Modeling of Diesel Generator Set in Electric Propulsion Ship. March, 31–37.
- Zhou, Z.-H. (2014). Ensemble Methods Foundations and Algorithms. In Chapman and Hall/CRC. <https://doi.org/10.1002/9781118914564.ch6>