

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Mecánica y Ciencias de la Producción

Análisis de ciclo de vida de paneles solares con IA y visión para detectar fallas

INGE-3013

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Mecatrónica

Presentado por:

Emilio Esteban Guerrero Columbus

Marco Vinicio Jr Sarmiento Añazco

Guayaquil - Ecuador

Año: 2025

Dedicatoria

Dedico este proyecto a mi familia, que han sido mi apoyo incondicional en toda la trayectoria de mi carrera y desarrollo académico. A todos mis abuelos que me acompañaron desde mi primer día de clases y vieron el fruto de su crianza en cada victoria ganada a través de mi carrera. A mi compañero de tesis y mejor amigo, Marco Sarmiento por ser un apoyo incondicional y ayudarme a crecer como profesional y como persona. A mi profesor de laboratorio Dr. Edwin Valarezo, quien me introdujo al mundo de la investigación e inteligencia artificial. En especial, a mis padres le dedico este proyecto y todos mis éxitos, por siempre confiar en mí y brindándome enseñanzas y valores para enfrentarme al mundo.

Emilio Guerrero C.

Dedicatoria

Este proyecto lo dedico a mi familia, quienes confiaron en mí desde el primer momento, me brindaron su apoyo y sobre todo su amor. A mi padre, Marco Sarmiento Pérez, por ser mi superhéroe favorito, por inculcarme el conocimiento y la dicha de la curiosidad. A mis hermanos, Guillermo y José, por ser pilares fundamentales de mi desempeño. A mi hermana Domenica, por enseñarme carácter y paciencia y amor. A mi tía Irven, porque fue una segunda madre para mí en este proceso universitario. A mi compañero de tesis y mejor amigo, Emilio Guerrero, por apoyarme en cada momento universitario, enseñándome la importancia de la hermandad.

A ti, madre mía, Verónica Añezco, por ser mi pilar y darme tu apoyo incondicional, ser símbolo de paz y resiliencia en mi vida. Sin ti no soy nada y es por ti que lo doy todo día a día, te amo.

Marco Sarmiento Añezco

Agradecimientos

Agradezco a Dios, por ser mi guía y luz en los momentos más difíciles, otorgándome la fuerza para culminar mi etapa universitaria.

A mi familia, que me brindaron siempre atención y apoyo en cada paso que daba, permitiéndome cumplir mis deseos y metas.

A mis amigos Marco Sarmiento, Daniela Espin y Nahin Martínez, con quienes he compartido risas, proyectos y momentos especiales, haciendo de esta experiencia universitaria única y nostálgica.

Al Dr. Edwin Valarezo por sus consejos y enseñanzas en el ámbito investigativo, enseñándome que no existen barreras para aprender nuevas cosas.

A mi tutor de materia integradora, Dr. Javier Urquizo, por confiar en nuestra capacidad y conocimientos para desarrollar el presente proyecto.

Emilio Guerrero C.

Agradecimientos

Agradezco a Dios por haberme guiado y protegido en mi etapa universitaria.

A mi familia por protegerme y velar por mí, por apoyarme en cada decisión e impulsarme hacia lo más alto, permitiéndome cumplir mis objetivos.

A mis amigos, quienes me hicieron sentir en casa a pesar de estar lejos de ella.

A Otto Bermúdez, por darme la oportunidad de desenvolverme y crecer profesionalmente, por aconsejarme y darme una nueva perspectiva de la vida profesional.

A Javier Urquiza, por permitirnos formar parte de este proyecto, dándonos su apoyo y resguardo, depositando su confianza y permitiéndonos involucrarnos con otras entidades.

Marco Sarmiento Añazco

Declaración Expresa

Nosotros Emilio Esteban Guerrero Columbus y Marco Vinicio Jr. Sarmiento Añezco acordamos y reconocemos que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá a los autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique los autores que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 17 de octubre del 2025.



Emilio Esteban Guerrero
Columbus



Marco Vinicio Jr. Sarmiento
Añezco

Evaluadores

Dr. Jorge Hurel

Dr. Javier Urquizo

RESUMEN

Las fallas térmicas, físicas y eléctricas aceleran la degradación de la vida útil de los paneles solares, al punto de comprometen su función de generación energética y a su vez la inversión puesta en el sistema fotovoltaico. Ante esta necesidad, la investigación desarrolló y validó un prototipo embebido orientado a monitoreo del ciclo de vida, capaz de detectar fallas externas e internas con trazabilidad y visualización inmediata. Se implementó una arquitectura en NVIDIA Jetson Xavier NX que ejecutó modelos de inteligencia artificial y presentó resultados con una interacción en un panel web local. En fallas externas, el sistema integró un modelo térmico para detección de puntos calientes y un modelo visual multiclase para identificar fisuras, superficie cubierta, acumulación de polvo y estado normal, donde se registró precisiones del 90 % en fisuras y del 84 % en la clase normal, y comportamiento intermedio en cobertura y polvo. Para fallas internas se compararon “Random Forest” y Potenciación por Gradiente, seleccionándose esta última por ofrecer predicciones más consistentes, alcanzando precisiones usando la métrica R^2 de 0,9997 y un error medio MAE de 117,65 W, que refleja el impacto de errores puntuales mayores. La solución incorporó reportes por inspección y almacenamiento en nube de servicios de Amazon web usando AWS S3 organizado por usuarios y plantas, con identificadores anonimizados y un archivo de estado que se actualizó ante cambios en la plataforma. Adicionalmente, se diseñó e imprimió una carcasa impresa en PETG que facilitó la protección, el orden interno y la ventilación del equipo. Finalmente, el prototipo se validó en campo mediante adquisición de datos con dron, demostrando viabilidad técnica como herramienta replicable para diagnóstico y mantenimiento en instalaciones fotovoltaicas.

Palabras Clave: sistemas fotovoltaicos, inteligencia artificial, fallas, monitoreo, embebido.

ABSTRACT

Thermal, physical, and electrical failures accelerate the degradation of solar panels' useful life, to the point of compromising their energy generation function and, in turn, the investment made in the photovoltaic system. In response to this need, the research developed and validated an embedded prototype aimed at monitoring the life cycle, capable of detecting external and internal failures with traceability and immediate visualization. An architecture was implemented on NVIDIA Jetson Xavier NX that ran artificial intelligence models and presented results with interaction on a local web panel. For external faults, the system integrated a thermal model for detecting hot spots and a multi-class visual model for identifying cracks, surface coverage, dust accumulation and normal status, where accuracies of 90% were recorded for cracks and 84% for the normal class, with intermediate performance for coverage and dust. For internal faults, Random Forest and Gradient Boosting were compared, with the latter being selected for offering more consistent predictions, achieving accuracies using the R^2 metric of 0.9997 and an average MAE error of 117.65 W, reflecting the impact of larger point errors. The solution incorporated inspection reports and cloud storage of Amazon web services using AWS S3 organized by users and plants, with anonymized identifiers and a status file that was updated when changes were made to the platform. In addition, a PETG printed casing was designed and printed to facilitate protection, internal organization and ventilation of the equipment. Finally, the prototype was validated in the field through data acquisition with a drone, demonstrating technical feasibility as a replicable tool for diagnosis and maintenance in photovoltaic installations.

Keywords: photovoltaic system, artificial intelligence, failures, monitoring, embedded.

Índice general

Resumen	I
Abstract	II
Índice general	III
Abreviaturas	VI
Índice de figuras	VII
Índice de tablas	VIII
1 Capítulo 1	1
1.1 Introducción	2
1.2 Descripción del Problema.....	3
1.3 Justificación del problema	4
1.4 Objetivos.....	5
1.4.1 Objetivo general.....	5
1.4.2 Objetivos específicos	5
1.5 Marco teórico.....	6
1.5.1 Estructura y características de paneles solares monocristalinos.....	6
1.5.2 Vida útil y fallas comunes en módulos fotovoltaicos.	6
1.5.3 Aplicación de inteligencia artificial para la detección de fallas	10
1.5.4 Arquitectura del modelo YOLOV5.....	11
1.5.5 Implementación de YOLOV5 en detección de fallas físicas y superficiales en módulos fotovoltaicos.....	13
1.5.6 Aplicación de Modelos de Regresión en el Análisis de Datos de Dataloggers Fotovoltaicos	13
2 Capítulo 2	15
2.1 Metodología.....	16
2.2 Formulación de alternativas de solución	16

2.3	Evaluación y selección de alternativas	19
2.3.1	Principios de solución y criterios de evaluación	19
2.3.2	Matriz de evaluación: subsistema de procesamiento e inferencia de IA	21
2.3.3	Matriz de evaluación: subsistema de adquisición de imágenes.....	21
2.3.4	Matriz de evaluación: subsistema de adquisición y gestión de datos eléctricos	22
2.3.5	Matriz de evaluación: subsistema de visualización y acceso a la información	22
2.4	Diseño del prototipo.....	22
2.5	Diseño conceptual	23
2.6	Requerimientos de Diseño	24
2.6.1	Requerimientos generales del sistema	25
2.6.2	Requerimientos de operación	25
2.7	Diseño electrónico	26
2.7.1	Estructura general del sistema electrónico	26
2.7.2	Características del sistema	26
2.8	Diseño mecánico	27
2.8.1	Parámetros de impresión y comparativa de material	28
2.9	Diseño del sistema de control.....	29
2.9.1	Adquisición de datos para entrenamiento	29
	Entrenamiento y validación de los modelos	30
3	Capítulo 3	32
3.1	Resultados y análisis.....	33
3.2	Resultados del sistema de control.....	33
3.2.1	Evaluación del modelo de visión artificial para detección de falla por puntos calientes	33
3.2.2	Evaluación del modelo de visión artificial para fallas visibles externas..	35

3.2.3	Resultados del modelo de fallas internas mediante potenciación por gradiente	38
3.2.4	Interfaz de usuario y experiencia de operación	40
3.2.5	Almacenamiento y trazabilidad de resultados	43
3.3	Resultados del diseño mecánico del prototipo	44
3.3.1	Justificación y consideraciones de seguridad del ensamble	44
3.3.2	Modelado CAD y visualización del diseño	45
3.3.3	Integración de los componentes electrónicos	46
3.4	Resultados del diseño electrónico y señalización del sistema	47
3.4.1	Desarrollo de la placa e integración con la Jetson	47
3.5	Condiciones de prueba y validación en campo	48
3.6	Análisis de Costos	49
4	Capítulo 4	52
4.1	Conclusiones y recomendaciones	53
4.1.1	Conclusiones	53
4.1.2	Recomendaciones	54
	Referencias	55

Abreviaturas

ARCERNNR	Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables
CENACE	Operador Nacional de Electricidad
CNN	Redes Neuronales de Propagación (Convolutional Neural Network)
DL	Deep Learning
ESPOL	Escuela Superior Politécnica del Litoral
EVA	Encapsulante Acetato de Etileno-Vinilo
IA	Inteligencia Artificial
ML	Machine Learning

Índice de figuras

Figura 1.1 <i>Falla por punto caliente (Hotspot) [11]</i>	7
Figura 1.2 <i>Falla en panel solar por fractura y microfracturas [16]</i>	9
Figura 1.3 <i>Estructura computacional del modelo YOLOV5 [25]</i>	12
Figura 2.1 <i>Diagrama de flujo del proceso de diseño del prototipo</i>	23
Figura 2.2 <i>Ilustración del prototipo propuesto</i>	24
Figura 2.3 <i>Diagrama de conexión de la Jetson Xavier NX</i>	27
Figura 2.4 <i>Prototipo impreso en el entorno de diseño 3D de BambuLab</i>	28
Figura 2.5 <i>Entorno de edición y etiquetado de imágenes de Roboflow</i>	29
Figura 2.6 <i>Imágenes de paneles capturadas de bodega del cliente</i>	30
Figura 2.7 <i>Entorno de entrenamiento local del modelo YOLOV5</i>	31
Figura 2.8 <i>Entrenamiento del modelo Gradient Boosting en Google Collab</i>	31
Figura 3.1 <i>Curvas de entrenamiento para puntos calientes</i>	34
Figura 3.2 <i>Matriz de Confusión Normalizada para puntos calientes</i>	35
Figura 3.3 <i>Curvas de entrenamiento para fallas visibles externas</i>	36
Figura 3.4 <i>Matriz de Confusión Normalizada para fallas visibles externas</i>	37
Figura 3.5 <i>Potencia estimada vs potencia real</i>	38
Figura 3.6 <i>Distribución de errores</i>	39
Figura 3.7 <i>Inicio de sesión</i>	40
Figura 3.8 <i>Pantalla principal</i>	41
Figura 3.9 <i>Entorno de fallas visuales</i>	42
Figura 3.10 <i>Entorno de fallas internas</i>	43
Figura 3.11 <i>Repositorio AWS S3</i>	44
Figura 3.12 <i>Cobertura Jetson Xavier NX</i>	45
Figura 3.13 <i>Impresión 3D cobertura Jetson Xavier NX</i>	46
Figura 3.14 <i>Integración del sistema embebido</i>	47
Figura 3.15 <i>Adquisición de imágenes</i>	48
Figura 3.16 <i>Paneles dañados</i>	49

Índice de tablas

Tabla 2.1 <i>Matriz de evaluación: subsistema de procesamiento e inferencia de IA</i>	21
Tabla 2.2 <i>Matriz de evaluación: subsistema de adquisición de imágenes</i>	21
Tabla 2.3 <i>Matriz de evaluación: subsistema de adquisición y gestión de datos eléctricos</i>	22
Tabla 2.4 <i>Matriz de evaluación: subsistema de visualización y acceso a la información</i>	22
Tabla 2.5 <i>Tabla de los requerimientos de operación del prototipo</i>	25
Tabla 2.6 <i>Parámetros de impresión 3D</i>	28
Tabla 3.1 <i>Desempeño de los modelos</i>	39
Tabla 3.2 <i>Costos de Materiales Electrónicos</i>	49
Tabla 3.3 <i>Materiales de Impresión</i>	49
Tabla 3.4 <i>Mano de obra</i>	49
Tabla 3.5 <i>Servicios y alquileres</i>	50
Tabla 3.6 <i>Procesos de fabricación</i>	50
Tabla 3.7 <i>Servicios en la nube</i>	50
Tabla 3.8 <i>Inversión de proyecto total</i>	51

Capítulo 1

1.1 Introducción

El sector energético de Ecuador, aunque históricamente basado en su capacidad hidroeléctrica, enfrenta un desafío importante: diversificar su matriz energética. La crisis energética provocada por las sequías en 2024, reportada por el Operador Nacional de Electricidad (CENACE), mostró lo vulnerable que es depender solo de fuentes de agua [1]. En este contexto, la generación de energía solar fotovoltaica surge como una opción confiable y con mucho potencial. Sin embargo, su uso todavía es pequeño; según la Agencia de Regulación y Control (ARCERNNR), en 2024 la energía solar solo representó el 0.11% del total consumido [2]. Este porcentaje muy bajo, en comparación con los grandes proyectos en marcha (como 'El Aromo' de 200 MW), resalta la necesidad urgente: no solo hay que instalar paneles solares, sino también asegurarse de que sean eficientes y duren mucho tiempo. Esto es importante para empresas como Vatio Pico S. A., que buscan mantener su energía estable en climas difíciles como el de Guayaquil.

