



## **Aplicación de un algoritmo de optimización basado en aprendizaje automático en la predicción de la generación fotovoltaica**

*Application of a machine learning based optimization algorithm in the prediction of  
photovoltaic generation*

Mg. Marlon Daniel Núñez Verdezoto<sup>1</sup>



0000-0001-6829-4234

Mg. Danner Anderson Figueroa Guerra<sup>2</sup>



0000-0003-1040-5485

Mg. Javier Fernando Culqui Tipan<sup>3</sup>



0000-0002-9270-1642

Mg. Juan Carlos Pisco Vanegas<sup>4</sup>



0000-0002-9624-7993

<sup>1</sup> Universidad Técnica de Cotopaxi, Ecuador

[marlon.nunez@utc.edu.ec](mailto:marlon.nunez@utc.edu.ec)

<sup>2</sup> Universidad Técnica Estatal de Quevedo, Ecuador

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

<sup>3</sup> Universidad de las Fuerzas Armadas, Ecuador

[jfculqui@espe.edu.ec](mailto:jfculqui@espe.edu.ec)

<sup>4</sup> Universidad Técnica Estatal de Quevedo, Ecuador

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

**Recepción:** 29 de julio de 2024

**Aceptación:** 03 de agosto de 2024

**Publicación:** 05 de agosto de 2024

**Citación/como citar este artículo:** Núñez, M., Figueroa, D., Culqui, J. y Pisco, J. (2024).  
Aplicación de un algoritmo de optimización basado en aprendizaje automático en la predicción  
de la generación fotovoltaica. Ideas y Voces, 4(2), Pág. 56-71.



## Resumen

Aprovechar la energía solar para generar electricidad fotovoltaica es crucial para el desarrollo sostenible. Esta investigación propone un modelo de predicción de generación fotovoltaica utilizando Machine Learning, específicamente la técnica "Random Forest", basado en datos reales de irradiación solar y temperatura del año 2020. Los datos se obtuvieron con un piranómetro Solar Power Meter SM206 en Lacatunga, Ecuador. El modelo se desarrolló en Python, analizando las variables más influyentes. Predice la potencia basándose en irradiación solar y temperatura, con el mes de mayo seleccionado por tener la mayor cantidad de datos, lo que permite mantener el error dentro de márgenes aceptables y garantiza la eficiencia del modelo. Se comparó con datos de marzo, un mes con menos datos disponibles. La precisión en la predicción diaria fue del 91,41% y en la predicción mensual alcanzó el 94,47%. La predicción mensual resulta más efectiva debido a la mayor cantidad de datos por variable, mejorando el rendimiento del entrenamiento. Este modelo es confiable para predecir la generación fotovoltaica y optimizar sistemas de energía solar, aprovechando las altas tasas de irradiación solar en regiones tropicales.

## Palabras clave

algoritmo, árbol de decisión, fotovoltaico, aprendizaje automático, predicción.

## Abstract

Harnessing solar energy to generate photovoltaic electricity is crucial for sustainable development. This research proposes a photovoltaic generation prediction model using Machine Learning, specifically the "Random Forest" technique, based on real solar irradiation and temperature data for the year 2020. The data were obtained with a Solar Power Meter SM206 pyranometer in Lacatunga, Ecuador. The model was developed in Python, analyzing the most influential variables. It predicts power based on solar irradiance and temperature, with the month of May selected for having the largest amount of data, which allows keeping the error within acceptable margins and guarantees the efficiency of the model. It was compared with data from March, a month with less available data. The daily prediction accuracy was 91.41% and the monthly prediction accuracy was 94.47%. The monthly prediction is more effective due to the greater amount of data per variable, improving training performance. This model is reliable for predicting photovoltaic generation and optimizing solar energy systems, taking advantage of the high solar irradiation rates in tropical regions.

## Keywords

algorithm, decision tree, photovoltaic, machine learning, prediction.



## Introducción

La tecnología solar fotovoltaica (FV) radica en la conversión directa de la radiación solar en electricidad, esta conversión es realizada por una celda solar cuya unidad básica es efecto fotovoltaico. La energía solar fotovoltaica está empleada en una amplia gama de aplicaciones donde se necesita producir electricidad para satisfacer las necesidades energéticas de quienes no tienen red eléctrica (o para generar energía para la red eléctrica (sistema fotovoltaico conectado a la red). Los sistemas fotovoltaicos son una solución factible a lugares remotos, el montaje de sistemas fotovoltaicos domiciliarios o en pueblos, ayudan a dar una vida más cómoda a la población (Qiu, 2022).

