

Aplicación de Inteligencia Artificial para el Diagnóstico y Mantenimiento Predictivo en Sistemas Fotovoltaicos

Calixto Gonzalo Rojas Duré, gonzardure@fiuna.edu.py¹, Mathias Aharon Benítez Brozón, mathiasbbrozon@fiuna.edu.py¹

¹Alumno, Facultad de Ingeniería, Universidad Nacional de Asunción, San Lorenzo, Paraguay

Palabras clave: ■ Termografía Infrarroja ■ Detección de Objetos ■ YOLOv26 / YOLOv8 ■ Fallas Fotovoltaicas ■ Mantenimiento Predictivo ■ IEC TS 62446-3 ■ Redes Neuronales Convolucionales	Resumen Este Trabajo Final de Grado analiza y evalúa el uso de inteligencia artificial para el diagnóstico de fallas y el mantenimiento predictivo en sistemas fotovoltaicos a partir de imágenes termográficas. El crecimiento acelerado de la generación solar a nivel mundial, y el desafío energético que enfrenta Paraguay, subrayan la necesidad de métodos de inspección y diagnóstico eficientes que permitan reducir costos de operación y mantenimiento. Se adaptó el <i>dataset</i> público del grupo VRAI (Università Politecnica delle Marche), generado en una planta de 66 MW en Sudáfrica, reetiquetándolo según la taxonomía de la norma IEC TS 62446-3 en seis clases de falla: Circuito Abierto, Diodo, Golpe, PID, Punto Caliente y Sombra. Se entrenaron cuatro variantes de la arquitectura YOLOv26 (Nano, Small, Large, Extra Large) con transferencia de aprendizaje y un pipeline de aumento de datos térmico-específico desarrollado con Albumentations. El mejor modelo (YOLOv26l) alcanzó un mAP₅₀ de 0.8817 y un mAP₅₀₋₉₅ de 0.5687. Los resultados evidencian la viabilidad de usar redes neuronales convolucionales para priorizar inspecciones, detectar anomalías relevantes y complementar la toma de decisiones de mantenimiento predictivo. De forma complementaria, se implementó una aplicación web para consultar inferencias y resultados del modelo, sin constituir el eje central del estudio.
Keywords: ■ Infrared Thermography ■ Object Detection ■ YOLOv26 / YOLOv8 ■ PV Module Faults ■ Predictive Maintenance ■ IEC TS 62446-3 ■ Convolutional Neural Networks	Abstract This Final Degree Project analyzes and evaluates the use of artificial intelligence for fault diagnosis and predictive maintenance in photovoltaic systems based on thermographic images. The rapid growth of solar generation worldwide, and the energy challenge faced by Paraguay, highlight the need for efficient inspection and diagnostic methods to reduce operation and maintenance costs. The public dataset from the VRAI group (Università Politecnica delle Marche), acquired at a 66 MW plant in South Africa, was re-labeled according to the IEC TS 62446-3 taxonomy into six fault classes: Open Circuit, Diode, Physical Damage, PID, Hot Spot, and Shadow. Four variants of the YOLOv26 architecture (Nano, Small, Large, Extra Large) were trained using transfer learning and a thermally-specific data augmentation pipeline built with Albumentations. The best model (YOLOv26l) achieved a mAP₅₀ of 0.8817 and mAP₅₀₋₉₅ of 0.5687. The results show the feasibility of using convolutional neural networks to prioritize inspections, detect relevant anomalies, and support predictive-maintenance decision-making. As a complementary component, a web application was implemented to inspect model inferences and results, without being the central focus of the study.

1. Introducción

A nivel global, la generación fotovoltaica ha experimentado un crecimiento exponencial durante la última década. En Paraguay, las proyecciones indican que la demanda pico superará los 10 000 MW hacia el año 2035 [1], rebasando la capacidad actual de las hidroeléctricas de Itaipú, Yacyretá y Acaray. Esta situación hace estratégica la incorporación y el aprovechamiento eficiente de la energía solar, así como la disponibilidad de herramientas que garanticen su operación confiable [9].

Las instalaciones fotovoltaicas de gran escala requieren monitoreo continuo: un solo módulo defectuoso puede provocar pérdidas de generación de hasta el 20 %. La termografía infrarroja, capturada mediante drones (UAV), permite detectar patrones térmicos anómalos con alta efi-

ciencia espacial, y ha sido ampliamente estudiada como herramienta de mantenimiento predictivo para módulos FV [7, 8]. Combinada con modelos de aprendizaje profundo, esta tecnología posibilita automatizar el diagnóstico y reducir la dependencia de inspecciones manuales costosas [16, 17, 18].