Abordar este problema requiere una visión general, algo fundamental en la Ingeniería Mecatrónica. Este proyecto tiene relevancia académica porque no solo analiza datos, sino que también diseña un sistema automático que combina electrónica, informática (IA y Visión por Computadora) y control (diagnóstico). Aunque entender cómo se produce la energía solar también es importante para otras carreras como la ingeniería eléctrica, crear un dispositivo inteligente que detecte fallas es una tarea típica de la mecatrónica, que une hardware y software en una solución única.

La relación con el sector productivo es clara, ya que puede ofrecer a Vatio Pico una herramienta para mejorar el servicio de mantenimiento que brindan y aprovechar mejor la inversión de sus clientes. El impacto positivo es crear una metodología que pueda escalarse. Este trabajo se enfoca en diseñar y probar un prototipo de sistema integrado, usando una plataforma avanzada (edge computing), que ejecuta modelos de IA directamente en el dispositivo (Jetson). Este método, muy

usado en Mecatrónica, hace que la solución sea un producto confiable y autónomo, que puede usarse en negocios, hogares o en la gestión inteligente de sistemas fotovoltaicos.

1.2 Descripción del Problema

El mercado actual presenta una demanda progresiva de sistemas fotovoltaicos considerando la tendencia al uso de energías renovables como soluciones eficientes y sostenibles con el medio ambiente, no obstante, los paneles solares sufren degradaciones y fallas a lo largo de su vida útil debido a factores como materiales de fabricación, factores ambientales y entornos causando degradación gradual del tiempo de vida de forma lineal y no lineal [3]. La falla progresiva de los paneles solares no solo compromete su capacidad para cumplir con la vida útil de diseño, también supone un riesgo en la inversión económica de proyectos fotovoltaicos, donde el principal objetivo es alcanzar un balance energético positivo. La problemática se vuelve aún más relevante en climas tropicales como el de Guayaquil, donde la combinación de alta irradiancia, humedad y temperatura acelera la degradación de los materiales y componentes de los módulos fotovoltaicos [4], [5].

En este escenario es posible abordar la reducción el tiempo de vida de los paneles, ya que este fenómeno no es aleatorio, sino que responde a patrones físicos y eléctricos que pueden ser detectados de forma temprana o identificados mediante el uso de sensores internos en los inversores eléctricos y sistemas de visión por computadora capaces de reconocer defectos externos en los paneles solares. El uso de dispositivos de recolección de datos conocidos como “dataloggers” en conjunto con modelos de inteligencia artificial permite transformar las señales de fallas en diagnósticos precisos, facilitando la construcción de un sistema de reconocimiento de anomalías tempranas o actuales que determinan la vida útil de los módulos fotovoltaicos. El uso de las metodologías desvela la susceptibilidad del problema de cuantificación objetiva, abriendo

la posibilidad a aplicar estrategias de mantenimiento predictivo, superando las limitaciones de los paradigmas tradicionales en mantenimientos correctivos o preventivos manuales.

El presente proyecto se desarrolla en colaboración con la empresa Vatio Pico S.A., empresa líder en el sector de sistemas fotovoltaicos en Ecuador que han manifestado el compromiso estratégico con la integración de energías renovables en su estructura operativa. El espacio de Vatio Pico cuenta con un campo piloto de pruebas, con el objetivo de evaluar la viabilidad técnica y económica de los sistemas fotovoltaicos bajo condiciones climáticas locales.

1.3 Justificación del problema

La implementación de un sistema inteligente de monitoreo y diagnóstico en plantas fotovoltaicas resulta esencial por varias razones. En primer lugar, la detección temprana de anomalías permite intervenir antes de que el daño se vuelva irreversible, preservando la eficiencia energética y prolongando la vida útil de los paneles solares, esto se traduce en mayor rendimiento acumulado y menor costo nivelado de energía (LCOE). En segundo lugar, el uso de técnicas de Machine Learning y visión por computadora permite transformar datos operativos de la red como corriente, voltaje, temperatura y clase de daño externo visual en indicadores de salud del sistema fotovoltaico que se clasificarán con índices de desviación o pronóstico de degradación. Además, en entornos climáticos extremos como Guayaquil, donde la degradación se acelera por el estrés térmico y la humedad, el enfoque predictivo es particularmente útil para adaptarse a condiciones locales. Por último, para Vatio Pico S.A., como empresa cliente del proyecto, disponer de un sistema que garantice la confiabilidad y eficiencia de sus activos fotovoltaicos es estratégico: minimiza riesgos financieros, soporta el cumplimiento de metas de sustentabilidad corporativa y mejora la resiliencia energética de su infraestructura.

1.4 Objetivos

1.4.1 Objetivo general

Diseñar un sistema de monitoreo y diagnóstico para módulos fotovoltaicos monocristalinos en Guayaquil que integre adquisición de datos eléctricos y visión por computadora, con el propósito de detección de fallas externas e internas, cuantificación de la degradación y generación energética, mediante el uso de una plataforma con integración de inteligencia artificial.

1.4.2 Objetivos específicos

1. Recoger los registros de parámetros eléctricos de los paneles solares para el entrenamiento de los modelos de Machine Learning mediante conexión entre sistema embebido y nube.
2. Capturar imágenes infrarrojas y RGB de los paneles solares para en reconocimiento de fotos de falla provenientes de suciedad, puntos calientes y daños físicos usando un protocolo de adquisición de datos en la nube.
3. Evaluar el rendimiento de los modelos de inteligencia artificial aplicados para la determinación de índices de precisión en operación del sistema mediante algoritmos y graficas propias de modelos.
4. Implementar un dispositivo de cómputo y periféricos con el fin de embeber el sistema de reconocimiento desarrollado mediante el uso de procesadores comerciales afines a integración de inteligencia artificial.

1.5 Marco teórico

En esta sección se recopila y analiza información relevante acerca de tiempo de vida útil de sistemas fotovoltaicos, fallas comunes en paneles solares, adquisición de datos en generación energética. Esto con especial enfoque en el uso de modelos de inteligencia artificial en estudios relacionados a la detección de fallas en módulos solares.

1.5.1 Estructura y características de paneles solares monocristalinos.

En recientes instalaciones fotovoltaicas modernas, particularmente en aplicaciones industriales donde se busca una alta eficiencia, la tecnología predominante son paneles monocristalinos. Estos módulos son caracterizados por fabricarse a partir de un único cristal de silicio, con el fin de obtener silicio monocristalino de alta pureza mediante el proceso de Czochralski, esencial en la fabricación de celdas solares de alto rendimiento [6].

Esta estructura cristalina uniforme le confiere una eficiencia de conversión energética superior en comparación a sus homólogos policristalinos. También se destaca su operación en óptimas condiciones ante escenarios de baja irradiancia, manteniendo coeficientes de temperatura ligeramente favorables [7]. La robustez de los paneles se fundamenta en un encapsulante polimérico que a su vez está cubierta por un vidrio templado de alta transmisividad, todo ensamblado en un marco de aluminio.

1.5.2 Vida útil y fallas comunes en módulos fotovoltaicos.


La vida útil de los paneles solares se estandariza comúnmente entre 20 a 25 años, considerando sus estándares de fabricación, material, rendimiento, los cuales pueden verse comprometidos por la aparición de diversas fallas y modos de degradación a lo largo de su operatividad [8]. No obstante, esta estimación no es fija, ya que se debe considerar factores climáticos, acumulación de suciedad, defecto de fábrica y mantenimientos deficientes, contribuyen a acortar la vida útil de los paneles solares [9]. En la práctica, diversos trabajos han demostrado

que fallas externas como golpes, impurezas, puntos calientes, grietas o impactos por granizo pueden reducir significativamente la energía generada y acortar la vida útil de los módulos.

A. Fallas por puntos calientes (Hotspot) en módulos fotovoltaicos

Esta falla se denomina punto caliente o Hotspot como fue identificada originalmente, es un fenómeno térmico que ocurre cuando las celdas individuales dentro de un módulo de panel solar desarrollan una resistencia eléctrica anormalmente elevada, provocando que se disipe la energía obtenida del sol en forma de calor en lugar de generar electricidad por medio del inversor [10]. Esta falla representa una anomalía crítica en sistemas fotovoltaicos debido a su capacidad de degradar irreversiblemente el módulo que se encuentra afectado, esto a su vez disminuye el rendimiento en la captación de energía y la seguridad operacional de los paneles.

Figura 1.1 *Falla por punto caliente (Hotspot) [11]*




El mecanismo físico fundamental de los “hotspots” está directamente relacionado con la polarización inversa en las celdas fotovoltaicas cuando operan bajo condiciones de sombreado parcial o degradación localizada. En una línea fotovoltaica conocida como “string”, las celdas están conectadas en serie, lo que implica que la corriente que circula está limitada por la celda de menor capacidad de generación. En consecuencia, la celda que presenta un defecto opera en modo de polarización inversa, actuando como carga resistiva que disipa la energía producida por las celdas funcionales adyacentes [12].

Los estudios previos demostraron que los puntos calientes dentro de paneles solares pueden causar pérdidas significativas de potencia, reducción de producción de energía y daños irreversibles, teniendo en cuenta que al incrementar la temperatura operativa del panel existe la posibilidad de enfrentar la pérdida de funcionalidad módulo [13]. Las elevadas temperaturas localizadas aceleran procesos de degradación química y mecánica, incluyendo delaminación del encapsulante acetato de etileno-vinilo (EVA), y microfracturas en las celdas de silicio. En casos severos, los “hotspots” pueden representar riesgos de incendio en instalaciones fotovoltaicas [14].

B. Degradación por factores físicos en Módulos Fotovoltaicos

Las anomalías físicas que son visibles en paneles solares se constituyen en varias categorías de defectos que tienen un impacto significativo en el rendimiento energético y en la vida útil de los sistemas. Los daños mecánicos en particular las microfracturas en celdas fotovoltaicas representan uno de los modos de falla más frecuentes y visibles en módulos fotovoltaicos. Estas fracturas microscópicas pueden originarse durante los procesos de manufactura, transporte, instalación o durante la operación del sistema debido a cargas mecánicas, estrés térmico o impactos ambientales [15]. En el trabajo de Molina-Ruiz et al se evidencia que estas fracturas tienen la capacidad de propagarse con el tiempo y reducir significativamente la eficiencia del módulo, por lo que su detección temprana es indispensable para determinar si el módulo puede aplicar a un mantenimiento correctivo o preventivo [15].

Figura 1.2 *Falla en panel solar por fractura y microfracturas [16]*



De forma similar el impacto de las microfracturas ha sido cuantificado por medio de estudios donde se ha logrado documentar pérdidas de potencia que oscilan entre 2% y 60%, dependiendo de la orientación, extensión y ubicación de las fracturas respecto a secciones de las celdas. En particular, Dhimish et al. demostraron que las fracturas paralelas y las de múltiples direcciones generan mayores pérdidas de potencia en comparación con las fracturas perpendiculares, confirmando la relevancia de la geometría de la grieta en la degradación del módulo [17].

Por otro lado, la acumulación de suciedad en la superficie de los paneles son fenómenos etiquetados originalmente como “soiling”, que estructuran una anomalía común relacionada a la suciedad y falta de limpieza que deriva en la reducción de la transmisión de radiación solar hacia las celdas fotovoltaicas. En este caso diversos agentes contaminantes incluyendo el polvo atmosférico, polen, excremento de aves y contaminadores industriales pueden depositarse en la barrera de vidrio frontal, creando una barrera que atenúa la irradiancia directa recibida por las celdas. Aunque no constituye como una falla de gran magnitud varia en la severidad del impacto a base de su ubicación geográfica, condiciones climáticas y características del entorno de trabajo, con regiones áridas experimentando tasas de deposición significativamente superiores comparadas con regiones húmedas o templadas [18].