En países como Ecuador existen lugares no cuentan con energía eléctrica, la cual es necesaria para brindar confort para turistas que buscan alejarse de lo cotidiano, especialmente en lugares de interés turístico como la isla Galápagos (Ayala, Arcos, Fernandes, Guinjoan & Martinez, 2023), así como en sectores rurales, que debido a las condiciones topográficas se dificulta el acceso a la red eléctrica nacional, lo que afectan la calidad de vida sus habitantes (Cuenca, Oña, Suquillo & Miniguano, 2023).

En la actualidad existen estaciones meteorológicas implementadas por instituciones gubernamentales que vienen realizando estudios sobre energía solar y plantean su aprovechamiento de manera muy eficiente, especialmente en los países tropicales (Litardo, Palme, Hidalgo, Amoroso & Soriano 2021) (Marzouk, 2022), lo cual constituiría una fuente de energía a bajo costo, por lo que se requiere de una adecuada estimación de su potencial para la generación eléctrica y poder determinar qué cantidad puede ser sustituida de la red eléctrica convencional.

Para predecir la generación de potencia se han usado complejas ecuaciones matemáticas, que se generan de la modelización de los datos, las cuales pueden ser en muchos casos imprecisos, por lo que el cálculo resulta alejado de la realidad, además que el tiempo para el diseño de los

sistemas fotovoltaicos impide de dar respuestas oportunas a la población, sin embargo con el surgimiento de la inteligencia artificial, las estimaciones de la capacidad de generación de energía aprovechando la irradiación solar ha mejorado (Zhang, Wang, Tong & Sun, 2021).

Dentro de la inteligencia artificial su principal rama o subconjunto para trabajar en predicción de datos es Machine Learning (Ramadhan, Heatubun, Tan & Lee, 2021), que trabaja mediante un aprendizaje supervisado usa un algoritmo interno de red neuronal para los datos de entrada irlos clasificando en clústeres y entrenándoles para tener una salida o una respuesta deseada, similar a la ingresada, permitiendo de esa manera predicciones precisas.

El algoritmo más utilizado en problemas de clasificación es el denominado árbol de decisión diseñados en forma de árbol (Meng & Song, 2020), los cuales van dividiendo en subconjuntos de datos cada vez más pequeños, al mismo tiempo se va formando un árbol de decisión asociados y al compararse con otros métodos como redes neuronales y Deep Learning (López, Ogando, Troncoso, Granada & Orosa, 2020) (Khan, Walker & Zeiler, (2022), resulta más preciso y con una menor tasa de error.

Considerando que el empleo de machine Learning ayudará a predecir la falta o exceso de irradiación solar empleando un algoritmo de predicción basado en “Random Forests” y utilizando los datos previamente obtenidos de medición en el lugar, el objetivo de esta investigación fue analizar la capacidad de estimación del potencial de irradiación solar mediante la aplicación de un algoritmo de predicción usando árboles de decisión que permita conocer el comportamiento de la generación fotovoltaica y compararlo con la variable real, para el diseño fotovoltaico que ayude a reducir la dependencia de la red eléctrica nacional en sectores de difícil acceso de Ecuador.

## Metodología

### Materiales y métodos

#### A. Ubicación del sitio experimental

La toma de datos se realizó en la hacienda “La campiña” de la parroquia rural Mulaló perteneciente al cantón Latacunga, con una Latitud de 0°46’40.33’’ S, Longitud 78°33’52.64’’ O, ubicada a una Altura de 3 752. Se obtuvieron datos de irradiación solar, temperatura mediante un piranómetro.

#### B. Alcance de la investigación

La presente investigación basa su estudio en predecir irradiación solar mediante una modelación que emplea Machine Learning y un algoritmo de predicción basado en “Árbol de decisión”, mediante el software Python, partiendo de la obtención de datos de irradiación solar y temperatura como variables principales para poder plasmar el modelo de predicción, estas variables se ingresan al modelo elaborado y entrenando, para lograr una predicción similar a la real con un margen de error permisible.

