

Análisis comparativo de algoritmos de aprendizaje automático para la detección de puntos calientes fotovoltaicos usando datos de sensores en climas tropicales

Comparative analysis of machine learning algorithms for the detection of photovoltaic hotspots using sensor data in tropical climates

Análise comparativa de algoritmos de aprendizado de máquina para a detecção de pontos quentes fotovoltaicos usando dados de sensores em climas tropicais

Ambar Cristhina Chancay Ureta, <https://orcid.org/0009-0001-9895-2805>

Víctor Alfonso Martínez Falcones, <https://orcid.org/0000-0002-0478-3175>

Universidad Técnica de Manabí. Ecuador

*Autor para correspondencia: achancay1714@utm.edu.ec

RESUMEN

En el presente trabajo se analiza la detección automática de puntos calientes en módulos fotovoltaicos mediante datos térmicos y ambientales capturados por sensores en condiciones de clima tropical. Se empleó la metodología CRISP-DM para limpiar y normalizar 9.996 registros temporales, además de realizar variables derivadas, como la diferencia térmica panel-ambiente, orientadas a un esquema de clasificación binaria de eventos de sobrecalentamiento. Se estima que la detección tardía del sobrecalentamiento disminuye la efectividad energética y acelerar la degradación del módulo, lo que aumenta los valores de operación y mantenimiento. Se entrenaron y compararon los modelos Random Forest y Perceptrón Multicapa bajo la validación temporal y métricas de clasificación. Los resultados evidencian mejor rendimiento de Random Forest (AUC=0.87; accuracy=0.779; F1=0.758), lo que respalda su uso para monitoreo predictivo y priorización de inspecciones en instalaciones fotovoltaicas de climas tropicales, con validación en una instalación ubicada en Ecuador.

Palabras clave: Puntos calientes; paneles fotovoltaicos; Random Forest; Perceptrón Multicapa (MLP); datos de sensores.

ABSTRACT

This paper analyzes the automatic detection of hot spots in photovoltaic modules using thermal and environmental data captured by sensors under tropical climate conditions. The CRISP-DM methodology was used to clean and normalize 9,996-time records, and derived variables, such as the panel-ambient temperature difference, were calculated for a binary classification scheme of overheating events. It is estimated that late detection of overheating reduces energy efficiency and accelerates module degradation, increasing operating and maintenance costs. Random Forest and Multilayer Perceptron models were trained and compared using temporal validation and classification metrics. The results show better performance for Random Forest (AUC=0.87; accuracy=0.779; F1=0.758), supporting its use for predictive monitoring and prioritization of inspections in photovoltaic installations in tropical climates, with validation at an installation located in Ecuador.

Keywords: Hotspots; photovoltaic panels; Random Forest; Multilayer Perceptron (MLP); sensor data.

RESUMO

Este artigo analisa a detecção automática de pontos quentes em módulos fotovoltaicos usando dados térmicos e ambientais capturados por sensores em condições climáticas tropicais. A metodologia CRISP-DM foi usada para limpar e normalizar 9.996 registros temporais, e variáveis derivadas, como a diferença de temperatura entre o painel e o ambiente, foram calculadas para um esquema de classificação binária de eventos de superaquecimento. Estima-se que a detecção tardia de superaquecimento reduz a eficiência energética e acelera a degradação do módulo, aumentando os custos de operação e manutenção. Os modelos Random Forest e Multilayer Perceptron foram treinados e comparados usando métricas de validação temporal e classificação. Os resultados mostram melhor desempenho para o Random Forest (AUC=0,87; precisão=0,779;

F1=0,758), apoyando su uso para monitoreo predictivo e priorización de inspecciones en instalaciones fotovoltaicas en climas tropicales, con validación en una instalación localizada en Ecuador.

Palabras-chave: Puntos calientes; painéis fotovoltaicos; Random Forest; Multilayer Perceptron (MLP); datos de sensores.

Recibido: 22/3/2025 Aprobado: 2/4/2026

Introducción

La adopción de sistemas fotovoltaicos como fuente de energía renovable ha crecido significativamente en los últimos años debido a su capacidad para reducir las emisiones de gases de efecto invernadero y promover el uso sostenible de los recursos energéticos (Carrillo, 2024).