C. Fallas por parámetros eléctricos

Los inversores fotovoltaicos juegan un papel crítico en la implementación de sistemas fotovoltaicos, ya que se encargan de convertir la energía solar captada por los paneles solares en energía eléctrica que provee de voltaje y corriente a las cargas designadas. Estos dispositivos de potencia contienen múltiples componentes susceptibles a degradación y falla, incluyendo capacitores electrolíticos, semiconductores de potencia (IGBTs, MOSFETs), circuitos de control y sistemas de comunicación. Las fallas presenten en estos dispositivos se manifiestan a través de variables eléctricas medibles como voltaje y corriente de entrada DC de paneles, así como la potencia de salida AC, teniendo una afectación en el factor de potencia [19]. La degradación progresiva de componentes internos produce patrones característicos en estas señales que pueden identificarse mediante análisis en dominio temporal o frecuencial mediante la recolección de datos.

Los inversores modernos típicamente registran las variables eléctricas, almacenando datos localmente o transmitiéndolos a plataformas centralizadas mediante protocolos de comunicación estándar como Modbus, SunSpec o interfaces propietarias de las empresas fabricantes. El monitoreo continuo de estas variables mediante sistemas de adquisición de datos como “dataloggers”, dispositivos que comparten parámetros de generación y de red mediante plataformas y tableros visuales.

1.5.3 Aplicación de inteligencia artificial para la detección de fallas

La evolución de las operaciones y mantenimientos en parques fotovoltaicos ha estado profundamente ligado al avance del poder computacional y conectividad de sistemas. El desafío de gestionar eficientemente plantas que abarcan hectáreas ha impulsado la transición de un mantenimiento correctivo a un paradigma predictivo y automatizado.

Esta transición ha sido posible gracias a la confluencia de dos factores tecnológicos entre los que se encuentran la proliferación de sistemas de adquisición de datos capaces de almacenar

grandes volúmenes de series temporales eléctricas; y segundo, el desarrollo de la visión por computadora mediante sensores de bajo costo como cámaras RGB y térmicas desplegadas en vehículos aéreos no tripulados [20], [21]. Es en este contexto donde la IA y específicamente sus subcampos del ML y DL, se ha posicionado como la tecnología habilitadora clave, ofreciendo la capacidad de analizar patrones complejos tanto en datos numéricos como visuales para la detección, clasificación y predicción de fallas.

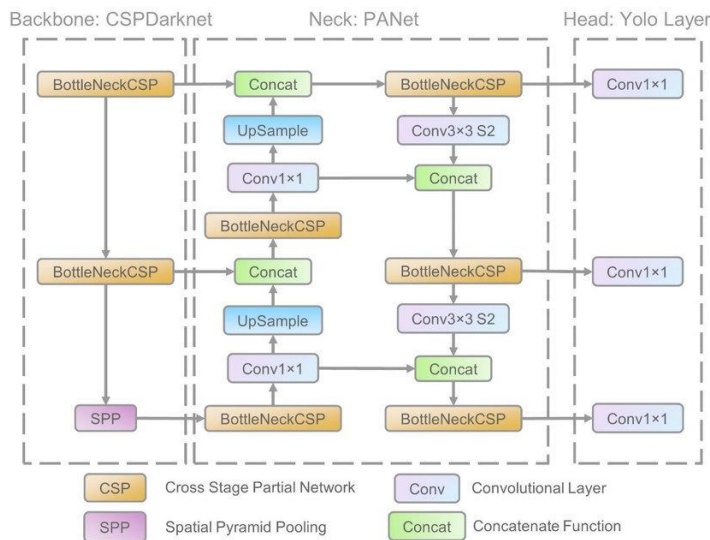
1.5.4 Arquitectura del modelo YOLOV5

En el grupo de modelos de inteligencia artificial “You Only Look Once” se cierne un paradigma revolucionario en la detección de objetos mediante aprendizaje profundo, una técnica que utiliza redes convolucionales para el aprendizaje de algoritmos en el reconocimiento y detección de clases. El algoritmo original YOLO fue introducido por Redmon et al. en 2015, proponiendo un enfoque radicalmente diferente a los métodos tradicionales de detección basados en propuestas de regiones que requerían múltiples etapas de procesamiento [22]. Esta arquitectura examina la imagen completa una única vez para predecir simultáneamente cajas delimitadoras y probabilidades de clase mediante un previo entrenamiento personalizado, logrando una velocidad de procesamiento superior a otros modelos.

YOLOv5, desarrollado por Ultralytics en 2020, representa una evolución significativa de la familia YOLO implementada completamente en el framework PyTorch, presenta una arquitectura del modelo que se compone de tres partes principales, que son “backbone”, “neck” y “head”. Por un lado, el “backbone” es el encargado de la extracción de características de las imágenes de entrenamiento que procesa la ilustración de entrada mediante capas convolucionales profundas organizadas en bloques residuales [23]. Mantiene una modificación arquitectónica, derivada de DenseNet, modelo clásico de detección de objetos, que divide los mapas de

características en dos ramas de procesamiento reduciendo significativamente la carga computacional y mejorando el flujo de gradientes durante el entrenamiento. Posteriormente, el componente “neck” concatena mapas de características en lugar de sumarlos como se realiza tradicionalmente, el concatenar conserva más información de la imagen por canal facilitando el paso del gradiente y reduciendo el proceso de cómputo [24]. Por último, el bloque “head” emplea capas de predicción basadas en la localización de objetos y clasificación solamente utilizando procesos convolucionales, para ajustar las cajas de predicción emplea una función de pérdida CIOU (Complete IoU loss) que combina evaluación entre caja predicha y real, distancia entre centros de imagen y relación de aspecto para mejorar la precisión del modelo.

Figura 1.3 Estructura computacional del modelo YOLOV5 [25]



Estudios comparativos han demostrado que YOLOv5 mantiene un balance óptimo entre precisión, velocidad de inferencia y eficiencia de memoria; superando arquitecturas alternativas en escenarios donde el procesamiento en tiempo real es crítico [26]. Esta característica principal es la que posibilita su implementación en sistemas embebidos de baja escala para la creación de prototipos funcionales.

1.5.5 Implementación de YOLOV5 en detección de fallas físicas y superficiales en módulos fotovoltaicos.

El modelo YOLOv5 presenta ventajas significativas para el análisis automatizado de imágenes térmicas y ópticas de módulos fotovoltaicos al presentar fallas. La capacidad del modelo para detectar y localizar simultáneamente múltiples anomalías en una sola imagen permite inspeccionar instalaciones fotovoltaicas extensas con alta eficiencia computacional, realizando un entrenamiento con múltiples clases de fallas dependiendo del contexto y metodología. En investigaciones previas se ha demostrado que YOLOV5 es capaz de identificar fallas de puntos calientes en imágenes termográficas con precisiones superiores al 97%, procesando imágenes a velocidades que permiten análisis en tiempo real de video capturado por drones durante inspecciones aéreas [27]. Aunque es imperativo pensar en implementaciones en tiempo real, también es posible trabajar en post procesado de imágenes, reduciendo el consumo de cómputo y aumentando la autonomía energética.

La arquitectura es específicamente adecuada para detectar fallas físicas como fracturas en vidrio, delaminación de partes inferiores del módulo y acumulación de suciedad en módulos fotovoltaicos mediante análisis de imágenes en espectro visible. El manejo de objetos en múltiples escalas resulta fundamental dado que las fallas fotovoltaicas pueden manifestarse en dimensiones variables, desde microfracturas localizadas en celdas individuales hasta acumulaciones de suciedad que afectan módulos completos de forma simultánea.

1.5.6 Aplicación de Modelos de Regresión en el Análisis de Datos de Dataloggers Fotovoltaicos

los modelos de regresión lineal se presentan como herramientas fundamentales para el análisis predictivo de datos recopilados mediante dataloggers en inversores fotovoltaicos. Estos registran continuamente variables eléctricas, proporcionando un flujo de datos históricos para entrenar modelos predictivos que pueden anticipar comportamientos anómalos indicativos de

fallas incipientes en inversores. Entre los modelos de machine learning más reconocidos se tiene regresión lineal múltiple, regresión Lasso, Random Forest y Gradient Boosting.

El algoritmo Gradient Boosting se conforma de modelos predictivos mediante la adición secuencial de aprendices débiles en términos informáticos, típicamente árboles de decisión poco profundos, donde cada nuevo modelo se entrena específicamente para corregir los errores residuales del ensemble acumulado [28]. A diferencia del algoritmo Random Forest que construye árboles independientes en paralelo, Gradient Boosting sigue un proceso iterativo donde cada árbol subsecuente se enfoca en las instancias que el ensemble actual predice incorrectamente en el entrenamiento. El principio fundamental se basa en optimización por descenso de gradiente aplicada al espacio de funciones, capturando relaciones no lineales complejas y automáticamente modelando las interacciones entre características. En cuanto su aplicación en sistemas fotovoltaicos, estudios recientes han implementado modelos “Extreme Gradient Boosting”, variación ligera para predecir la generación de potencia fotovoltaica utilizando datos recopilados por dataloggers IoT en sistemas remotos [29]. De esta misma investigación, Rinesh et al. demostró que es posible manejar efectivamente las relaciones no lineales complejas entre variables meteorológicas y producción energética con errores mínimos, lo que justifica su uso para esta investigación en el alcance y precisión del modelo aplicado a la detección de fallas.

Capítulo 2

2.1 Metodología.

Para el desarrollo del sistema de monitoreo de fallas externas e internas en paneles solares se requirió la integración de distintas tecnologías de hardware y software, incluyendo visión por computadora, modelos de machine learning, bases de datos y una plataforma de cómputo embebida que realiza las operaciones esenciales del sistema. La selección adecuada de la arquitectura de procesamiento fue crítica, ya que de ella depende el tiempo de respuesta del sistema, su robustez en condiciones reales de operación y la posibilidad de integrarlo con la infraestructura existente de la planta fotovoltaica.

2.2 Formulación de alternativas de solución

Durante el desarrollo del proyecto se descompuso el dispositivo embebido para diagnóstico de paneles solares en cuatro subsistemas funcionales principales que conforman el diseño final para cumplir con los requerimientos del cliente.

- Subsistema de procesamiento e inferencia de IA
- Subsistema de adquisición de imágenes de los paneles.
- Subsistema de adquisición y gestión de datos eléctricos.
- Subsistema de visualización y acceso a la información.

En esta sección se formularon alternativas de solución principalmente para el subsistema de procesamiento e inferencia, puesto que esta decisión condicionó el resto de la arquitectura, se consideraron diversas alternativas de solución, tomando en cuenta los criterios técnicos, operativos y de integración definidos posteriormente en la sección de evaluación.

A. Subsistema de procesamiento e inferencia de IA

En este subsistema se concentró la ejecución de los modelos de visión por computadora y del modelo de machine learning para fallas internas, así como los servicios de “backend” que permiten exponer los resultados al usuario.

- **Arquitectura basada en NVIDIA Jetson Xavier NX:** Se propuso utilizar una Jetson Xavier NX como plataforma principal de cómputo embebido.
- **PC industrial con GPU dedicada:** Como alternativa, se consideró el uso de una PC industrial instalada en la sala de control de la planta, equipada con una GPU dedicada para acelerar el procesamiento de redes neuronales.
- **Servidor en la nube para inferencia remota:** Se contempló desplegar los modelos de IA en un servidor en la nube, que, en este esquema, las imágenes y datos eléctricos se enviarían por Internet.

B. Subsistema de adquisición de imágenes de los paneles

Este subsistema se encargó de capturar la información visual necesaria para identificar fallas superficiales en los paneles, como suciedad, sombreado, delaminaciones o puntos calientes visibles.

- **Cámara IP fija de espectro visible:** Se analizó el uso de una cámara IP fija de alta resolución, instalada en una estructura cercana al campo fotovoltaico
- **Cámara térmica radiométrica fija:** Esta opción es de mayor especialización, se consideró el uso de una cámara térmica radiométrica fija, capaz de medir temperaturas de cada píxel.
- **Inspección periódica con dron y cámara:** Se evaluó un esquema de adquisición basado en vuelos periódicos de dron equipados con cámara visible o térmica.

C. Subsistema de adquisición y gestión de datos eléctricos

El objetivo de este subsistema fue obtener las variables eléctricas de operación del sistema fotovoltaico como tensión, corriente o potencia, que alimentan el modelo de machine learning para la detección de fallas internas.

- **Integración con el dataloggers existente de la planta:** Esta alternativa consiste en aprovechar el datalogger ya instalado por la empresa, accediendo a sus registros mediante exportación de archivos, API o conexión directa a la base de datos.
- **Módulo de medición dedicado por la línea de conexión:** Se planteó diseñar o integrar un módulo de medición dedicado, instalado en la línea de conexión (strings) fotovoltaicos, con sensores de tensión, corriente y comunicación digital.
- **Lectura directa desde el inversor mediante protocolo industrial:** Una tercera alternativa consideró la lectura de variables eléctricas directamente desde el inversor on-grid a través de protocolos industriales como Modbus/TCP.

D. Subsistema de visualización y acceso a la información

Este subsistema definió la forma en que el usuario final consultó las fallas detectadas, el estado de salud de los paneles y los registros históricos generados por el sistema.

- **Dashboard web alojado en la Jetson Xavier NX:** Se propuso implementar un desarrollo web ejecutados en la propia Jetson.
- **Interfaz local en pantalla integrada al dispositivo:** Otra alternativa consistió en priorizar una interfaz local mostrada en una pantalla táctil conectada directamente a la Jetson o PC industrial.
- **Aplicación cliente externa conectada a un servidor central:** Se considera desarrollar una aplicación de escritorio o móvil que consumiera datos desde un servidor central ubicado en la nube o en la sala de control.

Con esta descomposición en subsistemas y la formulación de alternativas para cada uno de ellos, se estableció la base para el análisis comparativo.