#### C. Recolección de los datos

Para la recolección de datos de irradiación solar se ha utilizado un instrumento de medición llamado Piranómetro Solar Power Meter SM206, este instrumento permite realizar la acumulación de la irradiación solar por un periodo de 5 minutos. Los datos obtenidos con el piranómetro Solar Power Meter SM206 se observan en la fig. 1.

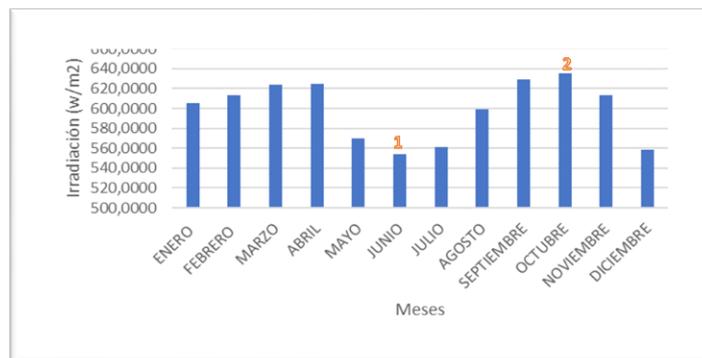


Fig. 1. Datos de irradiación solar medidos para su uso en el desarrollo de modelo de predicción de generación de energía fotovoltaica.

#### D. Análisis de calidad de los datos

Los datos obtenidos previamente del histograma se fueron ordenando adecuadamente de mayor a menor en un diagrama de Pareto, donde se pudo observar el número mayor de repeticiones de frecuencia absoluta de 3 664, la de menor repetición de 2 419, se obtuvo también una frecuencia relativa acumulada de 0.59 como mínimo y un valor de 0.93 de máximo.

#### *Análisis de la potencia requerida en el sector de la investigación*

Por ello se debe realizar un análisis de potencia requerida mediante la suma de potencias individuales instaladas para obtener una potencia total que necesita el lugar en la actualidad las 24 horas del día. Para el cálculo de la potencia máxima generada por el panel solar ENERGYGRE ECOGREEN ENERGY de 5 00 W se aplica la fórmula donde se hace una relación de transformación como se muestra en la ecuación (1).

$$P_{max} = \left( \left( \frac{255}{800} \right) * Irradiación \right) - \left( \frac{75}{4} \right) \quad (1)$$

$$\left( \frac{255}{800} \right) = \text{Relación de transformación del panel solar.}$$

Al aplicar esta ecuación se observa que la potencia generada que se presenta durante un día alcanza un pico máximo entre las 10 y 12 horas (Fig. 2), esta potencia estimada será la que se use para comparar con los datos obtenidos al simular la generación fotovoltaica mediante la simulación matemática.

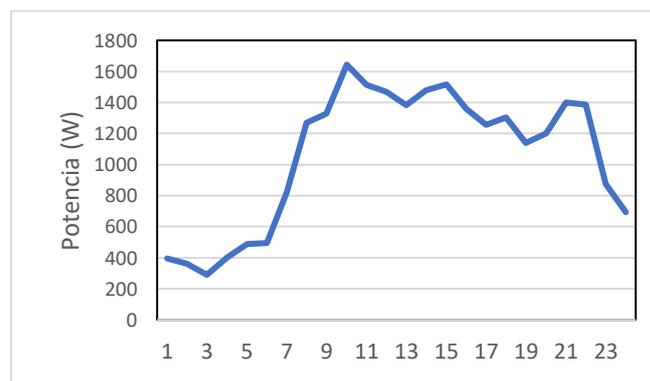


Fig. 2. Potencia eléctrica (W) estimada matemáticamente previa predicción de generación de energía fotovoltaica.

### E. Selección de algoritmo para estimación de energía fotovoltaica

La matriz de confusión se utiliza para identificar el algoritmo más eficiente en una predicción, permitiendo decidir cuál ofrece mayor exactitud y predicciones más cercanas a la variable real. En esta investigación, se compararon tres algoritmos: k-means, redes neuronales y árboles de decisión, la cual se presenta en la tabla 1.