No obstante, el rendimiento y confianza reflejados en estos sistemas se pueden ver perjudicados por acontecimientos térmicos, como los puntos calientes, los cuales se definen como aumentos anómalos de temperatura situados en zonas específicas del módulo fotovoltaico, ocasionando la disminución de eficiencia energética y por ende llegan a acelerar la degradación de los materiales (Yaulilahua & Sumarriva, 2025).

En climas tropicales, específicamente los que tienen alta radiación, temperaturas intensas y mucha humedad a lo largo del año, la disipación térmica del módulo podría verse limitada, ya que se incrementa el riesgo de acumulación de calor (Aco & Hancoco, 2023; Alonso, 2025). Según la clasificación de Köppen–Geiger, estos requisitos están relacionados principalmente con categorías cálidas-húmedas, introduciendo así una variabilidad ambiental importante para los modelos (Álvarez Contreras *et al.*, 2023) que se basan en sensores y además de requerir planes de validación en donde se tomen en cuenta el componente temporal.

La literatura transmite enfoques que ayudan a detectar fallas térmicas en sistemas fotovoltaicos bajo el uso de técnicas de inteligencia artificial (Domínguez, 2025; Sarián González *et al.*, 2025) y análisis termográfico. Algunos estudios actuales mencionan que modelos de aprendizaje automático, como Random Forest o redes neuronales artificiales (Naranjo & Escudero, 2025), se pueden identificar ciertos patrones de sobrecalentamiento desde variables ambientales y térmicas, mejorando así la precisión de los métodos habituales de inspección (Castañeda & Jiménez, 2023; Tirado, 2024).

De la misma manera, algunas investigaciones han determinado que variables como la radiación solar y la temperatura ambiente cumplen un rendimiento fundamental en la aparición de puntos calientes en módulos fotovoltaicos (Adekanbi & Alaba, 2024; Ramos, 2022).

Sin embargo, una parte esencial de estas investigaciones se enfoca en imágenes termográficas o en escenarios controlados, en cambio la detección que usa sensores en climas tropicales está expuesta a desafíos adicionales, como, por ejemplo: la variabilidad temporal marcada, posibles desbalances entre eventos anómalos y normales, y la necesidad de protocolos de validación temporal que eviten sobreestimar el desempeño del modelo.

En este sentido, la finalidad de la presente investigación es comparar el desempeño de Random Forest y Perceptrón Multicapa para la detección automática de puntos calientes en módulos fotovoltaicos, bajo el uso de datos térmicos y ambientales con sensores en condiciones de clima tropical, y empleando un protocolo de evaluación reproducible basado en métricas de clasificación.

Adicionalmente esta investigación muestra un esquema reproducible de preparación de datos y evaluación comparativa con datos tabulares sensoriales, que se orientan a contextos tropicales, y discute la aplicabilidad del modelo con mejores métricas como soporte para monitoreo predictivo.

Metodología

Este proyecto se encuentra bajo un enfoque cuantitativo y un diseño longitudinal no experimental, utilizando registros térmicos y ambientales obtenidos a través de sensores instalados en módulos fotovoltaicos.

En cuanto al proceso metodológico este se realizó con CRISP-DM, el cual incluye etapas de comprensión del problema, adquisición y limpieza de datos, preparación de atributos, entrenamiento de modelos y evaluación comparativa, poniendo realce en la reproducibilidad del protocolo de validación y en las métricas de clasificación (Hernandez & Löschenbrand, 2022).

Datos y adquisición

El dataset estuvo conformado por 9.996 registros temporales obtenidos de dos módulos fotovoltaicos instrumentados con sensores de temperatura superficial del panel, así como con sensores ambientales para medir temperatura ambiente, humedad relativa y radiación UV. Las mediciones cubrieron el periodo comprendido entre el 8 de abril de 2024 y el 1 de marzo de 2025, con registros obtenidos en intervalos no uniformes, en un entorno de clima tropical húmedo, correspondiente al caso de validación ubicado

en Portoviejo, Ecuador (1.05° S, 80.45° O). Posteriormente, se realizó un análisis exploratorio de los datos mediante estadísticas descriptivas y visualizaciones, incluyendo histogramas, diagramas de caja y matrices de correlación, con el fin de identificar patrones de comportamiento, relaciones entre variables y posibles valores atípicos.

En cuanto al procedimiento de depuración se incluyó:

Eliminación de registros duplicados.

Filtrado de valores fuera de rangos físicos plausibles.

Tratamiento de datos faltantes.