2.3 Evaluación y selección de alternativas

2.3.1 Principios de solución y criterios de evaluación

Para orientar el proceso de diseño se establecieron principios de solución que sirvieron como guía para definir los criterios de evaluación y permitir una comparación homogénea entre las alternativas planteadas. Estos principios se obtuvieron a partir del análisis funcional del sistema, de los requerimientos de la empresa colaboradora y de las condiciones reales de operación de la planta fotovoltaica. Los principios considerados fueron:

- **Compacto y bajo consumo energético:** el sistema debe ocupar poco espacio físico y consumir poca energía eléctrica.
- **Capacidad de procesamiento en tiempo:** la solución debe garantizar que el análisis de imágenes y de datos eléctricos se realizara con una latencia suficientemente baja para que las alertas de fallas fueran útiles en la operación diaria.
- **Robustez frente a fallos de conectividad:** el sistema debe mantener un funcionamiento básico incluso ante pérdidas temporales de conexión a Internet.
- **Accesibilidad económica:** la alternativa seleccionada debe ser económicamente viable para un entorno industrial local, evitando depender en exceso de suscripciones o licenciamientos costosos.
- **Facilidad de implementación y mantenimiento:** la arquitectura debe ser instalable con los recursos humanos disponibles y permitir el mantenimiento y actualización de modelos sin interrupciones prolongadas del servicio.

- **Pertinencia académica e innovación tecnológica:** la solución debe favorecer el desarrollo de competencias en sistemas embebidos e inteligencia artificial aplicada.

Con base en estos principios se definieron los criterios de evaluación, aplicables a todas las alternativas planteadas:

- **Costo total (C):** Incluye la inversión inicial en hardware y software.
- **Capacidad de procesamiento (CP):** Mide la aptitud de la plataforma para ejecutar los modelos de visión por computadora y machine learning dentro de los tiempos de respuesta requeridos.
- **Consumo energético (CE):** Considera la potencia típica demandada por el sistema en operación continua.
- **Robustez operativa y frente a conectividad (RO):** Evalúa qué tan sensible resulta la arquitectura a fallos de red.
- **Escalabilidad y replicabilidad (ER):** Valora la facilidad con la que la solución puede ampliarse a más líneas de conexión o plantas solares.
- **Complejidad de implementación y mantenimiento (CI):** Analiza la dificultad de instalación y configuración.

Para cada subsistema descrito en la sección 2.1 se construyó una matriz de decisión en la que se evaluaron las alternativas propuestas frente a los criterios definidos. La evaluación se realizó mediante una escala cualitativa de 1 a 5, donde “1” representa un desempeño deficiente frente al criterio considerado, “3” un desempeño aceptable o intermedio, y “5” un desempeño sobresaliente.

2.3.2 Matriz de evaluación: subsistema de procesamiento e inferencia de IA

Tabla 2.1 *Matriz de evaluación: subsistema de procesamiento e inferencia de IA*

Alternativa	C	CP	CE	RO	ER	CI	Total
Jetson Xavier NX embebida	4	4	5	5	4	4	26
PC industrial	3	5	2	4	3	3	20
Servidor en la nube	2	5	4	2	5	2	20

La alternativa basada en NVIDIA Jetson Xavier NX obtuvo la mayor puntuación total. Se valoró especialmente su bajo consumo energético y su robustez operativa, al ejecutar la inferencia en el borde sin depender de la conexión a Internet.

2.3.3 Matriz de evaluación: subsistema de adquisición de imágenes

Tabla 2.2 *Matriz de evaluación: subsistema de adquisición de imágenes*

Alternativa	C	CP	CE	RO	ER	CI	Total
Cámara IP fija de espectro visible	5	4	4	4	4	4	25
Cámara térmica radiométrica fija	2	5	3	4	3	3	20
Inspección periódica con dron y cámara	3	4	2	2	3	2	16

La cámara IP fija de espectro visible presentó el mejor equilibrio entre costo, consumo energético y facilidad de integración con la Jetson, alcanzando la puntuación más alta.

2.3.4 Matriz de evaluación: subsistema de adquisición y gestión de datos eléctricos

Tabla 2.3 *Matriz de evaluación: subsistema de adquisición y gestión de datos eléctricos.*

Alternativa	C	CP	CE	RO	ER	CI	Total
Lectura directa desde el inversor vía protocolo industrial	4	3	5	3	3	3	21
Módulo de medición dedicado por string	3	5	3	3	3	3	20
Integración con el datalogger existente	5	4	5	4	4	4	26

La integración con el recolector de datos de inversor existente obtuvo la puntuación más alta ya que, esta alternativa no requirió hardware adicional, aprovechó la instrumentación ya instalada por la empresa y mantuvo una buena robustez operativa al tratarse de un equipo probado en servicio.

2.3.5 Matriz de evaluación: subsistema de visualización y acceso a la información

Tabla 2.4 *Matriz de evaluación: subsistema de visualización y acceso a la información*

Alternativa	C	CP	CE	RO	ER	CI	Total
Interfaz local en pantalla integrada	4	3	4	4	3	3	21
Página web alojado en la Jetson Xavier NX	5	4	5	4	5	4	27
Aplicación cliente externa	3	4	5	3	4	2	21

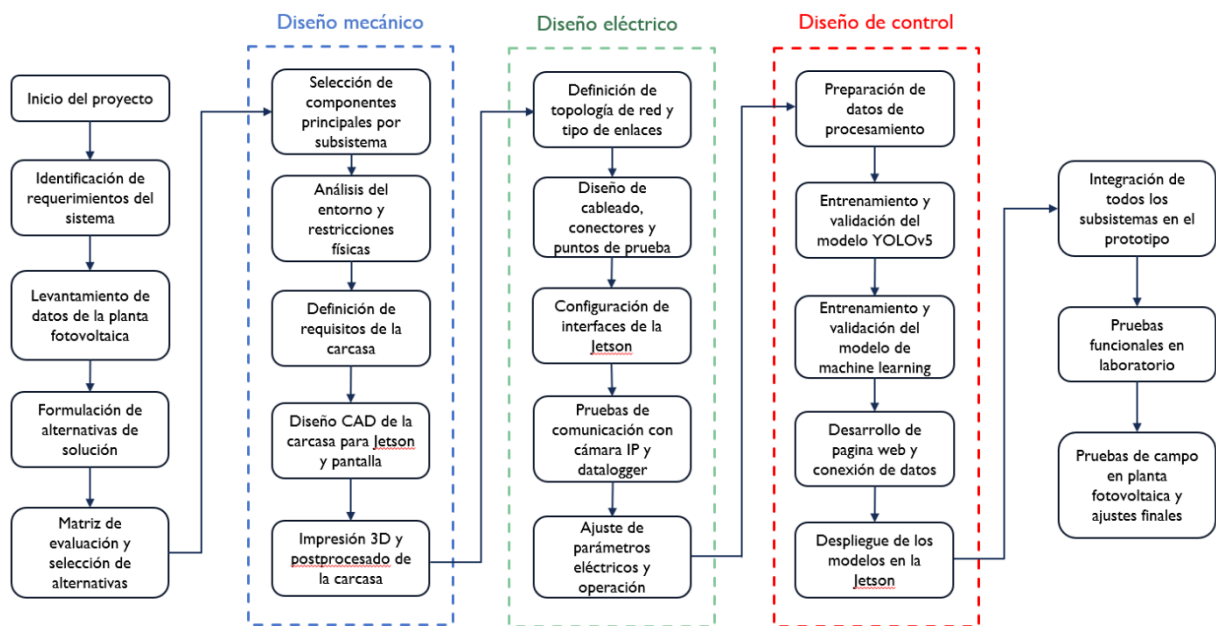
La página web alojado en la Jetson Xavier NX fue la alternativa con mayor puntuación. Esta solución permitió que el propio dispositivo embebido actuara como servidor de aplicaciones, accesible desde cualquier equipo conectado a la red local u opcionalmente, de forma remota.

2.4 Diseño del prototipo

El desarrollo del prototipo se estructuró mediante un proceso de diseño ordenado y coherente. En primera instancia se siguió una secuencia lineal que abarcó desde la identificación de los requerimientos funcionales y de instalación, hasta la formulación y evaluación de

alternativas y la posterior selección de los componentes principales de cada subsistema. Una vez definida la arquitectura general, el trabajo se organizó en tres líneas de diseño interrelacionadas: diseño mecánico, diseño electrónico y diseño del sistema de control y software.

Figura 2.1 Diagrama de flujo del proceso de diseño del prototipo



En la **Figura 2.1** se presenta el diagrama de flujo que resume las actividades realizadas a lo largo del proyecto. En dicho esquema se observa cómo, tras la selección de alternativas, el diseño mecánico se centró en la configuración física del dispositivo y su montaje en campo. Por otro lado, el diseño electrónico se ocupó de la alimentación, protección y comunicación con los equipos de medida. Finalmente, el diseño del sistema de control incorporó el entrenamiento, despliegue y orquestación de los modelos de visión y machine learning, así como el desarrollo de la central de visualización de la web.

2.5 Diseño conceptual

El diseño conceptual tuvo como propósito definir, a un nivel de bloques funcionales, cómo se organizaba el prototipo de monitoreo de paneles solares y qué rol cumplía cada parte dentro del

sistema. El dispositivo se concibió como una unidad embebida instalada en la planta fotovoltaica, integrada por: un módulo de captura de imágenes mediante una cámara fija de espectro visible, un módulo de adquisición de datos eléctricos conectado al registrador de datos o al inversor y una unidad de procesamiento basada en la tarjeta NVIDIA Jetson Xavier NX.

Figura 2.2 *Ilustración del prototipo propuesto*



En el prototipo se ejecutan el modelo de detección de fallas visuales y el modelo de aprendizaje automático para fallas internas, mientras que el almacenamiento interno conserva imágenes, variables eléctricas y resultados de evaluación. La pantalla muestra un panel de visualización, accesible desde un navegador web y alojado en la Jetson, que permite revisar el estado de los paneles y su generación energética.

2.6 Requerimientos de Diseño

En función a los requerimientos del cliente y las funciones esperadas por el prototipo final, se clasifican los requerimientos que debe de cumplir el producto para su correcta operación en la detección de fallas. Para esto se llevó a cabo la clasificación de dos grupos de requerimientos: requerimientos generales del sistema y requerimientos de operación.

2.6.1 Requerimientos generales del sistema

Los requerimientos generales describieron las características esenciales del prototipo para asegurar su funcionalidad, portabilidad y confiabilidad durante el proceso de inspección y diagnóstico.

- Portabilidad y peso del dispositivo.
- Capacidad de expansión de entradas y salidas.
- Baja latencia de procesamiento e inferencia.
- Alta precisión de los modelos para minimizar falsas alarmas.
- Generación de reportes organizados por inspección.

2.6.2 Requerimientos de operación

Los requerimientos de operación definieron el comportamiento esperado del prototipo durante el proceso de detección de fallas, especialmente en la forma de alertar al usuario y registrar la información.

Tabla 2.5 *Tabla de los requerimientos de operación del prototipo*

Detección de fallas	Función ante detección
Panel trizado / golpeado	Alerta visual con Led / Alerta visual en pantalla / reporte de fallas
Panel con falla de punto de calor	Alerta visual con Led rojo / Alerta visual en pantalla / reporte de fallas
Panel en estado de suciedad	Alerta visual con Led / Alerta visual en pantalla / reporte de fallas
Falla en la producción energética	Alerta visual con Led / Alerta visual en pantalla / reporte de fallas

2.7 Diseño electrónico

El diseño electrónico del prototipo se orientó a obtener una configuración sencilla, compacta y segura, centrada exclusivamente en los elementos que forman parte física del dispositivo: la tarjeta de procesamiento Jetson Xavier NX, una pantalla de visualización de pequeño formato, un conjunto de diodos emisores de luz como indicadores de estado y un ratón conectado a la Jetson para la interacción básica.

2.7.1 Estructura general del sistema electrónico

La estructura general del sistema electrónico puede resumirse en los siguientes bloques:


1. **Módulo de alimentación principal:** compuesto por la entrada de red, la fuente conmutada de 19 V en corriente continua y las protecciones internas.
2. **Unidad de procesamiento Jetson Xavier NX:** recibe la tensión de 19 V en su conector de alimentación y, a través de sus reguladores internos, genera las tensiones de 5 V y 3,3 V necesarias para el funcionamiento del módulo y para la alimentación de periféricos ligeros.
3. **Módulo de señalización mediante LED:** integrado por los diodos emisores de luz y sus resistencias limitadoras, conectados a pines de salida digital de la Jetson.
4. **Módulo de interfaz de usuario local:** conformado por la pantalla de visualización y el ratón, ambos conectados directamente a la Jetson mediante sus interfaces de vídeo y de periféricos.

2.7.2 Características del sistema

La Jetson Xavier NX se alimenta mediante una fuente de corriente continua conectada a la red eléctrica. De acuerdo con la documentación del fabricante, el kit de desarrollo admite tensiones

de entrada entre 9 y 20 V y se suministra habitualmente con un adaptador de 19 V, que es regulado internamente hacia los niveles de 5 V y 3,3 V requeridos por la placa. A continuación, La **figura 2.3** presenta un esquema de conexión de periféricos conectados al microcontrolador.

Figura 2.3 *Diagrama de conexión de la Jetson Xavier NX*



2.8 Diseño mecánico

El diseño mecánico del prototipo se centró en el desarrollo de una armadura o carcasa robusta para la Jetson Xavier NX, orientada a garantizar la protección física del hardware y una gestión térmica eficiente. La estructura fue modelada mediante el software Autodesk Inventor, priorizando un diseño funcional que permite el acceso a los puertos de conexión y optimiza el flujo de aire del dispositivo en caso de aumento de temperatura por operación de cómputo.