Tabla 1. Comparación de algoritmos como basados en k-means, redes neuronales y por último árboles de decisión

<b>Medidas de rendimiento</b>			
	K-means	Redes neuronales	Arboles de precisión
Precisión	0.72222	0.478021	0.478021
Exactitud	0.58333	0.479166	0.479166
F1	0.45054	0.448621	0.448621

A pesar de que en la tabla 1, se observa que el algoritmo basado en k-means es el más preciso y exacto, los resultados al aplicar la matriz de confusión de la (Fig. 3), muestran que el uso de árbol de decisión logro una adecuada predicción para estimar potencias de 200 y 500 W con un máximo de 3 lecturas erróneas, entre 7 y 9 aciertos respectivamente, siendo el rendimiento similar al obtenido con el algoritmo de k-means y superior al de redes neuronales.

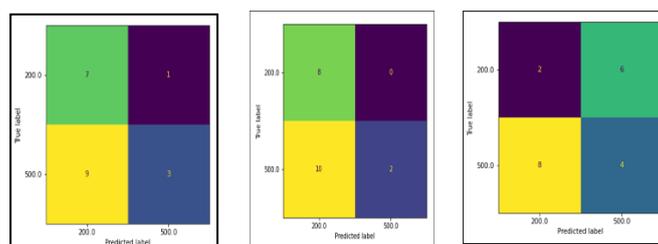


Fig. 3. Matriz de confusión para algoritmos basado en árbol de decisión, k-means y redes neuronales.

### F. Flujograma y pseudocódigo empleado en el análisis del proceso

La predicción utilizó dos variables: irradiación solar y temperatura, obtenidas de la estación del lugar de estudio. Estas variables se ingresaron en el programa de predicción, que fue

elaborado con el algoritmo de árbol de decisión. Se empleó el método de correlación, considerando las variables que más influyen: irradiación, temperatura ambiente y potencia asumida.

### **G. Preparación de datos**

Antes de ingresar los datos del instrumento de medición, se clasificaron adecuadamente por meses y días, sin alterar la concordancia de las dos variables. Se creó una base de datos completa de un año, que fue tratada y analizada estadísticamente.

### **H. Análisis del conjunto de datos y manejo de datos faltantes**

Una vez cargados los datos, se verificaron los faltantes y aquellos mal cargados o en formato erróneo para asegurar su utilidad y evitar errores durante el procesamiento en las librerías. Los datos faltantes se completaron con ceros.

### **I. Codificación de la matriz de datos**

La codificación aplicada es para identificar variables y relacionarlas entre ellas, con este proceso no sólo se identifica las variables si no que se va creando un vínculo entre los datos de la investigación, con este proceso se examinó y estructuro de una manera aplicada. Las variables codificadas se fueron ordenando para de una manera clara actuar sobre las necesidades de predicción.

### **J. Creación del modelo de predicción**

El modelo fue creado utilizando un estimado de 1 000 árboles de decisión o Random Forest y 42 Random State, se utilizó estos parámetros debido a la cantidad de datos que se obtuvo considerando que un modelo de predicción entre más datos se vaya ingresando más se asemeja al valor real.

### **K. Entrenamiento del modelo de predicción**

Para el proceso de entrenamiento realizado se preparó al modelo con datos de las variables de irradiación solar, temperatura y potencia como se ha venido mencionando de un día para

predecir la potencia del otro día y evaluar el rendimiento del modelo, expresado en la capacidad de predicción y la tasa de error.

#### **L. Cálculo del error absoluto**

Este proceso se realizó al obtener el valor absoluto con la resta de la potencia predicha con la original. Y el cálculo de MAPE que es el error porcentual medio. La ecuación (2) es utilizada para el cálculo.

$$ABS\ ERROR = ABS (PREDICCIÓN - ORIGINAL) \quad (2)$$

#### **M. Error porcentual medio (MAPE)**

El MAPE es un porcentaje que me indica la exactitud del error, que resulta de la división entre el error absoluto y el dato real como indica la ecuación (3). Si el MAPE es de 4, el pronóstico se encuentra errado en el 4%. Los valores cercanos a 0 afectan el MAPE.

$$MAPE = 100 * \left( \frac{ABS\ ERROR}{DATO\ REAL} \right) \quad (3)$$

#### **N. Descripción del proceso de modelización usando árbol de decisión**

El estudio de campo permitió crear una base de datos de irradiación solar y temperatura del año 2020, que se ordenó y trató para eliminar valores atípicos que distorsionan el modelo de predicción. Usando la matriz de confusión, se definió el modelo de “árboles de decisión” por su facilidad de codificación y eficacia en los resultados. El modelo fue entrenado y luego se utilizó para predecir la potencia, calculando posteriormente la eficiencia y la tasa de error.