Cuando se descubrieron faltantes consecutivos de hasta tres intervalos, se empleó la interpolación lineal en donde se logró estimar los valores ausentes. Por el contrario, cuando los faltantes excedían ese umbral, los registros correspondientes se eliminaron del análisis para evitar distorsiones en el entrenamiento de los modelos.

Preparación de los datos

En la etapa de preparación se realizaron varias transformaciones para garantizar la consistencia de los datos y facilitar el entrenamiento de los modelos.

Primero, las variables numéricas se normalizaron mediante el método Min-Max, escalando los valores al rango [0,1], lo que permite homogeneizar las escalas y mejorar la estabilidad de los algoritmos de aprendizaje automático.

Segundo, se construyó la variable derivada: $\text{delta_temp} = T_{\text{panel}} - T_{\text{ambiente}}$ la cual representa la diferencia térmica entre el módulo fotovoltaico y el ambiente. Este indicador permite cuantificar el sobrecalentamiento relativo del panel y se utilizó como referencia para definir eventos de anomalía térmica.

Tercero, se definió una etiqueta binaria (hotspot / no hotspot) utilizando el criterio: $\text{delta_temp} > 10$ °C valor reportado en la literatura como indicador de sobrecalentamiento potencial en módulos fotovoltaicos (Dhimish, 2024).

Las variables utilizadas como predictoras del modelo fueron la temperatura del panel, la temperatura ambiente, la humedad relativa y la radiación UV. La variable delta_temp se empleó únicamente para crear la etiqueta y no como predictor, con el objetivo de prevenir la fuga de información (data leakage) en el entrenamiento.

Después del proceso de etiquetado, el conjunto de datos final consistió en 7.810 registros clasificados como condiciones normales (no hotspot) y 2.186 como hotspot, lo que representa aproximadamente el 78 % y el 22 % del total, respectivamente.

Configuración de modelos

En cuanto al modelado se eligieron dos algoritmos de clasificación supervisada considerablemente aplicados en problemas de detección de anomalías en datos tabulares: Random Forest (RF) y Perceptrón Multicapa (MLP).

Random Forest es un modelo basado en ensambles de árboles de decisión, el cual es capaz de modelar relaciones no lineales entre variables y de ofrecer robustez frente a ruido y variabilidad en los datos (Yaqoob et al., 2025).

En esta investigación, el método se ejecutó en Scikit-learn usando una configuración base, con $\text{random_state} = 42$ y $\text{class_weight} = \text{"balanced"}$, todo esto con el único fin de mejorar el manejo del desbalance de clases.

El Perceptrón Multicapa (MLP) es una red neuronal artificial feed-forward capaz de aproximar funciones complejas mediante capas de neuronas interconectadas (Silvestrini & Lavagna, 2022). El modelo se empleó en Scikit-learn con $\text{random_state} = 42$, $\text{max_iter} = 500$, $\text{early_stopping} = \text{True}$ y $\text{validation_fraction} = 0.2$. El entrenamiento se ejecutó bajo la optimización de Adam, utilizando los valores por defecto de la librería.

La elección de ambos modelos facilita la comparación de un enfoque basado en árboles, robusto e interpretable, frente a un modelo neuronal con capacidad para capturar relaciones no lineales más complejas (Flores & Vásquez, 2025).

Evaluación del modelo

El rendimiento de los modelos se valoró a través de una partición estratificada del dataset en entrenamiento y prueba, usando el 80 % de los datos para entrenamiento y el 20 % para prueba, con $\text{random_state} = 42$ y conservando la proporción de clases mediante $\text{stratify} = y$.

Se aplicaron como métricas de evaluación la matriz de confusión, la precisión (precision), la sensibilidad (recall), el F1-score y el área bajo la curva ROC (AUC). Las probabilidades originadas por los modelos se convirtieron en etiquetas binarias utilizando un umbral de decisión de 0.5.

De manera complementario para futuras evaluaciones se podrían incorporar métricas como PR-AUC, especificidad o MCC, centrándose en escenarios con desbalance de clases.

Resultados y discusión


Comportamiento térmico del panel fotovoltaico

Previo al proceso de modelado, se realizó una exploración descriptiva del dataset, compuesto por 9.996 registros térmicos y ambientales, con el objetivo de verificar los rangos de variación, la consistencia de las mediciones y posibles valores extremos. Este análisis permitió identificar una alta variabilidad térmica asociada a los ciclos de radiación solar y a las condiciones ambientales del sistema.