El presente trabajo propone un estudio de análisis de fallas que une termografía infrarroja y la arquitectura de detección YOLOv26 para automatizar la identificación de las seis categorías de falla más relevantes en sistemas fotovoltaicos, conforme a la norma IEC TS 62446-3 [2].

2. Objetivo General

Diseñar e implementar un sistema inteligente, basado en CNN (*Convolutional Neural Network*), para el diagnóstico

automatizado de fallas en sistemas fotovoltaicos.

3. Objetivos Específicos

- Caracterizar los tipos de anomalías comunes en módulos fotovoltaicos.
- Preparar el *dataset* termográfico recolectado mediante verificación normativa, reetiquetado de clases y balanceo de muestras.
- Entrenar un modelo de detección mediante transferencia de aprendizaje.
- Cuantificar el desempeño del modelo mediante métricas de detección.
- Comparar el desempeño de las variantes YOLOv26 en-
trenadas.

4. Marco Teórico

4.1 Termografía Infrarroja en Sistemas FV

La termografía infrarroja detecta diferencias de temperatura (ΔT) en la superficie de los módulos FV originadas por defectos eléctricos, físicos o ambientales. La norma IEC TS 62446-3 [2] define criterios de ΔT y Clase de Anomalia (CoA) para clasificar la severidad de cada patrón térmico en módulos cristalinos. Esta base normativa se complementa con estudios de fallas recurrentes en módulos FV, donde se reportan defectos de interconexión, diodos, sombreado, PID y daño físico como causas frecuentes de degradación operacional [7, 8].

4.2 Fallas Fotovoltaicas y Criterios Normativos

La Tabla 1 sintetiza las seis clases de falla adoptadas en este trabajo conforme a la norma IEC TS 62446-3, incluyendo el ΔT típico y la CoA correspondiente.

Tabla 1. Clases de falla según IEC TS 62446-3.

Clase	ΔT (K)	CoA	Descripción breve
Circ. Abierto	4–6	2	Calentamiento homogéneo por interrupción eléctrica.
Diodo	variable	2–3	Activación del diodo <i>bypass</i> por fallo en substring.
Golpe	variable	3	Daño físico del vidrio; afecta aislamiento.
PID	2–7	2	Patrón extendido por degradación por potencial inducido.
Punto Caliente	10–40+	2–3	Temperatura elevada en celda individual.
Sombra	variable	1–2	Oclusión parcial por suciedad u objetos.

Fuente: [2].

Las clases con ΔT elevado y localizado (Punto Caliente, Golpe) presentan firmas térmicas más diferenciadas, mientras que Circuito Abierto y PID exhiben patrones ex-

tendidos con mayor solapamiento mutuo, lo que repercute directamente en las métricas de clasificación [8].

4.3 Arquitectura YOLOv26

YOLOv26 (*You Only Look Once*, versión 26) realiza detección en una única pasada, prediciendo simultáneamente posición y clase de las anomalías mediante *bounding boxes* [11, 13]. Este enfoque es idóneo para inspección masiva desde UAV por su alta velocidad de inferencia, una característica señalada de forma consistente en revisiones recientes de la familia YOLO [12]. La familia incluye cinco escalas; la Tabla 2 resume los parámetros clave y tiempos de inferencia de referencia.

Tabla 2. Variantes YOLOv26 (COCO, 640 px).

Modelo	mAP _{50–95}	CPU (ms)	T4 TRT (ms)	Params (M)	GFLOPs
YOLOv26n	40.9	38.9	1.7	2.4	5.4
YOLOv26s	48.6	87.2	2.5	9.5	20.7
YOLOv26m	53.1	220.0	4.7	20.4	68.2
YOLOv26l	55.0	286.2	6.2	24.8	86.4
YOLOv26x	57.5	525.8	11.8	55.7	193.9

Fuente: [11].

5. Metodología

La Figura 1 resume el flujo metodológico seguido, desde la preparación del conjunto de datos hasta la evaluación del modelo y la validación cualitativa con imágenes reales.