El proceso de fabricación se llevó a cabo mediante manufactura aditiva (impresión 3D), seleccionando el tereftalato de polietileno glicolado (PETG) como material base. La elección de este polímero técnico responde a la necesidad de una pieza que soporte el calor generado por el procesamiento intensivo sin sufrir deformaciones.

2.8.1 Parámetros de impresión y comparativa de material


Para la ejecución de la pieza en la impresora Bambu Lab A1, se configuraron parámetros específicos que equilibran la calidad superficial con la resistencia estructural. A continuación, se presenta una tabla comparativa entre el material utilizado y el estándar convencional (PLA), junto con los detalles de impresión del prototipo:

Tabla 2.6 *Parámetros de impresión 3D*

Parámetro / Propiedad	PLA (Estándar)	PETG (Prototipo)
Temperatura de boquilla	190 – 210 °C	240 – 250 °C
Temperatura de cama	40 – 60 °C	70 – 80 °C
Resistencia térmica (\$T_g\$)	~60 °C	~80 °C
Duración de impresión	~3.5 horas	4.6 horas
Diámetro de boquilla	0.4 mm	0.4 mm
Resistencia al impacto	Baja (Frágil)	Alta (Tenaz)

Finalmente, se cuenta con la visualización de la pieza dibujada mediante Inventor en el programa de impresión de Bambu Slicer, dedicado a calcular las horas de impresiones y características del proceso de manufactura del prototipo.

Figura 2.4 *Prototipo impreso en el entorno de diseño 3D de BambuLab*



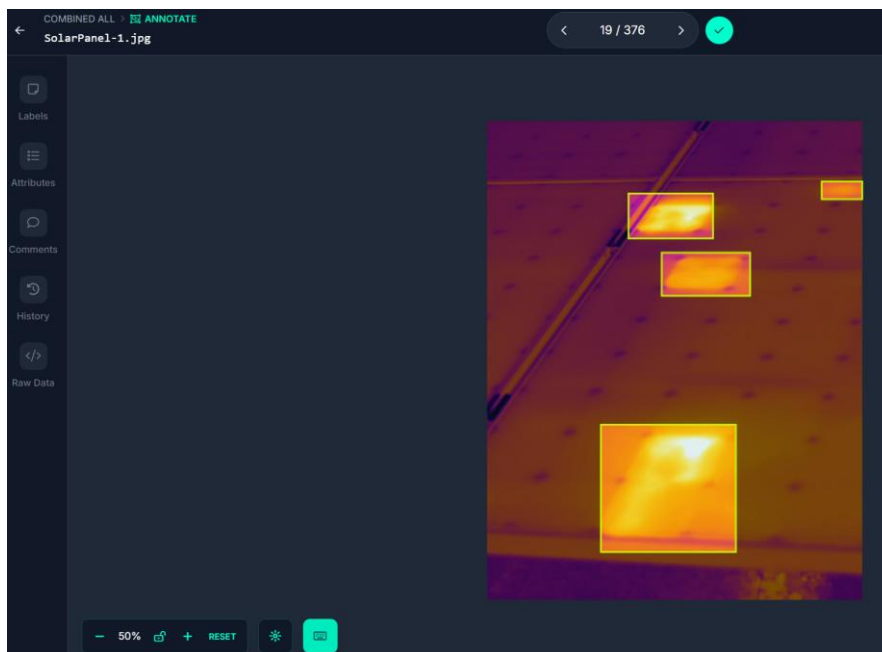
2.9 Diseño del sistema de control

El diseño del sistema de control se enfocó en establecer un flujo completo que abarcara la obtención de datos, su preparación, el entrenamiento de modelos de inteligencia artificial y su integración en el prototipo basado en Jetson Xavier NX.

2.9.1 Adquisición de datos para entrenamiento

Se emplearon imágenes infrarrojas de paneles solares provenientes de una base de datos pública proveniente de la página web Roboflow, enfocada en el uso de datos para entrenamientos de modelo de visión por computadora. A partir de este medio se seleccionó la base de datos de las fallas por puntos de calor en paneles solares, obteniendo en el formato adecuado para el respectivo entrenamiento.

Figura 2.5 Entorno de edición y etiquetado de imágenes de Roboflow



Este proceso incluyó la verificación de consistencia de etiquetas y la organización del repositorio en particiones para entrenamiento, validación y prueba.

Para representar condiciones reales de operación, se utilizaron imágenes de paneles con fallas externas proporcionadas por la empresa cliente. Estas imágenes permitieron incorporar variabilidad propia del entorno de instalación, como suciedad y daños superficiales, fortaleciendo la robustez del modelo ante escenarios de campo.

Figura 2.6 *Imágenes de paneles capturadas de bodega del cliente*

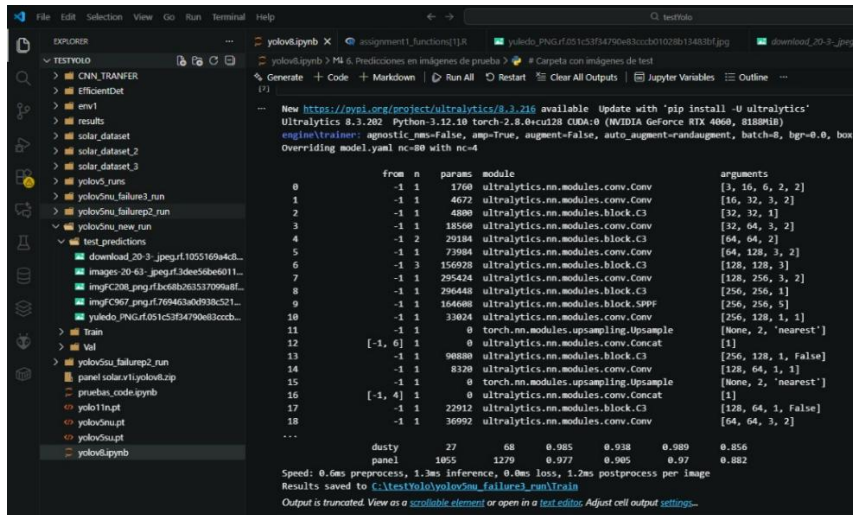


El entrenamiento del modelo de fallas internas se realizó con registros históricos obtenidos desde un registrador de datos del sistema fotovoltaico. Dichos registros incluyeron mediciones eléctricas y operativas asociadas al comportamiento del arreglo conectado de paneles.

Entrenamiento y validación de los modelos

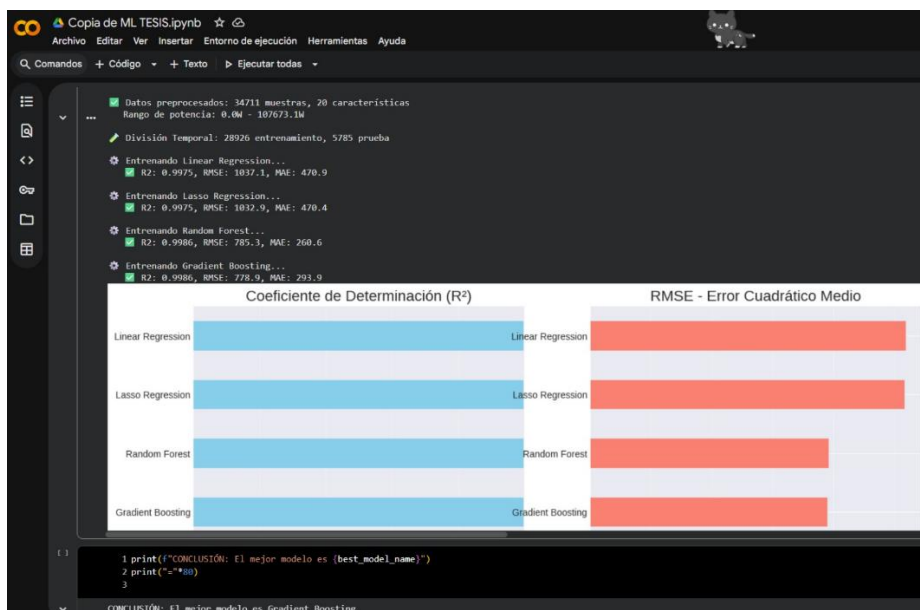
El entrenamiento del modelo de detección se realizó sobre los conjuntos de imágenes previamente etiquetados, donde se ejecutó un proceso estándar que incluyó: carga del conjunto de datos, ajuste de parámetros de entrenamiento, evaluación iterativa del desempeño y selección del mejor modelo según métricas de precisión. Posteriormente, el modelo final se exportó en un formato compatible con su ejecución en la Jetson.

Figura 2.7 Entorno de entrenamiento local del modelo YOLOV5



Para el análisis de fallas internas se entrenó un modelo basado en potenciación por gradiente, seleccionado por su capacidad para modelar relaciones no lineales en datos tabulares y su desempeño en tareas predictivas. El entrenamiento contempló la separación de datos en subconjuntos de entrenamiento y prueba, el ajuste de parámetros del modelo y la evaluación mediante métricas apropiadas para predicción.

Figura 2.8 Entrenamiento del modelo Gradient Boosting en Google Collab



CAPÍTULO 3

3.1 Resultados y análisis

En este capítulo se presentan los resultados y el análisis del prototipo desarrollado para la detección de fallas en paneles solares. Se reportó el desempeño del sistema de visión artificial mediante métricas, evidencia visual y tiempos de respuesta en la unidad de procesamiento embebida, junto con los resultados del modelo basado en variables eléctricas del registrador de datos para la identificación de anomalías internas. Además, se documentó la integración del sistema a través del almacenamiento y trazabilidad de inspecciones, así como capturas del panel web de visualización.

3.2 Resultados del sistema de control

En esta sección se presentaron los resultados obtenidos por el subsistema de visión artificial implementado en el prototipo, el cual se apoyó en dos modelos de detección entrenados para condiciones distintas: fallas térmicas mediante imágenes infrarrojas y fallas visibles externas a partir de imágenes proporcionadas por la empresa y fuentes complementarias.

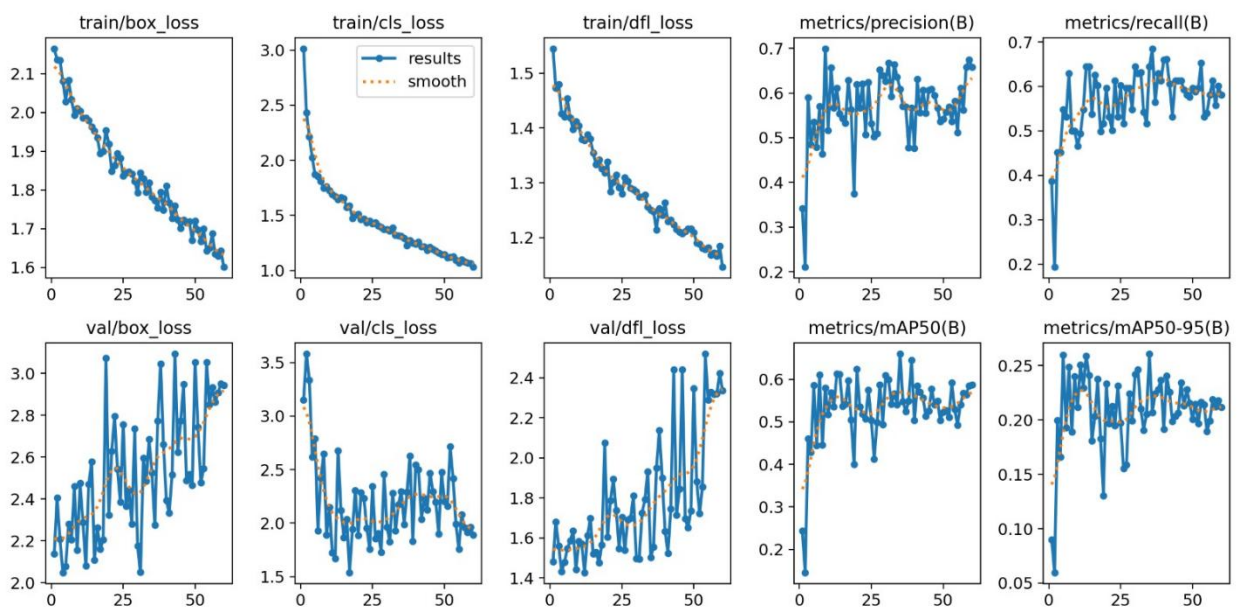
3.2.1 Evaluación del modelo de visión artificial para detección de falla por puntos calientes

Para la detección de puntos calientes se entrenó un modelo de detección de objetos utilizando imágenes infrarrojas, con el fin de identificar regiones de sobrecalentamiento asociadas a anomalías térmicas en paneles solares. El desempeño del modelo se evaluó mediante métricas cuantitativas de detección, análisis de error y revisión cualitativa de resultados.

Las curvas de entrenamiento evidenciaron una disminución progresiva de las pérdidas asociadas a la localización y clasificación durante el ajuste, lo cual indicó que el modelo aprendió patrones relevantes para delimitar la región térmica de interés. No obstante, en fase de validación las pérdidas mostraron oscilaciones y un aumento en las últimas épocas, lo que indicó que el modelo tuvo dificultades para generalizar cuando las escenas cambiaban en términos de


contraste térmico, reflejos o variaciones ambientales. En el mismo sentido, el indicador mAP a un umbral de intersección sobre unión de 0,5 se estabilizó en valores intermedios, mientras que el mAP promedio bajo umbrales más estrictos fue menor, lo cual sugirió que el modelo detectó la falla de forma relativamente consistente, pero con menor precisión para delimitar exactamente su extensión en todos los casos.