La conducta térmica del panel se valoró a través de delta_temp , determinada como la diferencia entre la temperatura del panel y la temperatura ambiente ($\text{delta_temp} = T_{\text{panel}} - T_{\text{ambiente}}$). Este parámetro cuantifica el sobrecalentamiento relativo del módulo y facilita constituir el criterio operativo para identificar eventos de punto caliente.

La Figura 1 muestra la distribución de la variable delta_temp_c en conjunto con el umbral térmico de 10 °C utilizado para clasificar registros como hotspot (Dhimish, 2024). En la distribución se contemplan valores negativos, cercanos a cero y positivos elevados, evidenciando así distintos niveles de diferencia térmica entre el panel y el ambiente, además los valores que superan el umbral muestran condiciones de sobrecalentamiento anómalo y se consideran eventos de punto caliente para el modelado supervisado.

Figura 1. Distribución del delta_temp_c y umbral de hotspot



En los datos analizados, aproximadamente el 22% de los registros superó el umbral de 10 °C, con percentiles $P50 = 3.8$ °C, $P75 = 8.6$ °C y $P95 = 15.4$ °C para la variable delta_temp . Esta distribución garantiza el uso del umbral como criterio operativo para la generación de etiquetas en el modelado supervisado.

Desempeño de los modelos de clasificación

En la Tabla 1 se puede observar un resumen de las métricas globales obtenidas para los modelos evaluados. Adicional a ello, se muestra el análisis de la matriz de confusión que permitió calcular métricas por clase, como precisión (precision), sensibilidad (recall) y F1-score.

Tabla 1. Comparación de métricas de clasificación

Modelo	Accuracy	F1-score	AUC
Random Forest	0.779	0.758	0.87
MLP	0.586	0.296	0.675

El modelo Random Forest presentó un mejor rendimiento general y un comportamiento más equilibrado en cuanto a la detección de la clase hotspot, con $\text{recall_hotspot} = 0.74$ y $\text{precision_hotspot} = 0.78$. Por el contrario, el modelo MLP mostró una sensibilidad considerablemente menor y una mayor proporción de falsos negativos, con $\text{recall_hotspot} = 0.20$ y $\text{precision_hotspot} = 0.54$, lo que explica su menor F1-score.

A continuación, en la Figura 2 y 3 se observan las curvas ROC de los dos modelos (RF y MLP), destacando una mayor capacidad discriminativa del modelo Random Forest ($\text{AUC} = 0.87$) en comparación con el modelo MLP ($\text{AUC} = 0.675$).

Figura 2. Curva ROC - Random Forest (hotspot)





Figura 3. Curva ROC - MLP (hotspot)



El mejor desempeño de Random Forest puede explicarse por varias características del conjunto de datos. En primer lugar, el desempeño inferior del MLP puede estar relacionado con su sensibilidad a la configuración de hiperparámetros y arquitectura. En este estudio, se utilizó una arquitectura MLP con dos capas ocultas (16 y 8 neuronas), optimizador Adam, 100 épocas de entrenamiento y regularización L2, lo que proporciona una configuración básica pero no necesariamente óptima para datos tabulares sensoriales.