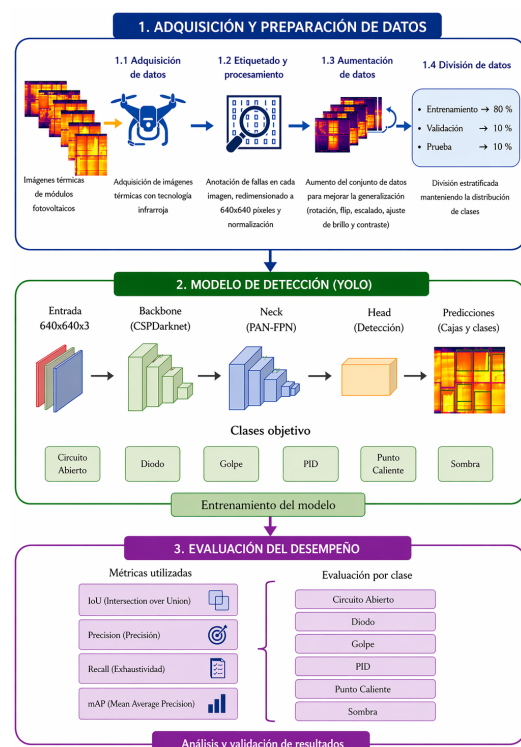


Figura 1. Flujo de trabajo metodológico. Fuente: Elaboración propia.

5.1 Dataset Base

Se empleó el *dataset* del grupo VRAI (Università Politecnica delle Marche), adquirido en la planta fotovoltaica de 66 MW de Tom Burke, Sudáfrica (21–27 enero 2019), bajo

alta irradiancia y cielo despejado [16]. Las anotaciones originales son máscaras binarias de segmentación, convertidas a *bounding boxes* en formato YOLO mediante extracción del rectángulo envolvente mínimo sobre las regiones conectadas. La Figura 2 muestra la planta fotovoltaica de origen del conjunto de datos.



Figura 2. Planta fotovoltaica Tom Burke, Sudáfrica (66 MW). **Fuente:** [15].

El *dataset* VRAI no está disponible para descarga directa; su acceso requiere formulario de solicitud y acuerdo de uso académico firmado con el grupo VRAI. Contiene 3062 imágenes térmicas con anotaciones validadas mediante el software ThermoViewer.

5.2 Reetiquetado según IEC TS 62446-3

El *dataset* fue reetiquetado manualmente en Roboflow, asignando cada imagen a una de las seis clases de falla definidas en la norma (Tabla 1), descartando patrones ambiguos para reducir ruido en las etiquetas. La Figura 3 ilustra este proceso de etiquetado.




Figura 3. Etiquetado en Roboflow conforme a IEC TS 62446-3. **Fuente:** Elaboración propia.

5.3 Balanceo y Aumento de Datos

El *dataset* base presentaba fuerte desequilibrio, dominado por la clase Punto Caliente. Se definieron objetivos de instancias por clase (Tabla 3) y se implementó un pipeline de aumento de datos (*data augmentation*) offline con Albumentations, diseñado específicamente para imágenes térmicas.

Tabla 3. Instancias objetivo de entrenamiento por clase.

Clase	Instancias objetivo
Circuito Abierto	1 800
Diodo	2 200
Golpe	1 800
PID	1 800
Punto Caliente	8 500
Sombra	2 600

Fuente: Elaboración propia.

Las transformaciones del pipeline offline incluyeron: *flip* horizontal/vertical, afines suaves ($\pm 7\%$ escala, $\pm 10^\circ$ rotación, $\pm 4\%$ traslación), ajuste de brillo/contraste ($\pm 8\%$), CLAHE (*clip limit* 2.0), ruido gaussiano del sensor IR ($\sigma \in [5, 25]$ DN) y *CoarseDropout* para simular obstrucciones parciales. Las transformaciones de tono HSV se desactivaron completamente, dado que en imágenes térmicas el tono corresponde al mapa de color y no a información física real. La selección de candidatos usa puntaje ponderado que penaliza la co-aumentación accidental de la clase Punto Caliente, garantizando diversidad controlada en el conjunto sintético.

5.4 Configuración de Entrenamiento

Se entrenaron las cuatro variantes YOLOv26 con los siguientes hiperparámetros comunes: optimizador AdamW ($lr_0 = 0,001$), decaimiento coseno, *warmup* de 5 épocas, 150 épocas máximas con *early stopping* (*patience* = 30) y pesos COCO preentrenados como punto de partida. La resolución de entrada fue de 640 px. Las variantes Large y XL emplearon *batch* fijo de 10 por restricciones de memoria GPU; Nano y Small usaron *batch* automático calculado al 60 % de utilización.