### **Resultados**

#### **A. Resultados de la ejecución del modelo de predicción diario**

Tras entrenar el modelo con las variables planteadas, se obtuvo una predicción similar a la real. Para contextualizar, se entrenó el modelo con las variables de los días 01 y 20, ocultando la variable a predecir. Es crucial entrenar adecuadamente los datos para obtener resultados cercanos a los reales (Fig. 4).

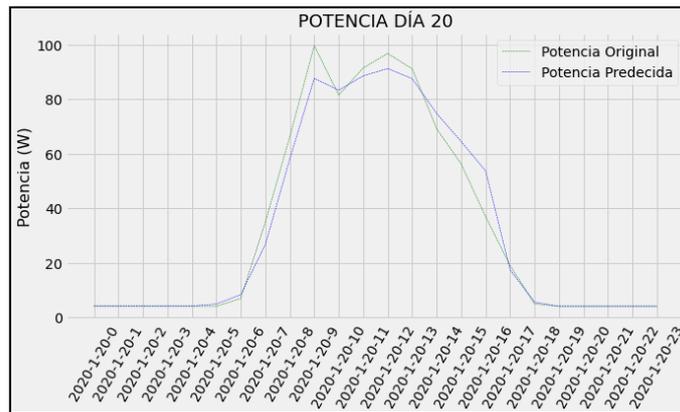


Fig. 4. Comparación de datos originales y datos predichos usando algoritmo de árbol de decisión para la predicción de potencia fotovoltaica diaria.

La Fig. 4. es el resultado obtenido con el modelo elaborado a base de Machine Learning y su librería Random Forest que tiene la capacidad de predecir generación fotovoltaica. La variable original se encuentra en la curva de color verde mientras que la variable de predicción se encuentra de color azul, como se aprecia el comportamiento de las curvas tiene una cierta diferencia una de la otra.

#### a. Error absoluto

Para determinar el MAPE o error absoluto, se restaron los datos de la variable de predicción de los de la variable original. La ejecución del pseudocódigo produjo un error absoluto de 3.24 vatios, con un rendimiento del modelo del 91.41%. Este resultado confirma que el modelo está bien desarrollado y funciona adecuadamente.

Tabla 2. Cálculo de error absoluto usando algoritmo de árbol de decisión para la predicción de energía fotovoltaica

HORA	P. ORIGINAL	P. PREDICCIÓN	ERROR ABS	MAPE
0:00	4	4,096164	0,096164	2,4041
1:00	4	4,096164	0,096164	2,4041
2:00	4	4,096164	0,096164	2,4041
3:00	4	4,096164	0,096164	2,4041
4:00	4	4,096164	0,096164	2,4041
5:00	4	4,096164	0,096164	2,4041
6:00	6,881766	8,312983	1,431217	20,7972343
7:00	34,889350	26,62586	8,265490	23,6905818
8:00	66,218391	58,04884	8,169551	12,3372841
9:00	99,668456	87,65973	12,008731	12,0486777
10:00	81,525365	83,337761	1,812396	2,22310688
11:00	91,496111	88,58982	2,906293	3,17641151
12:00	96,806394	91,27030	5,536098	5,71873176
13:00	91,156605	87,57222	3,584386	3,9321188
14:00	69,172156	74,78047	5,608313	8,10776087
15:00	56,259800	64,49330	8,233498	14,6347801
16:00	36,892668	53,679761	16,787093	45,5025183
17:00	18,945200	17,343239	1,601961	8,45576188
18:00	4,889518	5,495335	0,605817	12,390117
19:00	4,000000	4,000000	0,000000	0
20:00	4,000000	4,000000	0,000000	0
21:00	4,000000	4,000000	0,000000	0
22:00	4,000000	4,000000	0,000000	0
23:00	4,000000	4,000000	0,000000	0

## b. Validación del modelo de predicción mensual

Mediante el análisis de los datos recolectados se planteó una base mensual similar a la base de datos diaria a diferencia que se aplicó la base de datos completa, en el proceso se identificó las relaciones puntuales entre las variables más utilizadas o las que mayor porcentaje de participación tienen para demostrar la eficiencia del modelo predictivo que se elaboró con RANDOM FOREST.