Figura 3.1 *Curvas de entrenamiento para puntos calientes*



La matriz de confusión evidenció que la clase punto caliente fue reconocida en la mayoría de las ocasiones, con un valor cercano a 0,84, mientras que aproximadamente 0,16 de los casos reales se omitieron y fueron clasificados como fondo. Estas omisiones se encuentran asociadas principalmente a puntos calientes poco marcados o con bordes térmicos difusos. Sin embargo, el resultado más relevante fue la presencia de falsos positivos: una proporción importante de escenas sin falla fue clasificada como punto caliente. Este comportamiento es consistente con situaciones donde existen zonas naturalmente más cálidas en el panel, bordes y conexiones con temperatura elevada, o gradientes térmicos que el modelo puede interpretar como anómalos.

Figura 3.2 *Matriz de Confusión Normalizada para puntos calientes*



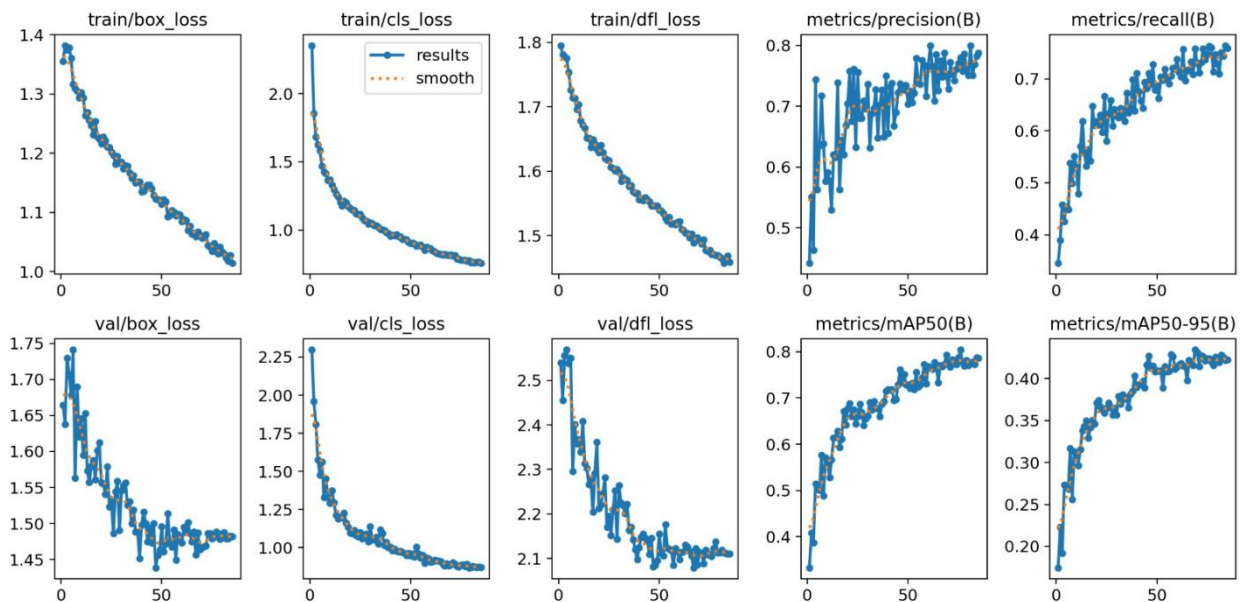
Las métricas del modelo infrarrojo en el entorno de programación mostraron capacidad para identificar puntos calientes con un desempeño aceptable y un comportamiento sensible, mostrando una precisión de reconocer la falla del 84%, pero su operación práctica requirió ajuste del umbral de confianza e hiperparámetros del modelo, con el fin de reducir sobre detección en fondos térmicamente complejos.

3.2.2 Evaluación del modelo de visión artificial para fallas visibles externas

Para la detección de fallas visibles se entrenó un segundo modelo de visión artificial orientado a identificar condiciones superficiales y defectos físicos observables en imágenes convencionales. A diferencia del modelo infrarrojo, este modelo trabajó con múltiples clases, entre las que destacaron: superficie cubierta, fisura, polvo y panel en estado normal. Su evaluación se realizó con las mismas métricas de detección, complementadas con la matriz de confusión normalizada con el objetivo de estudiar su confiabilidad en detectar fallas.

En las curvas de entrenamiento se evidenció una mejora sostenida del aprendizaje donde las pérdidas asociadas a localización y clasificación disminuyeron de forma progresiva, mientras que en validación se observó una reducción gradual con estabilización conforme el tiempo de entrenamiento transcurre. De manera coherente, las métricas globales mostraron una tendencia ascendente a lo largo del entrenamiento, alcanzando valores altos en precisión y cobertura, y una precisión media promedio a intersección sobre unión de 0,5 cercana al rango alto. La métrica promedio en umbrales mAP más exigentes se mantuvo en un valor intermedio, lo cual indicó que el modelo no solo logró reconocer la clase correcta, sino que también delimitó con buena exactitud los recuadros en una proporción importante de casos, aunque con limitaciones cuando los defectos fueron sutiles o difusos.


Figura 3.3 *Curvas de entrenamiento para fallas visibles externas*



La matriz de confusión permitió identificar con claridad el desempeño por clase. La clase fisura presentó el mejor reconocimiento, con un acierto cercano a 0,90, lo cual indicó que el patrón visual de la fisura fue altamente distintivo en el conjunto evaluado. El panel en estado normal también mostró un desempeño sólido, con un acierto cercano a 0,84, lo que evidencia que el

modelo aprendió a diferenciar adecuadamente paneles sin anomalías visibles. En contraste, las clases polvo y superficie cubierta presentaron mayores desafíos, con aciertos aproximados de 0,69 y 0,62 respectivamente.

Figura 3.4 *Matriz de Confusión Normalizada para fallas visibles externas*

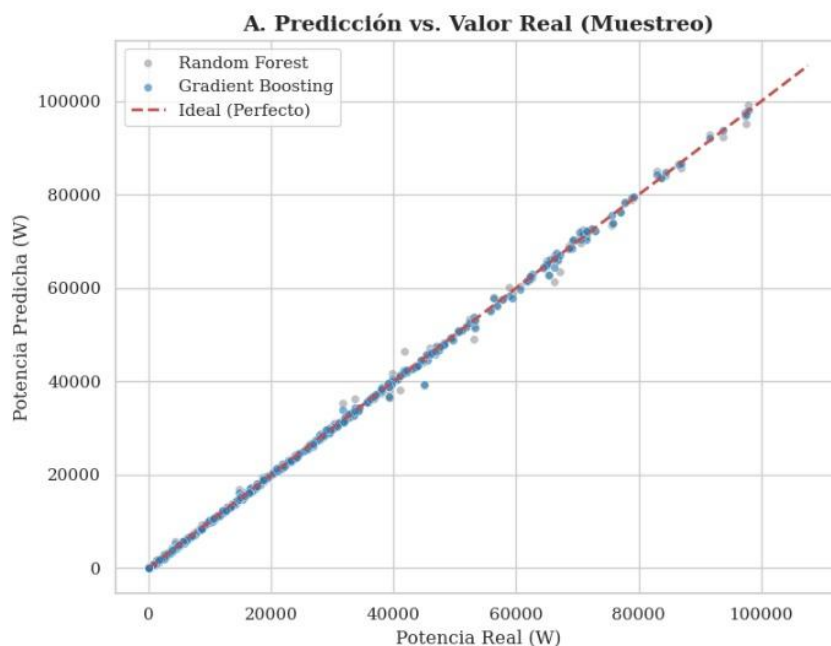


Un resultado esperable ya que el polvo suele manifestarse como una alteración gradual de textura y contraste, y la superficie cubierta puede variar en tamaño, forma y apariencia según el objeto o elemento que ocluye el panel. Además, en la matriz se observó que existió una proporción de instancias reales que fueron omitidas y asignadas como fondo, lo cual representó falsos negativos, especialmente en superficie cubierta y polvo.

3.2.3 Resultados del modelo de fallas internas mediante potenciación por gradiente

Para el análisis de fallas internas se desarrolló un modelo predictivo cuyo objetivo fue estimar la potencia esperada del sistema fotovoltaico a partir de variables eléctricas registradas por el registrador de datos. La idea central consistió en que, si la potencia real medida se alejaba de forma sostenida de la potencia estimada bajo condiciones comparables, dicha desviación podía interpretarse como un indicador de comportamiento anómalo que ameritaba revisión técnica. Con el fin de seleccionar la alternativa más conveniente, se compararon dos enfoques: **bosque aleatorio** y **potenciación por gradiente**, eligiéndose este último para su integración en el prototipo.

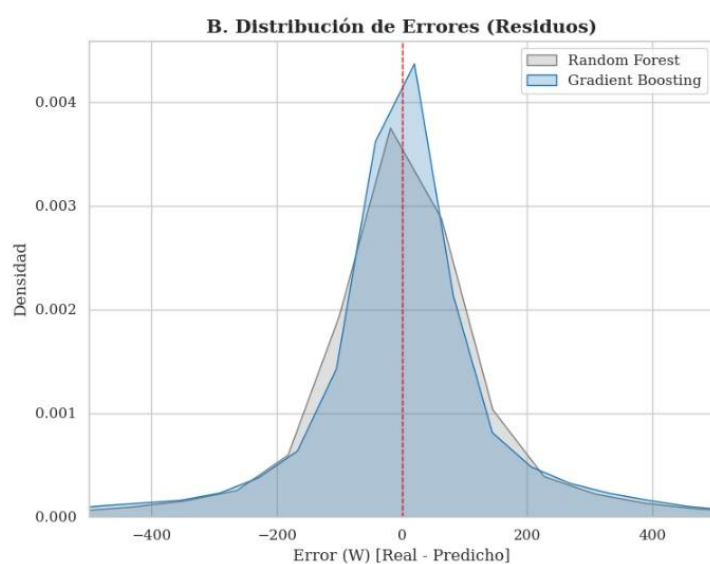
Figura 3.5 *Potencia estimada vs potencia real*



En la gráfica de **potencia estimada vs potencia real**, los puntos se concentraron alrededor de la línea ideal, lo que evidenció que el modelo predijo adecuadamente a lo largo de todo el rango de operación. Además, se observó que el conjunto correspondiente a potenciación por gradiente se mantuvo más cercano a la línea de referencia, coherente con sus menores valores de MAE y

RMSE. Por otro lado, La gráfica de **distribución de errores** (real menos estimado) mostró que los residuos se agruparon alrededor de cero, lo cual indicó ausencia de un sesgo marcado de sobreestimación inicial. Adicionalmente, la curva de potenciación por gradiente presentó una concentración más alta cerca del centro, sugiriendo que la mayor parte de sus predicciones tuvo errores pequeños, lo que fortaleció la decisión de selección para el despliegue final.

Figura 3.6 *Distribución de errores*



Para culminar, se realizó una tabulación de resumen del desempeño que mostró en el alcance de ambos modelos un ajuste muy alto, reflejado en valores de R^2 cercanos a 1, lo que indicó que la variación de la potencia real fue explicada casi en su totalidad por las variables de entrada.

Tabla 3.1 *Desempeño de los modelos*

Modelo	R^2 (precisión)	MAE (Error med.)	RMSE (Error cuad.)
Random forest / Bosque Aleatorio	0.9994	130.08 W	440.19 W
Gradient Boosting/ Potenciación por Gradiente	0.9997	117.65 W	326.87 W

La importancia relativa de variables evidenció que las corrientes tuvieron mayor contribución que los voltajes para explicar la potencia estimada, destacándose una corriente específica como la más influyente en el modelo. Desde un punto de vista operativo, este resultado fue coherente: cambios en corriente suelen reflejar de manera más directa variaciones en generación, sombreado parcial, degradación o desconexiones por cadena, mientras que el voltaje puede permanecer relativamente estable en ciertos regímenes de operación.

3.2.4 Interfaz de usuario y experiencia de operación

El sistema incorporó un panel web ejecutado localmente en la Jetson, accesible desde la red interna mediante el navegador, con el fin de simplificar la interacción del operario y concentrar el diagnóstico en un flujo guiado. La interfaz inició con una pantalla de ingreso seguro, lo que permitió controlar el acceso y reducir la exposición del sistema ante usos no autorizados.

Figura 3.7 Inicio de sesión



P Panel Fault Detector
Jetson powered

Ingreso seguro

Accede a tu planta y genera reportes profesionales.

Login Register

Usuario
usuario

Contraseña

Entrar

El administrador puede gestionar usuarios desde el panel interno.

Posteriormente, la pantalla principal habilitó la selección de planta y el acceso directo a los dos módulos de análisis: fallas visuales y fallas internas, manteniendo una estructura de navegación breve y orientada a la operación.