5.5 Implementación Web Complementaria

Como apoyo a la revisión de resultados, se implementó una aplicación web cliente-servidor con backend FastAPI y frontend React. Esta implementación permite cargar imágenes termográficas, ejecutar inferencia con el modelo entrenado y visualizar las detecciones; se presenta como componente auxiliar del estudio, no como objetivo central de la tesis. La Figura 4 muestra la arquitectura general de esta implementación complementaria.




Figura 4. Arquitectura cliente-servidor de la aplicación web. **Fuente:** Elaboración propia.

6. Resultados

6.1 Resultados Globales de Detección

La Tabla 4 resume los indicadores clave de las cuatro configuraciones entrenadas, obtenidos en la mejor época de validación (*best.pt*).

Tabla 4. Comparación de configuraciones (mejor época de validación).

Modelo	Época	mAP ₅₀₋₉₅	mAP ₅₀	Prec.	Recall	MB
Nano	95	0.5387	0.8388	0.855	0.819	5.2
Small	150	0.5588	0.8551	0.875	0.855	19.4
Large	96	0.5687	0.8817	0.897	0.833	50.5
XL	136	0.5612	0.8540	0.852	0.842	112.9

Fuente: Elaboración propia.

El modelo **YOLOv26l (Large)** obtuvo el mejor desempeño global ($mAP_{50} = 0.8817$, precisión = 0.8971). El modelo **Small** presentó el mejor *recall* (0.8546) y la relación más favorable entre desempeño y tamaño de archivo, convirtiéndolo en la opción preferida para despliegue en recursos limitados. El modelo XL no justificó su mayor costo computacional frente a Large y Small; el salto de Nano a Small produjo la ganancia proporcional más significativa. La Figura 5 presenta las curvas de entrenamiento y validación del modelo Large.




Figura 5. Curvas de entrenamiento y validación del modelo YOLOv26l. Fuente: Elaboración propia.

6.2 Resultados por Clase

La Tabla 5 presenta el *recall* por clase, y la Figura 6 complementa esta lectura con la matriz de confusión normalizada del mejor modelo.

Tabla 5. *Recall* por clase en la mejor época de validación.

Clase	Nano	Small	Large	XL
Circuito Abierto	0.61	0.70	0.74	0.65
Diodo	0.85	0.88	0.90	0.90
Golpe	0.89	0.95	0.95	0.92
PID	0.81	0.81	0.81	0.81
Punto Caliente	0.88	0.90	0.91	0.90
Sombra	0.92	0.92	0.91	0.94

Fuente: Elaboración propia.

Las clases **Golpe**, **Diodo**, **Punto Caliente** y **Sombra** mostraron $recall \geq 0.85$ en todos los modelos, indicando firmas térmicas bien diferenciadas. **Circuito Abierto** fue la clase más difícil (0.61–0.74) por solapamiento térmico con PID, conforme se observa en la diagonal de la Figura 6. **PID** mantuvo un desempeño estable de 0.81 en las cuatro variantes, lo que sugiere que la limitación radica en la variabilidad intrínseca de su firma térmica y no en la capacidad del

modelo. La mayor proporción de falsas detecciones sobre fondo (*background*) se concentró en Punto Caliente, lo que justifica calibrar cuidadosamente el umbral de confianza en aplicaciones reales.




Figura 6. Matriz de confusión normalizada del modelo YOLOv26l. Fuente: Elaboración propia.

6.3 Interfaz Web Complementaria

La aplicación web complementaria integra el flujo de revisión de resultados: carga de imagen (JPG, PNG, TIFF), ajuste interactivo de umbrales (confianza, IoU), inferencia sobre YOLOv26, visualización de *bounding boxes* anotados y consulta de severidad y acción sugerida para cada clase. La Tabla 6 sintetiza estos criterios. La comunicación entre el frontend React y el backend FastAPI se realiza mediante API REST, permitiendo intercambiar los pesos del modelo sin modificar la interfaz.

Tabla 6. Severidad y acción recomendada por clase de falla.