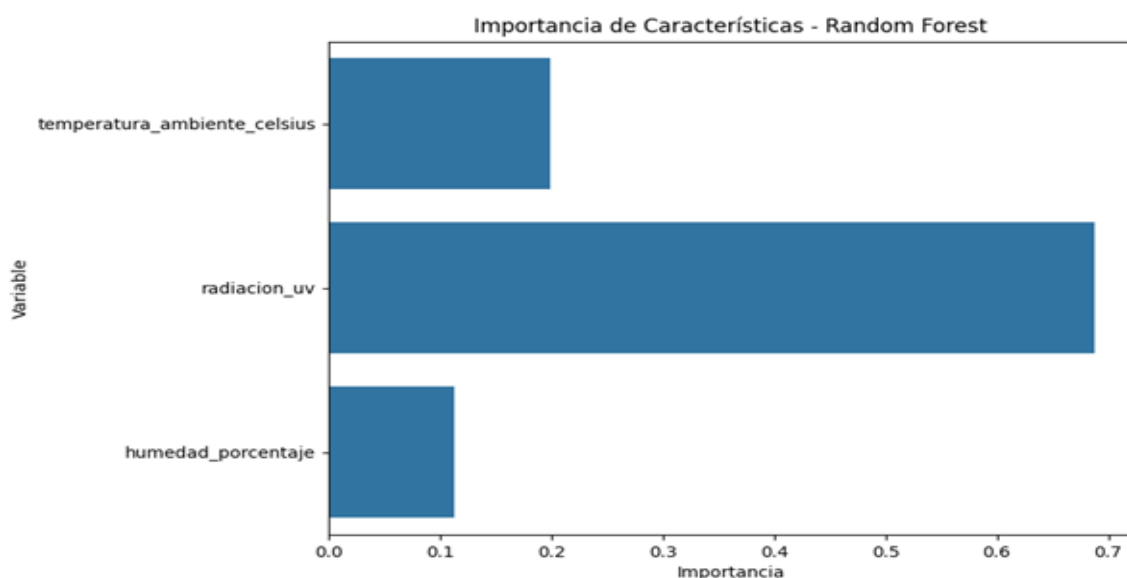
Posteriormente, Random Forest es específicamente macizo ante el ruido en los datos, a relaciones no lineales entre variables y a diferencias de escala, condiciones que se encuentran comúnmente en los registros ambientales obtenidos a partir de sensores. Asimismo, los modelos a partir de árboles se acoplan de mejor manera con los datos tabulares, a diferencia de las redes neuronales que requieren de mayor volumen de datos y adaptaciones arquitectónicas más complejas que ayuden a alcanzar un rendimiento comparable.

Importancia de las variables

Este punto se evaluó bajo el criterio de impureza de Gini, usando el algoritmo Random Forest que ayuda a valorar la contribución de cada variable en el proceso de división de los árboles de decisión.

Bajo este principio, la radiación UV evidenció una mayor contribución en el proceso de clasificación, seguida por la temperatura ambiente, a diferencia de la humedad relativa que mostró menor influencia en la predicción de eventos de sobrecalentamiento (Barrero & Salazar, 2024).

Figura 4. Importancia de Características - Random Forest



Viéndolo desde una perspectiva física, este hallazgo está acorde con el comportamiento térmico de los módulos fotovoltaicos, ya que la radiación solar se comporta como el factor externo principal que desarrolla el calentamiento del panel que coincide con lo expresado por Acici (2025). Sin embargo, para lograr reconfortar la interpretación del modelo, se menciona que para futuros trabajos se podría complementar este análisis bajo el uso de métodos más robustos de interpretabilidad, como permutation importance o SHAP, los cuales facilitan la evaluación de estabilidad del ranking de variables ante correlaciones entre predictores (Herrera, 2022).

Comparación con trabajos previos

Varias investigaciones han utilizado técnicas de inteligencia artificial que ayudan a detectar anomalías térmicas en sistemas fotovoltaicos. Estudios actuales mencionan que los modelos orientados en árboles de decisión y métodos de ensamble muestran mayor estabilidad que redes neuronales tradicionales más aun cuando se emplean múltiples variables ambientales (Castañeda & Jiménez, 2023; Yang & Sun, 2024). Estos hallazgos coinciden con los resultados obtenidos en este estudio, en el que Random Forest superó al modelo MLP en precisión y F1-score (Ramírez & Garrido, 2023; Robayo, 2025; Zhao *et al.*, 2025).

Este comportamiento puede atribuirse a características propias del dataset utilizado. Los modelos Random Forest son capaces de manejar eficazmente relaciones no lineales, ruido en los datos y variables con escalas distintas, condiciones comunes en registros ambientales provenientes de sensores.

Desde la perspectiva latinoamericana, ciertas investigaciones realizadas en Ecuador como el de Castrillón (2022), el cual reconoce a la radiación solar y la temperatura ambiente como variables determinantes en la aparición de anomalías térmicas en sistemas fotovoltaicos, lo que viene a ser consistente con la importancia relativa observada en este trabajo.

Por otro lado, investigaciones que tratan sobre termografía infrarroja de alta resolución suelen exponer exactitudes superiores al 85 %, ya que las imágenes térmicas logran capturar directamente patrones espaciales de calentamiento en los módulos fotovoltaicos (Ramos, 2022; Oyeniyi & Meyer, 2022).