La predicción mensual elaborada es del mes de mayo, y se entrenó con los datos de marzo para su modelo. El proceso de entrenamiento se elaboró con los mismos 1 000 árboles de decisión. La Fig. 5 muestra los resultados del pseudocódigo con dos curvas: la verde representa la variable real y la azul, la variable de predicción. La predicción mensual incluye los 31 días de mayo, lo que permite analizar si la irradiación cubrirá la demanda solicitada.

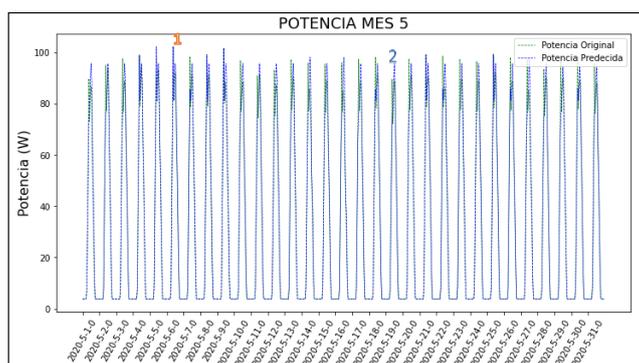


Fig. 5. Comparación de datos originales y datos predichos usando algoritmo de árbol de decisión para la predicción de potencia fotovoltaica mensual.

El modelo de predicción basado en Árboles de decisión creó una curva por cada día del mes, empieza en el 01 hasta el último día del mes de mayo 31. Mientras se ejecutó el modelo se fue probando varias predicciones como se muestran en la Fig. 6, hasta que el error resultante esté dentro de los parámetros adecuados y permisibles. donde se llegó a una precisión del 94.47 %, es decir la potencia de prueba colocada tuvo un margen de error de 2.37 Wattios, la cual es superior a la precisión de 91.41 % obtenidos con datos diarios.

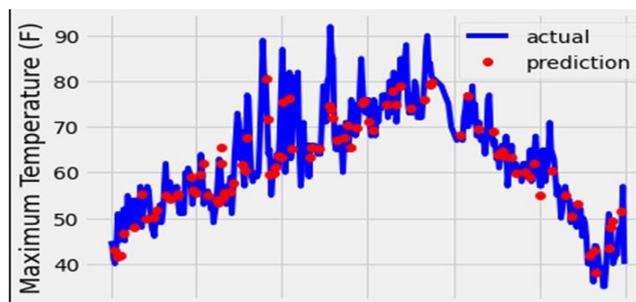


Fig. 6. Error absoluto usando algoritmo de árbol de decisión para la predicción de energía fotovoltaica para datos mensuales.

### c. Validación cruzada del modelo de predicción (Cross-Validation)

Para evaluar el desempeño del modelo predictivo, se utilizó la Validación Cruzada, dividiendo el proceso en entrenamiento e implementación. En el entrenamiento, se ajustó el modelo, y en la implementación se usaron datos no observados para evaluar el rendimiento real. Se utilizaron 1,000 árboles de decisión. Inicialmente, se probó con 100 árboles, logrando un desempeño de 0.8012 en entrenamiento y 0.7354 en implementación, lo que indicó un error amplio y predicción inexacta. El modelo final se entrenó con todos los datos, utilizando 1,000 rondas para determinar la estabilidad. La Fig. 7, muestra la curva de entrenamiento, que aumenta con la magnitud de los datos, y la curva de desempeño de predicción, que se estabiliza al alcanzar el número de rondas necesarias.