Clase	Sever.	Acción recomendada
Circ. Abierto	Media	Verificar conectores y fusibles; medir curva I-V.
Punto Caliente	Alta	Limpiar o reemplazar módulo; medir I-V.
Diodo	Alta	Medir voltaje por <i>string</i> ; reemplazar caja si hay cortocircuito.
PID	Media	Polarización inversa; revisar puesta a tierra; evaluar inversores anti-PID.
Sombra	Media	Eliminar fuente de sombra; evaluar optimizadores de potencia.
Golpe	Crítica	Documentar y reemplazar módulo dañado.

Fuente: Elaboración propia.

Las Figuras 7 y 8 muestran, respectivamente, la pantalla principal con imagen cargada, la salida de detección con *bounding boxes* y el panel de configuración de umbrales disponible en la interfaz.




Figura 7. Pantalla principal de la aplicación web con imagen termográfica cargada y detecciones activas. **Fuente:** Elaboración propia.




Figura 8. Panel de resultados con *bounding boxes*, clase, confianza y recomendaciones de mantenimiento. **Fuente:** Elaboración propia.

7. Validación en Campo

Se realizó una prueba de campo en una instalación fotovoltaica residencial en San Bernardino, Paraguay. Las termografías mostraron patrones térmicos extendidos compatibles con PID y zonas con indicios de Circuito Abierto. El propietario reportaba que el sistema dejaba de operar en días de lluvia y se activaban las protecciones eléctricas, conducta consistente con fuga a tierra por degradación del aislamiento asociada a PID. La verificación técnica en campo confirmó esta hipótesis, validando la capacidad del sistema para apoyar decisiones de mantenimiento correctivo en condiciones reales. La Figura 9 muestra una de las termografías usadas en esta validación de campo.




Figura 9. Termografía de la instalación en San Bernardino con detecciones PID y Circuito Abierto. **Fuente:** Elaboración propia.

Adicionalmente, se realizó validación cualitativa con imágenes propias obtenidas en el Laboratorio de Energías Renovables de FIUNA, donde el modelo identificó correctamente patrones de Punto Caliente y Sombra en módulos disponibles para prácticas, como se observa en la Figura 10.




Figura 10. Validación cualitativa en el Laboratorio de Energías Renovables FIUNA. **Fuente:** Elaboración propia.

Ambas pruebas de campo confirmaron la capacidad de generalización del modelo ante condiciones de captura no representadas en el *dataset* de entrenamiento: distintas geometrías de montaje, resolución efectiva, contraste térmico variable y nivel de suciedad superficial.

8. Conclusiones

Se desarrolló e implementó una metodología de detección automática de anomalías térmicas en módulos fotovoltaicos mediante visión por computadora y aprendizaje profundo, basada en modelos YOLOv26 aplicados a imágenes termográficas del grupo VRAI.

Caracterización de anomalías. Se caracterizaron las seis clases de falla conforme a la norma IEC TS 62446-3: Circuito Abierto, Diodo, Golpe, PID, Punto Caliente y Sombra. Golpe, Diodo, Punto Caliente y Sombra presentan firmas térmicas más distinguibles, mientras que Circuito Abierto y PID concentran la mayor dificultad de separación.

Preparación del dataset. Se preparó el *dataset* termográfico mediante verificación normativa, reetiquetado de clases en Roboflow, conversión al formato YOLO y balanceo de muestras con pipeline de aumento térmico-específico (Albumentations). Este proceso favoreció un entrenamiento estable entre variantes de modelo.

Entrenamiento. Se entrenaron cuatro variantes de YOLOv26 (Nano, Small, Large, Extra Large) con transferencia de aprendizaje a partir de pesos COCO. El enfoque permitió converger efectivamente sobre un problema específico con cantidad limitada de datos especializados.

Desempeño del detector. Todas las configuraciones alcanzaron mAP_{50} superiores a 0.83 (0.8388–0.8817). El mejor resultado global correspondió al modelo YOLOv26l ($mAP_{50} = 0.8817$, precisión = 0.8971), mientras que YOLOv26s obtuvo el mejor *recall* global (0.8546). Estos resultados validan la viabilidad del sistema para inspección automatizada.

Comparación de variantes. El aumento del tamaño de la red no garantiza mejoras proporcionales. La variante **Large** obtuvo la mejor exactitud global; **Small** presentó la relación más favorable entre desempeño y costo computacional.

para despliegues con recursos limitados. El modelo XL no superó de manera concluyente a Large a pesar de triplicar el tamaño de pesos.