Figura 3.8 *Pantalla principal*

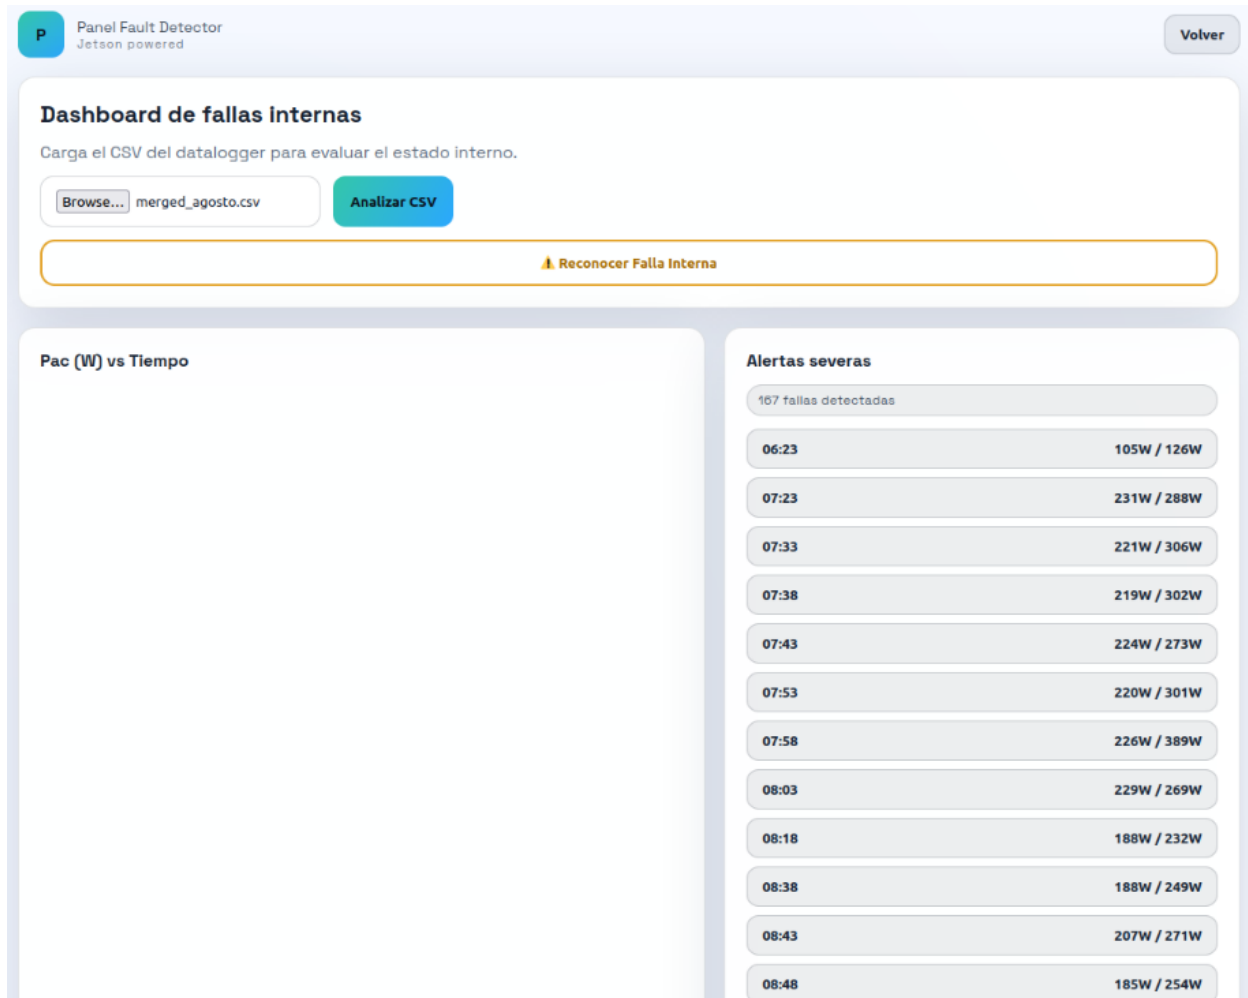
The screenshot displays the main interface of the 'Panel Fault Detector' application. The header includes the application name 'Panel Fault Detector Jetson powered' and the user session 'Sesion: Emilio Guerrero'. The main content area is titled 'Bienvenido' and prompts the user to 'Selecciona o registra una planta para continuar'. A dropdown menu shows 'Casa Guerrero (30 paneles)' and a status indicator 'Monitoreando: Casa Guerrero - GYE'. Below this are two buttons: 'Opción 1: Fallas visuales' (blue) and 'Opción 2: Fallas internas' (orange). The bottom section is titled 'Registrar nueva planta' and contains a form with fields for 'Nombre', '1' (with a dropdown arrow), 'Localizacion', '01 / 09 / 2026' (with a calendar icon), and 'Notas'. A blue 'Agregar planta' button is at the bottom of the form.

En el caso de inspecciones por imagen, el panel presentó el detalle del evento en una vista única, incluyendo la evidencia visual con el recuadro de detección, el número de hallazgos y un resumen de la confianza estimada. Esta organización facilitó una lectura rápida del estado y permitió que la revisión se realice sin interpretar salidas técnicas del modelo. Además, el sistema generó reportes descargables por inspección, lo que aportó trazabilidad y soporte documental para seguimiento.

Figura 3.9 Entorno de fallas visuales

Para el análisis interno, la interfaz contempló la carga de archivos de medición en formato tabular, la ejecución del procesamiento y la visualización de alertas, de modo que el usuario pudiera identificar anomalías sin depender de herramientas externas. En esta sección se puede observar las fallas detectadas a partir de la predicción con la que el modelo fue entrenado, indicando variables eléctricas del grupo de paneles conectados al registrador de datos solares.

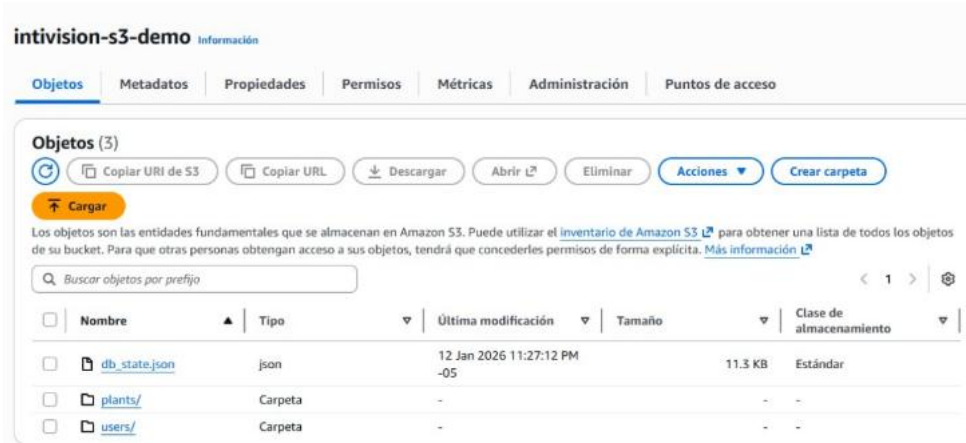
Figura 3.10 *Entorno de fallas internas*



3.2.5 Almacenamiento y trazabilidad de resultados

La persistencia de evidencias y resultados se resolvió mediante un repositorio en la nube basado en AWS S3, empleado como almacenamiento de objetos, capaz de conservar archivos heterogéneos, tales como imágenes, reportes y registros del sistema. Con el fin de mantener la seguridad y la privacidad, en el documento no se expusieron rutas reales ni identificadores directos de acceso, limitándose a describir la estructura lógica de almacenamiento y su función dentro del prototipo.

Figura 3.11 Repositorio AWS S3



La información se organizó por inspección, de manera que cada evento genera un conjunto coherente de evidencias asociadas a la planta y al usuario correspondiente. Como parte de esta estructura, el archivo “db_state.json” operó como un estado consolidado del sistema, registrando usuarios y plantas asignadas, y actualizándose conforme se realizaban modificaciones desde la interfaz. Esta separación lógica evitó cruces entre usuarios y plantas, ya que cada cuenta operó únicamente sobre su propio conjunto de datos, reforzando el principio de compartimentación.

3.3 Resultados del diseño mecánico del prototipo

El diseño mecánico del prototipo se enfocó en convertir la Jetson en un equipo portable y manipulable en entorno real, reduciendo riesgos de daño físico durante transporte, conexión y uso. Para ello se desarrolló una carcasa impresa en 3D que integra protección, orden interno y condiciones básicas de disipación térmica, manteniendo acceso directo a los elementos de operación del sistema.

3.3.1 Justificación y consideraciones de seguridad del ensamble

En términos de criterios de diseño, se priorizaron tres aspectos. Primero, el acceso funcional, mediante aberturas para los puertos necesarios y una geometría que permite conectar


cables sin forzar conectores. Segundo, la estabilidad mecánica, incorporando puntos de fijación y soporte interno para evitar movimiento del equipo dentro de la carcasa. Tercero, la ventilación, considerando ranuras y aperturas distribuidas para favorecer el intercambio de aire y reducir acumulación de calor durante operación continua, evitando degradación del rendimiento por temperatura del computador.

3.3.2 Modelado CAD y visualización del diseño

El encapsulado fue modelado en Autodesk Inventor, permitiendo definir una estructura paramétrica compuesta por cuerpo principal y tapa, con detalles orientados a manufactura aditiva. El conjunto incluye superficies de apoyo internas, puntos de tornillería, ranuras de ventilación y ventanas para conectores, manteniendo una geometría compacta que facilita su transporte y uso en campo. En este caso la **figura 3.12**, en A muestra el renderizado de la pieza que cubre al microprocesador y B muestra el proceso de toma de medidas con el uso de un calibrador Vernier.

Figura 3.12 Cobertura *Jetson Xavier NX*

A) Renderizado de la pieza que cubre al microprocesador, B) Mediciones Jetson Xavier NX



A)



B)

Para validar el proceso de manufactura del ensamblaje, el modelo se exportó y se preparó en Bambu Studio, donde se verificó la orientación de impresión, el ajuste del conjunto y la correcta separación entre tapa y base. La visualización del CAD y los renders del ensamblaje permiten evidenciar la distribución de aperturas, la ubicación de soportes y la lógica estructural del diseño, asegurando coherencia entre el modelo digital y el prototipo físico construido.

Figura 3.13 *Impresión 3D cobertura Jetson Xavier NX*



3.3.3 Integración de los componentes electrónicos

La integración de los componentes electrónicos se realizó directamente sobre el ensamblaje impreso en 3D, el cual funciona como soporte físico y elemento de protección para la unidad de procesamiento. En esta etapa, la Jetson se coloca dentro del cuerpo principal de la carcasa, quedando alineada con las ventanas laterales diseñadas para permitir el acceso a los puertos de alimentación, red y periféricos. En la **figura 3.14**, A muestra la disposición de la Jetson Xavier en el ensamblaje y B presenta la pieza con los periféricos conectados al microprocesador. Esta disposición reduce esfuerzos mecánicos sobre los conectores y evita manipulaciones innecesarias durante la operación.

Figura 3.14 Integración del sistema embebido

A) Disposición Jetson Xavier NX, B) Conexión de periféricos al microprocesador



A)



B)

3.4 Resultados del diseño electrónico y señalización del sistema

3.4.1 Desarrollo de la placa e integración con la Jetson

Para la señalización del estado del sistema se implementó una placa sencilla de indicadores luminosos, concebida como un módulo auxiliar de bajo costo y fácil mantenimiento. En este contexto, la placa integra diodos emisores de luz y resistencias limitadoras de corriente, además de conectores para alimentación y control, con el objetivo de proteger los componentes y asegurar una iluminación estable durante operación continua.

Su distribución priorizó orden y accesibilidad, permitiendo reemplazo rápido de un diodo o resistencia sin intervenir el resto del prototipo. La integración física se realizó dentro del encapsulado, de forma que los indicadores sean visibles desde el exterior y el cableado permanezca organizado y protegido. Las conexiones hacia la Jetson se dispusieron con longitudes mínimas y rutas definidas, reduciendo riesgo de desconexiones por manipulación y evitando interferencias con la ventilación interna del equipo.

3.5 Condiciones de prueba y validación en campo

La validación del prototipo se ejecutó mediante pruebas iterativas en un entorno controlado para verificación funcional del sistema y jornadas en campo para contrastar el desempeño bajo condiciones reales de operación. En campo se realizó adquisición de datos con apoyo de un dron para capturar vistas representativas de módulos fotovoltaicos e inspeccionar zonas de difícil acceso, complementando el análisis con revisiones presenciales.

Figura 3.15 *Adquisición de imágenes*

A) Personal manejando el dron de recolección de imágenes, B) Imágenes recolectadas de paneles solares




A)



B)

La verificación operativa incluyó la generación de reportes y su revisión directa en el panel web, donde se evidenció la trazabilidad de eventos y la lectura rápida del estado por planta. Como resultado práctico de estas pruebas, el sistema permitió identificar módulos con condición anómala y apoyar decisiones de mantenimiento, incluyendo la segregación y retiro de paneles dañados detectados durante inspecciones en otras instalaciones.

Figura 3.16 Paneles dañados

El acceso al panel se controló por credenciales y el contenido mostrado se limita a la planta asociada a cada usuario, reduciendo el riesgo de cruces de información entre instalaciones.