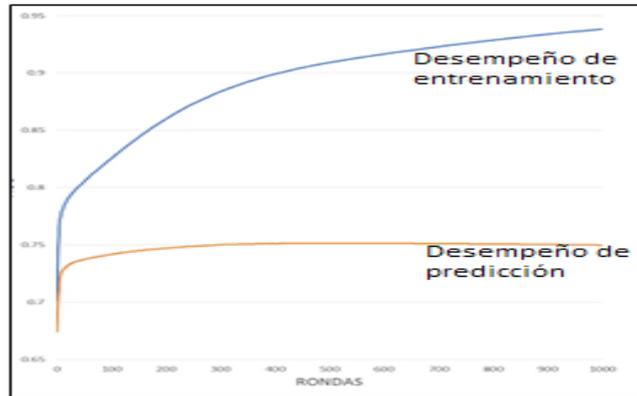


Fig. 7. Error absoluto usando algoritmo de árbol de decisión para la predicción de energía fotovoltaica para datos mensuales.

## Discusión

Aunque la inteligencia artificial mejora la predicción, los resultados muestran que los datos predichos están alejados de los reales. Aunque el algoritmo de árbol de decisiones es más preciso que k-means y redes neuronales (Dhibi, 2023), los datos de entrenamiento fueron aceptables, pero los de la predicción no lo fueron. Para mejorar la precisión, se deben incorporar más variables además de la irradiación y temperatura, ya que un mayor número de datos reduce el error experimental (Montilla, Mora, Durán & Pastrán, 2024). En Ecuador, una ventaja es la amplia red climatológica con suficientes datos de acceso libre, más completa y eficiente que muchas en Latinoamérica. Aunque el árbol de decisión tiene buena capacidad de predicción, su rendimiento es relativamente bajo.

Estimar la potencia de generación fotovoltaica puede beneficiar sectores como el turismo y la agricultura, donde la falta de acceso a la red eléctrica afecta la calidad de los servicios, especialmente en regiones de la Sierra y las Islas Galápagos. Según (Inca, Cabrera, Carrion, Villalta, Bautista & Cabrera, 2023), es necesario adoptar estos sistemas no solo por los beneficios ambientales, sino también para reducir la brecha de acceso a la energía entre zonas urbanas y rurales.

El procedimiento utilizado no solo puede aplicarse para estimar la potencia en sistemas de energía solar, sino también para calcular la energía en sistemas eólicos, cuyo potencial es alto

en ciertas regiones de Ecuador (Uvidia, Masaquiza, Paladines & Moyano, 2024). Esto ha permitido sustituir parcialmente sistemas de energía convencionales y generar electricidad en áreas sin acceso al servicio, aprovechando las condiciones climáticas favorables del país, especialmente en cuanto a viento e irradiación solar.

El cálculo de potencia es el primer paso para la optimización de los sistemas de energía limpia, que actualmente es limitado por los altos costos, pero que su uso es imprevisible en un contexto de cambio climático que limita el uso de energía hidroeléctrica (Naranjo, 2024), como paso previo a la instalación de un sistemas fotovoltaico se debe calcular la potencia requerida y cuantificar la capacidad de sustitución de la energía convencional por energía solar u eólica, para lo cual el uso de los modelos basados en inteligencia artificial y alimentados con datos climáticos es la vía más expeditas para lograr datos rápidos, precisos y confiables.

### **Conclusiones**

Mediante el análisis comparativo con dos algoritmos predictivos con la herramienta matriz de confusión es el más cercano a la variable real con las siguientes medidas de rendimiento: precisión de 0.4780, exactitud de 0.4791 y la función F1 de 0.4486, cuya precisión se mejora cuando se utiliza rondas de 1 000 árboles de decisión, sin embargo, el rendimiento obtenido en la ejecución es menor al observado durante el entrenamiento.

La creación del algoritmo de predicción el cual me brindó dos predicciones una diaria y una mensual siendo la más acertada la mensual que tiene un rendimiento del 94.4 % a comparación de la predicción diaria que tiene un rendimiento del 91.41 % esto es debido a que en el mensual ingresa en el proceso de entrenamiento una base de datos completa y el resultado depende de un entrenamiento pertinente del 80 %.

Con la elaboración del algoritmo es recomendable en estudios posteriores la implementación de nuevas variables que pueden ayudar a aumentar el porcentaje de rendimiento del modelo y explicar el comportamiento de la irradiación solar, valerse de variables adicionales como

velocidad del viento, humedad relativa, punto de rocío entre otros que puede ser de gran aporte para robustecer el modelo.