Recomendaciones y Trabajos Futuros

- Ampliar el *dataset* con imágenes de distintas instalaciones fotovoltaicas bajo diversas condiciones ambientales y operativas.
- Explorar modelos de segmentación semántica o de instancias para delimitar con mayor precisión las regiones defectuosas.
- Investigar estrategias avanzadas de aumento de datos y ajuste fino de hiperparámetros para reducir la necesidad de grandes volúmenes etiquetados.
- Desarrollar un sistema completo de inspección que integre adquisición UAV, procesamiento mediante IA y generación automática de reportes de diagnóstico.
- Evaluar la implementación en entornos de monitoreo continuo dentro de plantas fotovoltaicas reales, integrando el sistema con plataformas de gestión de activos.

Referencias

- [1] Administración Nacional de Electricidad (ANDE), *Plan Maestro de Generación del Sistema Eléctrico Paraguay 2024–2043*, Asunción, Paraguay, 2024.
- [2] IEC, *IEC TS 62446-3: Photovoltaic (PV) Systems — Requirements for Testing, Documentation and Maintenance — Part 3: Photovoltaic Modules and Plants — Outdoor Infrared Thermography*, edición vigente.
- [3] IEC, *IEC 61215: Crystalline silicon terrestrial photovoltaic modules*, International Electrotechnical Commission, 2021.
- [4] J. Nelson, *The Physics of Solar Cells*, Imperial College Press, 2003.
- [5] R. Messenger y J. Ventre, *Photovoltaic Systems Engineering*, CRC Press, 2010.
- [6] A. Luque y S. Hegedus, *Handbook of Photovoltaic Science and Engineering*, 2.a ed., Wiley, 2011.
- [7] M. Köntges *et al.*, *Review of Failures of Photovoltaic Modules*, IEA Photovoltaic Power Systems Programme, IEA-PVPS T13-01:2014, 2014.
- [8] J. A. Tsanakas, L. Ha y C. Buerhop, "Faults and infrared thermographic diagnosis in operating c-Si photovoltaic modules: A review of research and future challenges," *Renewable and Sustainable Energy Reviews*, vol. 62, pp. 695–709, 2016.
- [9] D. C. Jordan *et al.*, "Photovoltaic degradation rates — an analytical review," *Progress in Photovoltaics: Research and Applications*, vol. 30, n.º 1, pp. 3–19, 2022.
- [10] B. Basnet, H. Chun y J. Bang, "An Intelligent Fault Detection Model for Photovoltaic Systems," *Journal of Sensors*, vol. 2020, art. 6960328, 2020.
- [11] G. Jocher, A. Chaurasia y J. Qiu, "Ultralytics YOLO," 2026. [En línea]. Disponible: <https://github.com/ultralytics/ultralytics>
- [12] J. Terven *et al.*, "A comprehensive review of YOLO architectures," *Machine Learning and Knowledge Extraction*, vol. 5, n.º 4, 2023.
- [13] P. Hidayatullah y R. Tubagus, "YOLO26: A Comprehensive Architecture Overview and Key Improvements," arXiv:2602.14582, 2026.
- [14] L. Alzubaidi *et al.*, "Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *Journal of Big Data*, vol. 8, art. 53, 2021.
- [15] Enel Green Power, "Tom Burke Solar Plant," disponible en línea.
- [16] R. Pierdicca, M. Paolanti, A. Felicetti, F. Piccinini y P. Zingaretti, "Automatic Faults Detection of Photovoltaic Farms: solAIr, a Deep Learning-Based System for Thermal Images," *Energies*, vol. 13, n.º 24, art. 6496, 2020.
- [17] A. Ghahremani, S. D. Adams, M. Norton, S. Y. Khoo y A. Z. Kouzani, "Detecting Defects in Solar Panels Using the YOLO v10 and v11 Algorithms," *Electronics*, vol. 14, n.º 2, art. 344, 2025.
- [18] M. Shamisavi, I. Segovia Ramirez y C. Q. Gómez Muñoz, "Comparative Evaluation of YOLO- and Transformer-Based Models for Photovoltaic Fault Detection Using Thermal Imagery," *Energies*, vol. 19, n.º 3, art. 845, 2026.
- [19] A. Et-taleby, Y. Chaibi, N. Ayadi, B. Elkari, M. Benslimane y Z. Chalh, "Enhancing fault detection and classification in photovoltaic systems based on a hybrid approach using fuzzy logic algorithm and thermal image processing," *Scientific African*, vol. 28, art. e02684, 2025.