3.6 Análisis de Costos

Tabla 3.2 Costos de Materiales Electrónicos

Componentes	Costo Unitario (USD\$)	Cantidad	Subtotal (USD\$)
Jetson Xavier NX	275.00	1	250.00
Diodos Led	0.43	3	1.29
Resistencia de carbón 220 Ohms	0.08	3	0.24
Periféricos de control (mouse y teclado)	28.29	1	28.29
Periféricos de visualización (monitor)	58.99	1	58.99
SUBTOTAL			338,81

Tabla 3.3 Materiales de Impresión

Componentes	Costo Unitario (USD\$)	Cantidad	Subtotal (USD\$)
Filamento PLA 1000g	25.00	1	25.00
SUBTOTAL			25.00

Tabla 3.4 Mano de obra

Concepto	Tarifa (USD\$)	Horas	Subtotal (USD\$)
Entrenamiento e implementación de modelos de IA	12.00	20	240.00
Implementación de sitio web y acceso a usuario	10.00	15	150.00
Personal de toma de datos en campo	8.00	2	16.00
Extracción de paneles dañados	8.00	2	16.00
SUBTOTAL			422.00

Tabla 3.5 *Servicios y alquileres*

Concepto	Tarifa (USD\$)	Horas	Subtotal (USD\$)
Alquiler de equipo de cámara infrarroja para detección	35.00	5	175.00
Transporte y movilización de materiales extraídos	15.00	2	30.00
SUBTOTAL			205.00

Tabla 3.6 *Procesos de fabricación*

Componentes	Costo Unitario (USD\$)	Cantidad	Subtotal (USD\$)
Impresión 3D (filamento)	20.00	1	20.00
SUBTOTAL			20.00

Tabla 3.7 *Servicios en la nube*

Componentes	Costo Unitario (USD\$)	Cantidad	Subtotal (USD\$)
Servicios en la nube Amazon WS	5.00	1	5.00
SUBTOTAL			5.00

Tabla 3.8 *Inversión de proyecto total*

Rubro	Inversión (USD\$)
Costos de Materiales Electrónicos	338,81
Materiales de Impresión	25.00
Mano de obra	422.00
Servicios y alquileres	205.00
Procesos de Fabricación	20.00
Servicios en la nube	5.00
TOTAL	1 015,81

CAPÍTULO 4

4.1 Conclusiones y recomendaciones

En esta sección se sintetizan las conclusiones más relevantes, sustentadas en el desempeño de los modelos de visión y fallas internas, la trazabilidad lograda mediante reportes y almacenamiento, y la viabilidad de operación demostrada en pruebas de laboratorio y validación en campo. Finalmente, se plantean recomendaciones orientadas a fortalecer la generalización de los modelos, robustecer el prototipo y ampliar su alcance en futuras iteraciones.

4.1.1 Conclusiones

- Se consolidó una arquitectura operativa organizada, donde la Jetson ejecuta el procesamiento, gestiona el flujo de análisis y entrega resultados a través de un panel web con generación de reportes. Esta integración confirmó la viabilidad del prototipo para apoyar inspecciones y seguimiento, al permitir registrar eventos, visualizar evidencias y mantener trazabilidad sin depender de herramientas externas para interpretar el resultado.
- El sistema de visión artificial demostró capacidad para detectar fallas externas mediante dos enfoques complementarios, un modelo térmico para hotspot y un modelo visual multiclase. La evidencia gráfica y las métricas obtenidas validan su utilidad para identificar condiciones de interés en inspecciones manteniendo márgenes de precisión del 84% y 90% en clases de fallas importantes.
- El modelo de predicción para fallas internas evidenció un ajuste alto entre el valor real y el estimado, donde la comparación entre Random Forest y potenciación por gradiente mostró ventajas consistentes a favor de “Gradient Boosting”, reflejadas en mejores métricas agregadas y menor dispersión del error. Esto respaldó su selección como modelo principal para estimar la potencia esperada y detectar desviaciones de energía.
- La validación en campo permitió confirmar la aplicabilidad del prototipo en un entorno real, tanto para adquisición de datos como para verificación de resultados con el usuario

final. Durante las pruebas se lograron identificar paneles con condiciones degradadas y se fundamentó el uso del sistema como herramienta de apoyo para decisiones de mantenimiento acompañado de reportes descargables para seguimiento, y auditoría.

4.1.2 Recomendaciones

- Se recomienda ampliar el conjunto de datos de entrenamiento y validación incorporando mayor variabilidad de condiciones reales, como cambios de iluminación, diferentes inclinaciones, niveles de suciedad, sombras y distancias de captura. Esto permitiría reducir confusiones entre clases visualmente similares y mejorar la estabilidad del modelo cuando se despliegue en inspecciones no controladas.
- Para el módulo de fallas internas, se recomienda fortalecer la detección de anomalías incorporando criterios temporales y reglas de consistencia operativa, además de reportar el resultado con explicaciones breves orientadas al usuario, haciendo diagnósticos más interpretable y útil para priorizar acciones de mantenimiento sin requerir conocimiento técnico profundo.
- Se sugiere implementar un esquema de mantenimiento y actualización de modelos, que contemple registro de versiones, pruebas rápidas antes de reemplazar un modelo en producción y un procedimiento de retroceso en caso de degradación del desempeño. Con ello se mejora la continuidad del servicio, evitando introducir cambios sin validación y facilitando la mejora progresiva del sistema conforme se recolecten nuevas evidencias de fallas.

Referencias

- [1] “Rendición de Cuentas 2024 – Operador Nacional de Electricidad CENACE.” Accessed: Nov. 04, 2025. [Online]. Available: <https://www.cenace.gob.ec/rendicion-de-cuentas-2024/>
- [2] “P A N O R A M A ELÉCTRICO 2024 Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables”, Accessed: Nov. 04, 2025. [Online]. Available: www.controlrecursosyenergia.gob.ec
- [3] T. Rahman *et al.*, “Investigation of Degradation of Solar Photovoltaics: A Review of Aging Factors, Impacts, and Future Directions toward Sustainable Energy Management,” *Energies* 2023, Vol. 16, Page 3706, vol. 16, no. 9, p. 3706, Apr. 2023, doi: 10.3390/EN16093706.
- [4] A. N. Chicaiza Macias, “Estudio del comportamiento de paneles fotovoltaicos bajo diversas condiciones climatológicas mediante herramientas de programación,” 2024, Accessed: Nov. 04, 2025. [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/27297>
- [5] B. N. Tapia del Pino, “Impacto de las condiciones climáticas en paneles fotovoltaicos con envejecimiento simulado,” 2023, *PUCE - Quito*. Accessed: Nov. 04, 2025. [Online]. Available: <https://repositorio.puce.edu.ec/handle/123456789/21017>
- [6] W. Su, R. Guo, J. Li, Y. Zhang, and Z. Zhang, “Numerical Study on Different Shapes of Heat Shields in Continuous Czochralski Silicon,” *Silicon* 2025 17:5, vol. 17, no. 5, pp. 1153–1163, Feb. 2025, doi: 10.1007/S12633-025-03253-3.
- [7] I. Ambiental, A. Joel Zapana Marchan Chris Andersson Aucchahuaque Mariñas Asesor, and M. Sc Gladys Sandi Licapa Redolfo, “Estudio comparativo del rendimiento de paneles fotovoltaicos monocristalinos y policristalinos,” *Universidad Privada del Norte*, Nov. 2021, Accessed: Nov. 02, 2025. [Online]. Available: <https://repositorio.upn.edu.pe/handle/11537/29199>
- [8] N. Fernando, L. Seneviratne, N. Weerasinghe, N. Rathnayake, and Y. Hoshino, “Efficient Hotspot Detection in Solar Panels via Computer Vision

- and Machine Learning,” *Information 2025, Vol. 16, Page 608*, vol. 16, no. 7, p. 608, Jul. 2025, doi: 10.3390/INFO16070608.
- [9] O. Bamisile, C. Acen, D. Cai, Q. Huang, and I. Staffell, “The environmental factors affecting solar photovoltaic output,” *Renewable and Sustainable Energy Reviews*, vol. 208, p. 115073, Feb. 2025, doi: 10.1016/J.RSER.2024.115073.
- [10] T. Tajwar, S. F. Hossain, O. Hassan Mobin, M. Islam, F. R. Khan, and M. Mosaddequr Rahman, “Infrared Thermography Based Hotspot Detection of Photovoltaic Module using YOLO,” *Proceedings of the Energy Conversion Congress and Exposition - Asia, ECCE Asia 2021*, pp. 1542–1547, May 2021, doi: 10.1109/ECCE-ASIA49820.2021.9478998.
- [11] “Güneş Panellerinde Hotspot Oluşumu ve Zararları - Reset Solar Temizleme.” Accessed: Nov. 13, 2025. [Online]. Available: <https://resetsolartemizleme.com/gunes-panellerinde-hotspot-olusumu-ve-zararlari/>
- [12] M. C. Alonso-García, W. Herrmann, W. Böhmer, and B. Proisy, “Thermal and electrical effects caused by outdoor hot-spot testing in associations of photovoltaic cells,” *Progress in Photovoltaics: Research and Applications*, vol. 11, no. 5, pp. 293–307, Aug. 2003, doi: 10.1002/PIP.490;CTYPE:STRING:JOURNAL.
- [13] M. Karimi, H. Samet, T. Ghanbari, and E. Moshksar, “A current based approach for hotspot detection in photovoltaic strings,” *International Transactions on Electrical Energy Systems*, vol. 30, no. 9, p. e12517, Sep. 2020, doi: 10.1002/2050-7038.12517;ISSUE:ISSUE:DOI.
- [14] M. K. Alam, F. Khan, J. Johnson, and J. Flicker, “A Comprehensive Review of Catastrophic Faults in PV Arrays: Types, Detection, and Mitigation Techniques,” *IEEE J Photovolt*, vol. 5, no. 3, pp. 982–997, May 2015, doi: 10.1109/JPHOTOV.2015.2397599.
- [15] H. D. Molina-Ruiz, V. K. K. Tangirala, L. Martínez-Ayala, and A. G. Hernández-Zanabria, “Microfracturas en paneles solares y sus implicaciones en la producción de energía,” *TEPEXI Boletín Científico de la Escuela*

- Superior Tepeji del Río*, vol. 6, no. 12, pp. 9–13, Jul. 2019, doi: 10.29057/ESTR.V6I12.4288.
- [16] “Massive increase’ in solar module defects poses risk to industry.” Accessed: Nov. 13, 2025. [Online]. Available: <https://www.pv-tech.org/massive-increase-in-solar-module-defects-poses-significant-risk-to-pv-industry-cea/>
- [17] M. Dhimish, V. Holmes, B. Mehrdadi, and M. Dales, “The impact of cracks on photovoltaic power performance,” *Journal of Science: Advanced Materials and Devices*, vol. 2, no. 2, pp. 199–209, Jun. 2017, doi: 10.1016/J.JSAMD.2017.05.005.
- [18] L. Micheli and M. Muller, “An investigation of the key parameters for predicting PV soiling losses,” *Progress in Photovoltaics: Research and Applications*, vol. 25, no. 4, pp. 291–307, Apr. 2017, doi: 10.1002/PIP.2860.
- [19] S. Yang, A. Bryant, P. Mawby, D. Xiang, L. Ran, and P. Tavner, “An industry-based survey of reliability in power electronic converters,” *IEEE Trans Ind Appl*, vol. 47, no. 3, pp. 1441–1451, May 2011, doi: 10.1109/TIA.2011.2124436.
- [20] L. Morando, C. T. Recchiuto, J. Calla, P. Scuteri, and A. Sgorbissa, “Thermal and Visual Tracking of Photovoltaic Plants for Autonomous UAV Inspection,” *Drones 2022, Vol. 6, Page 347*, vol. 6, no. 11, p. 347, Nov. 2022, doi: 10.3390/DRONES6110347.
- [21] S. Silva, R. Juan, and V. Uribe, “Predicción del Consumo Eléctrico mediante Análisis de Big Data y Series Temporales Corporación Universitaria Remington. Nombre de la facultad: Facultad de Ingenierías Nombre del programa académico: Ingeniería de Sistemas”.
- [22] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016-December, pp. 779–788, Jun. 2015, doi: 10.1109/CVPR.2016.91.
- [23] R. Khanam and M. Hussain, “What is YOLOv5: A deep look into the internal features of the popular object detector,” Jul. 2024, Accessed: Nov. 03, 2025. [Online]. Available: <https://arxiv.org/pdf/2407.20892v1>

- [24] M. Alameri and Q. A. Memon, "YOLOv5 Integrated With Recurrent Network for Object Tracking: Experimental Results From a Hardware Platform," *IEEE Access*, vol. 12, pp. 119733–119742, 2024, doi: 10.1109/ACCESS.2024.3442822.
- [25] "YOLOv5 network structure | Download Scientific Diagram." Accessed: Nov. 13, 2025. [Online]. Available: https://www.researchgate.net/figure/YOLOv5-network-structure_fig1_392295689
- [26] D. Noah, M. Olivia, S. Liam, and W. Elijah, "Adaptive Inference Strategies for Enhanced Lightweight YOLOv5 Deployment," *ResearchGate*, Sep. 2024, Accessed: Nov. 03, 2025. [Online]. Available: https://www.researchgate.net/publication/385103674_Adaptive_Inference_Strategies_for_Enhanced_Lightweight_YOLOv5_Deployment
- [27] T. Tajwar, S. F. Hossain, O. Hassan Mobin, M. Islam, F. R. Khan, and M. Mosaddequr Rahman, "Infrared Thermography Based Hotspot Detection of Photovoltaic Module using YOLO," *Proceedings of the Energy Conversion Congress and Exposition - Asia, ECCE Asia 2021*, pp. 1542–1547, May 2021, doi: 10.1109/ECCE-ASIA49820.2021.9478998.
- [28] J. H. Friedman, "Greedy function approximation: A gradient boosting machine.," <https://doi.org/10.1214/aos/1013203451>, vol. 29, no. 5, pp. 1189–1232, Oct. 2001, doi: 10.1214/AOS/1013203451.
- [29] S. Rinesh *et al.*, "Prediction and classification of solar photovoltaic power generation using extreme gradient boosting regression model," *International Journal of Low-Carbon Technologies*, vol. 19, pp. 2420–2430, Jan. 2024, doi: 10.1093/IJLCT/CTAE197.
- [30] "Rendición de cuentas 2024 CENACE," OPERADOR NACIONAL DE ELECTRICIDAD. Accessed: Nov. 04, 2025. [Online]. Available: https://www.cenace.gob.ec/wp-content/uploads/downloads/2025/06/Informe-de-rendicion-de-cuentas-2024_CENACE_preliminar.pdf