De manera complementaria, la presente investigación incluye datos tabulares provenientes de sensores ambientales, de forma en la que se disminuye el costo operativo y autoriza la implementación de esquemas de monitoreo continuo, aunque con un desempeño condicionado por la definición del umbral térmico y la variabilidad ambiental. Desde esta perspectiva, la exactitud obtenida (77,9 %) se deduce como coherente con investigaciones basadas en el monitoreo con sensores convencionales (Asociación Empresarial Eólica [AEE], 2025).

Limitaciones del estudio

El estudio presenta algunas limitaciones que deben considerarse al interpretar los resultados. En primer lugar, el dataset se basa en dos módulos fotovoltaicos monitorizados entre el 8 de abril de 2024 y el 1 de marzo de 2025, con registros temporales obtenidos en intervalos no uniformes, lo que puede limitar la aplicabilidad del modelo a otros sistemas fotovoltaicos con configuraciones distintas o bajo condiciones climáticas diferentes; por ello, se recomienda realizar validaciones externas en varias instalaciones.

En segundo lugar, el umbral de temperatura de 10 °C empleado para detectar eventos de hotspot incide directamente en la distribución de las clases del conjunto de datos, además si se realizan cambios en este criterio se llegaría a alterar la proporción de registros clasificados como anomalías y, por consiguiente, alterar las métricas de rendimiento del modelo.

Además, el análisis se realizó mediante variables ambientales y térmicas exclusivamente, sin integrar variables eléctricas del módulo fotovoltaico, como corriente o voltaje, misma inclusión que ayudaría a mejorar la capacidad del modelo para reconocer fallos asociados al comportamiento eléctrico del sistema.

Por último, el modelo MLP llegaría a necesitar de un mayor volumen de datos y ajustes adicionales en su arquitectura en donde se logre mejorar su capacidad de aprendizaje. De esta manera en futuros estudios podrían aplicar la orientación para integrar variables electrotérmicas, valorar modelos más robustos como XGBoost o redes profundas, y además verificar el enfoque en múltiples instalaciones fotovoltaicas localizadas en climas tropicales.

CONCLUSIONES

La investigación evaluó el empleo de algoritmos de aprendizaje automático para determinar puntos calientes en sistemas fotovoltaicos bajo el uso de datos térmicos y ambientales obtenidos con sensores. Los hallazgos muestran que este método es viable para garantizar el monitoreo automático de anomalías térmicas en un clima tropical, tomando en cuenta el criterio de etiqueta utilizado.

La exploración descubrió la diferencia térmica entre el panel y el entorno (Δ_{temp}), es decir, que este es un

indicador operativo fundamental para valorar el sobrecalentamiento del módulo, en cuanto a la radiación UV y la temperatura ambiente se relacionan con el comportamiento térmico observado. Al comparar modelos, Random Forest evidenció un rendimiento superior al Perceptrón Multicapa (MLP), teniendo una precisión del 77,9%, puntuación F1 de 0,758 y AUC de 0,87, lo que indica una superior capacidad para captar relaciones no lineales en datos tabulares recogidos por sensores.

De manera conjunta, esta investigación facilita evidencia técnica de forma en la que respalda el uso de modelos de aprendizaje automático bajo el uso de datos sensoriales para controlar sistemas fotovoltaicos en climas tropicales. Asimismo, muestra una metodología que ayuda a priorizar inspecciones y mejorar de alguna manera las estrategias de mantenimiento preventivo, sin tener que reemplazar la verificación técnica en campo.

Agradecimientos

Expreso mi sincero agradecimiento a la Universidad Técnica de Manabí por el apoyo institucional en esta investigación. También a la Facultad de Ingeniería y Ciencias Aplicadas por facilitar el acceso a información, infraestructura y las condiciones necesarias para recoger datos y validar el estudio.

Al docente tutor Ing. Víctor Martínez Falcones, Mg. por su guía y valiosas recomendaciones durante el desarrollo del presente estudio.

Finalmente, agradezco a Dios por brindarme la fortaleza y luz necesaria para culminar mis estudios y de manera muy especial, agradezco a mi mamá Senia Lucia Ureta por su amor incondicional, sus sacrificios y por ser mi mayor inspiración en cada paso que doy. Asimismo agradezco a mi novio Elieser Soliz por su apoyo constante y motivación siendo un pilar fundamental para alcanzar este logro.