## Bibliografía

Ayala-Pico, J., Arcos-Aviles, D., Ibarra, A., Fernandez, C., Guinjoan, F., & Martinez, W. (2023). Current development of electricity generation systems in the Galapagos Islands – Ecuador. *Renewable Energy Focus*, 46, 88–102. <https://doi.org/10.1016/j.ref.2022.12.006>

Cuenca, A., Oña, C., Suquillo, I., & Miniguano, H. (2023). Design methodology of off-grid PV solar powered systems for rural areas in Ecuador. *Revista Técnica "energía"*, 20(1), 43–51.

Dhibi, K., et al. (2020). Reduced kernel random forest technique for fault detection and classification in grid-tied PV systems. *IEEE Journal of Photovoltaics*, 10(6), 1864–1871. <https://doi.org/10.1109/JPHOTOV.2020.3016510>

Inca Yajamín, G. S., Cabrera Carrión, D. F., Villalta Gualán, D. F., Bautista Zurita, R. C., & Cabrera Carrion, H. D. (2023). Evaluación de la actualidad de los sistemas fotovoltaicos en Ecuador: avances, desafíos y perspectivas. *Ciencia Latina*, 7(3), 9493–9509. [https://doi.org/10.37811/cl\\_rcm.v7i3.3549](https://doi.org/10.37811/cl_rcm.v7i3.3549)

Khan, W., Walker, S., & Zeiler, W. (2022). Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach. *Energy (Oxford)*, 240, 122812. <https://doi.org/10.1016/j.energy.2021.122812>

Litardo, J., Palme, M., Hidalgo-León, R., Amoroso, F., & Soriano, G. (2021). Energy saving strategies and on-site power generation in a university building from a tropical climate. *Applied Sciences (Basel)*, 11(2), 542. <https://doi.org/10.3390/app11020542>

López Gómez, J., Ogando Martínez, A., Troncoso Pastoriza, F., Febrero Garrido, L., Granada Álvarez, E., & Orosa García, J. A. (2020). Photovoltaic power prediction using artificial neural networks and numerical weather data. *Sustainability*, 12(24), 10295. <https://doi.org/10.3390/su122410295>

Marzouk, O. A. (2022). Land-use competitiveness of photovoltaic and concentrated solar power technologies near the Tropic of Cancer. *Solar Energy*, 243, 103–119. <https://doi.org/10.1016/j.solener.2022.08.007>

Meng, M., & Song, C. (2020). Daily photovoltaic power generation forecasting model based on random forest algorithm for North China in winter. *Sustainability*, 12(6), 2247. <https://doi.org/10.3390/su12062247>



Montilla Pacheco, A. de J., Mora Pisco, C. I., Durán Vasco, M. E., & Pastrán Calles, F. R. (2024). Contribución al estudio de la geografía climática del Ecuador continental. *Ciencia UNEMI*, 17(44), 237–248. <https://doi.org/10.29076/issn.2528-7737vol17iss44.2024pp237-248>

Naranjo-Silva, S. (2024). A hydropower development perspective in Ecuador: past, present, and future. *Granja*, 39(1). <https://doi.org/10.17163/lgr.n39.2024>

Qiu, T., et al. (2022). Potential assessment of photovoltaic power generation in China. *Renewable and Sustainable Energy Reviews*, 154, 111900. <https://doi.org/10.1016/j.rser.2021.111900>

Ramadhan, R. A. A., Heatubun, Y. R. J., Tan, S. F., & Lee, H.-J. (2021). Comparison of physical and machine learning models for estimating solar irradiance and photovoltaic power. *Renewable Energy*, 178, 1006–1019. <https://doi.org/10.1016/j.renene.2021.06.066>

Uvidía Armijo, L. A., Masaquiza Masaquiza, J. U., Paladines Carrión, J. M., & Moyano Jácome, M. G. (2024). Revisión documental de la energía eólica para la generación de energía eléctrica en el Ecuador. *Ciencia Latina*, 7(6), 6714–6734. [https://doi.org/10.37811/cl\\_rcm.v7i6.4926](https://doi.org/10.37811/cl_rcm.v7i6.4926)

Zhang, S., Wang, J., Liu, H., Tong, J., & Sun, Z. (2021). Prediction of energy photovoltaic power generation based on artificial intelligence algorithm. *Neural Computing and Applications*, 33(3), 821–835. <https://doi.org/10.1007/s00521-020-05132-8>