Referencias bibliográficas

- Acici, K. (2025). Comparative Analysis of Machine and Deep Learning Algorithms for Bragg Peak Estimation in Polymeric Materials for Tissue-Sparing Radiotherapy. MDPI. <https://www.mdpi.com/2073-4360/17/15/2068>
- Aco, A., & Hanco, B. (2023). Análisis comparativo de Técnicas de Machine Learning para la predicción de casos de deserción universitaria. RISTI-Revista Ibérica de Sistemas e Tecnologias de Informação, (51), 84-98. <https://scielo.pt/pdf/rist/n51/1646-9895-rist-51-84.pdf>
- Adekanbi, M., & Alaba, E. (2024). Soiling loss in solar systems: A review of its effect on solar energy efficiency and mitigation techniques. Cleaner Energy Systems, 7, 100094. <https://www.sciencedirect.com/science/article/pii/S2772783123000444>
- Alonso, J. (2025). ¿Cuáles son las Causas y Efectos de los Puntos Calientes en Placas Solares? SUNFIELDS. <https://www.sfe-solar.com/paneles-solares/puntos-calientes/?srsltid=AfmBOopQhIQ4Lr-JRCAImY15hJGy8mH1lcAvoJB1qwCwwOdMdwH8zSHO>
- Álvarez Contreras, D. E., Díaz Pérez, C. M., & Herazo Morales, R. (2023). Factores académicos asociados al proceso de investigación formativa en las instituciones educativas del sector oficial de Sincelejo, Sucre. Región Científica, 2(1), 202319. <https://doi.org/10.58763/rc202319>
- Asociación Empresarial Eólica [AEE]. (2025). Chile establece récords de energía eólica y fotovoltaica en 2024. Asociación Empresarial Eólica. <https://reve.aeeolica.org/2025/01/13/chile-establece-records-de-energia-eolica-y-fotovoltaica-en-2024/>
- Barrero, M., & Salazar, V. (2024). Efectos biológicos de las radiaciones electromagnéticas: Índice UV y afecciones cutáneas en el cantón Quito. Ciencia Latina Revista Multidisciplinar, 8(4), 7622-7639. <https://www.ciencialatina.org/index.php/cienciala/article/view/12933>
- Carrillo, R. (2024). Inteligencia Artificial en Sistemas Robotizados para el Mantenimiento de Paneles. Repositorio Universidad Rafael Belloso Chacín. <https://dialnet.unirioja.es/descarga/articulo/10307749.pdf>
- Castañeda, D., & Jiménez, D. (2023). Predicción de la radiación solar utilizando redes neuronales para el dimensionamiento de plantas fotovoltaicas en la provincia de Pichincha. Repositorio Universidad Técnica de Cotopaxí. <https://repositorio.utc.edu.ec/items/c1f38176-e74a-4db6-9b52-cffef9843074>
- Castrillón, D. (2022). Detección de puntos calientes en sistemas fotovoltaicos. ITM. <https://repositorio.itm.edu.co/entities/publication/9d22c1c1-14f2-4433-b7d0-9bd90ecbbc10>
- Dhimish, M. (2024). Photovoltaic hotspots: A mitigation technique and its thermal cycle. Optik, 300, 171627. <https://www.sciencedirect.com/science/article/pii/S0030402624000251>
- Domínguez, J. (2025). El Reto de la Inteligencia Artificial ante la Investigación en Ciencias Sociales. Revista Científica Hallazgos21, 10(1), 60-70. <https://revistas.pucese.edu.ec/hallazgos21/article/view/688>

Flores, L., & Vásquez, J. (2025). Modelos matemáticos para predicción del ruido ambiental urbano: revisión crítica 2020-2025. *Revista Alfa*, 9(27), 59-67. <https://revistaalfa.org/index.php/revistaalfa/article/download/544/1212/3530>

Hernandez, A., & Löschenbrand, M. (2022). Una revisión sistemática de técnicas de aprendizaje automático relacionadas con comunidades energéticas locales. *Cuaderno activa*, 13(1), 113-121. <https://www.sciencedirect.com/science/article/pii/S1364032122005433?via%3Dihub>

Herrera, R. (2022). Propuesta de modelo predictivo inteligente para una planta fotovoltaica. Repositorio Universidad de las Ciencias Informáticas. <https://www.redalyc.org/journal/3783/378370413010/html/>

Naranjo, L., & Escudero, A. (2025). Random Forest como herramienta para mejorar la precisión en la imputación de datos meteorológicos en Chimborazo, Ecuador. *Esprint Investigación*, 4(2), 358-375. <https://rei.esprint.tech/index.php/esprint-investigacion/article/view/169>

Oyeniya, A., & Meyer, E. (2022). Solar Photovoltaic Modules' Performance Reliability and Degradation Analysis—A Review. *Energies*, 15(16), 5964. <https://www.mdpi.com/1996-1073/15/16/5964>

Sarián González, M., Bruna Román, C., Robles Lagos, C., & Vaca Lombana, G. (2025). Gestión empresarial de la sostenibilidad, RSE e Inteligencia Artificial. Una nueva frontera en las decisiones. *Región Científica*, 4(1), 2025382. <https://doi.org/10.58763/rc2025382>

Ramírez, E., & Garrido, A. (2023). Effect of temperature on the efficiency of photovoltaic panels. Repositorio Universidad Tecnológica de Tecámac. <https://repository.uaeh.edu.mx/revistas/index.php/icbi/article/download/11841/10933>

Ramos, J. (2022). Análisis de defectos en Paneles Solares de Plantas Fotovoltaicas mediante Termografía y Electroluminiscencia. Repositorio Universidad de Valladolid. <https://uvadoc.uva.es/bitstream/handle/10324/52181/TFG-I-2139.pdf?sequence=1>

Robayo, M. (2025). Análisis comparativo de algoritmos de machine learning aplicados a la predicción de fallas en un motor eléctrico basados en datos sensoriales. Repositorio Universidad Nacional de Chimborazo. <http://dspace.unach.edu.ec/bitstream/51000/15742/1/Robayo%2C%20Mar%C3%ADa%20Cristina%20%282025%29.%20An%C3%A1lisis%20comparativo%20de%20algoritmos%20de%20machine%20learning%20aplicados%20a%20la%20predicci%C3%B3n%20de%20fallas.pdf>

Silvestrini, S., & Lavagna, M. (2022). Deep Learning and Artificial Neural Networks for Spacecraft Dynamics, Navigation and Control. *Drones*, 6(10), 270. <https://www.mdpi.com/2504-446X/6/10/270>

Tirado, V. (2024). Redes Neuronales Artificiales como Modelo de Predicción de los Factores Climáticos en Nicaragua en el Periodo 2021-2022. *Ciencia Latina Revista Científica Multidisciplinar*, 8(1), 1458-1474. <https://ciencialatina.org/index.php/cienciala/article/view/9541>

Yang, C., & Sun, F. (2024). Un estudio de los métodos de superposición de paneles fotovoltaicos y detección de fallos. ResearchGate. https://www.researchgate.net/publication/378111531_A_Survey_of_Photovoltaiic_Panel_Overlay_and_Fault_Detection_Methods

Yaqoob, A., Kumar Verma, N., & Ahmad, M. (2025). SGA-Driven feature selection and random forest classification for enhanced breast cancer diagnosis: A comparative study. *Scientific Reports*, 15(1), 10944. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11955515/>

Yaulillahua, R., & Sumarriva, L. (2025). Sistemas de energía fotovoltaica: Una revisión sistemática. *Revista Alfa*, 9(27), 31-50. <https://revistaalfa.org/index.php/revistaalfa/article/download/542/1208/3526>

Zhao, W., Chen, H., & Murat, D. (2025). Few-shot learning and deep predictive models for cost optimization and carbon emission reduction in energy-water management. *Journal of environmental management*, 389, 126077. <https://www.sciencedirect.com/science/article/pii/S0301479725020535?via%3Dihub>

Declaración de conflicto de intereses: Los autores no presentan ningún conflicto de interés.

Declaración de contribución de los autores/as utilizando la Taxonomía CRediT:

Ambar Cristhina Chancay Ureta: Conceptualización, Metodología, Investigación, Recolección de datos, Análisis de resultados, Discusión y Redacción del borrador original.

Víctor Alfonso Martínez Falcones: Conceptualización, Metodología, Investigación, Recolección de datos, Análisis de resultados, Discusión y Redacción del borrador original.

Declaración de aprobación por el Comité de Ética: Los autores declaran que la investigación fue aprobada por el Comité de Ética de la institución responsable, en tanto la misma implicó a seres humanos.

Declaración de originalidad del manuscrito:

Los autores confirman que este texto no ha sido publicado con anterioridad, ni ha sido enviado a otra revista para su publicación.