


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
SANTIAGO – CHILE



**“Clasificación automatizada de fallas en módulos
fotovoltaicos mediante análisis de curvas I-V”**

VICTOR SCOTT SMITH ROMERO

**MEMORIA DE TITULACIÓN PARA OPTAR AL TÍTULO DE:
INGENIERO CIVIL MECÁNICO**

PROFESOR GUÍA: PhD. DANILO ESTAY B.
**PROFESOR CORREFERENTE: PhD. RODRIGO
BARRAZA V.**

Marzo – 2026



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título Tesis de Postgrado

Título del trabajo: "Clasificación automatizada de fallas en módulos fotovoltaicos mediante análisis de curvas I-V"

Nombre del candidato(a): Victor Scott Smith Romero

Carrera / Grado: Ingeniería Civil Mecánica / Ingeniero Civil Mecánico

Campus: San Joaquín Departamento: Ingeniería Mecánica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Danilo Estay Barrientos, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

6 meses 12 meses 2 años 3 años 5 años 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 09-03-2026

Firma:

Estudiante o Candidato(a):

Fecha: 09-03-2026

Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

AGRADECIMIENTOS

Agradezco profundamente a mi familia, comenzando por mi madre Jeny, quien me ha entregado el apoyo más fuerte durante todos los momentos de mi vida, a mi tía Maricela, mi abuela Bernarda y mis hermanos Mikahella, Benjamín y Florencia, quienes siempre han estado a mi lado, y por último a mi padre Richard, que a pesar de todas las circunstancias siempre creyó en mí y me entregó lo mejor de él.

Al equipo del Laboratorio de Energía Solar, por toda esa energía “fotovoltaica” generada, en especial al Profesor Rodrigo Barraza, Valentina Arias, Valentina Navarro y Valentina González, son unas personas geniales y excelentes profesionales, sin dudarlos son el mejor equipo que un laboratorio puede tener.

A mis amigos de la universidad, en especial a Javiera, klaus y el Sr. Baros, con quienes formamos una complicidad única, gracias por el apoyo en momentos cruciales, por todas las risas y charlas abstractas compartidas.

A mis amigos que no forman parte de mi ámbito universitario, gracias por estar presentes, por las conversaciones, los consejos y por ayudarme a mantenerme de pie cuando todo se caía. A todos los que han sido parte de este viaje, mi sincero agradecimiento.

Y por último, a todas las personas que ya no forman parte de mi vida, pero que aun así fueron parte importante de mi proceso de formación académica y personal.

Encontrarme con cada uno de ustedes ha sido una grata experiencia, me han permitido crecer, aprender y desarrollarme a lo largo de mi estadía en este infinito universo que he renderizado.

RESUMEN

Esta memoria presenta el desarrollo de una metodología automatizada para la clasificación de fallas en módulos fotovoltaicos monofaciales, mediante el análisis de sus curvas corriente-tensión (I-V). Las curvas fueron obtenidas a partir de ensayos realizados en el simulador solar “Temperature Controlled Laboratory Flasher” (TCLF), bajo condiciones controladas, y posteriormente sometidas a un procesamiento computacional basado en técnicas de inteligencia artificial y visión por computador.

El enfoque metodológico consistió en transformar las curvas I-V en imágenes mediante el uso de Gramian Angular Difference Fields (GADF), permitiendo capturar información estructural completa de la curva. Se construyó una base de datos de 75 curvas, incluyendo tanto módulos en buen estado como defectuosos. Se desarrollaron dos modelos de clasificación: uno basado en análisis de porcentaje de color en sectores clave de la imagen, y otro empleando redes neuronales convolucionales (CNN) entrenadas sobre imágenes GADF etiquetadas.

La metodología permitió identificar con alta precisión distintas fallas representativas, tales como degradación por resistencia serie o paralelo, cortocircuito, sombreado parcial y errores de medición. Se alcanzaron precisiones superiores al 99% en la clasificación de fallas con la CNN entrenada, y se implementó un sistema de generación automatizada de reportes individuales por módulo, consolidando resultados cuantitativos y visuales.

Se concluye que el uso combinado de transformaciones GADF y aprendizaje profundo permite implementar un sistema confiable, rápido y escalable para el diagnóstico de módulos fotovoltaicos, lo que representa un aporte significativo al mantenimiento predictivo en plantas solares.

ABSTRACT

This thesis presents the development of an automated methodology for the fault characterization of monofacial photovoltaic modules, based on the analysis of their current-voltage (I-V) curves. These curves were obtained through tests conducted in the “Temperature Controlled Laboratory Flasher” (TCLF) solar simulator under controlled conditions, and subsequently processed using computer-based techniques involving artificial intelligence and computer vision.

The methodological approach involved transforming I-V curves into images using Gramian Angular Difference Fields (GADF), enabling the extraction of complete structural information from the curves. A database of 75 I-V curves was constructed, including both healthy and faulty modules. Two classification models were developed: one based on analyzing the percentage of color in specific sectors of the images, and another using convolutional neural networks (CNN) trained on labeled GADF images.

This methodology successfully identified key fault types—such as series and shunt resistance degradation, short circuits, partial shading, and measurement errors—with classification accuracies above 99% using the CNN model. Additionally, an automated reporting system was implemented to generate individual reports per module, consolidating both quantitative results and visual data.

The study concludes that the combined use of GADF transformations and deep learning enables the implementation of a reliable, fast, and scalable fault diagnosis system for PV modules, representing a significant contribution to predictive maintenance in solar power plants.

GLOSARIO

FV	Fotovoltaico.
ERNC	Energías Renovables no Convencionales.
IEC	International Electrotechnical Commission.
I-V	Corriente – Voltaje.
STC	Standard Test Condition.
TCLF	Temperature Controlled Laboratory Flasher.
Isc	Corriente de Cortocircuito.
Voc	Voltaje de Circuito bierto.
Imp	Corriente Máxima de Potencia.
Vmp	Voltaje Máxima de Potencia.
ID	Identificador Único
CNN	Convolutional Neural Network
GADF	Gramian Angular Difference Field
EM2	Error de Medición 2
EM1	Error de Medición 1
Rs	Resistencia en Serie
Rsh	Resistencia en Paralelo

ÍNDICE

AGRADECIMIENTOS.....	2
RESUMEN.....	3
ABSTRACT.....	4
GLOSARIO.....	5
ÍNDICE.....	6
1 Introducción.....	13
2 Objetivos.....	15
Objetivo General:.....	15
Objetivos Específicos:.....	15
3 Estado del Arte.....	16
3.1 Fundamentos de la Energía Solar Fotovoltaica.....	18
3.2 Diagnóstico de Falla en Módulos Fotovoltaicos.....	20
3.2.1 Análisis de Curvas Corriente-Tensión (I-V).....	20
3.2.2 Electroluminiscencia.....	21
3.2.3 Termografía Infrarroja.....	22
3.2.4 Limitaciones y evolución hacia métodos automatizados.....	22
3.3 Fallas Típicas en Módulos Fotovoltaicos y su Impacto en Curvas I-V.....	23
3.3.1 Clasificación General de Fallas.....	23
3.3.2 Manifestación de Fallas en Curvas I-V.....	24
3.3.3 Impacto de Fallas sobre la Curva I-V.....	25
3.3.4 Consideraciones Normativas.....	27
3.4 Diagnóstico Automatizado de Fallas en Módulos Fotovoltaicos.....	28
3.4.1 Evolución de los Métodos de Diagnóstico.....	28

3.4.2	Machine Learning en Diagnóstico Fotovoltaico.....	28
3.4.3	Transformaciones de la Curva I-V: Gramian Angular Difference Field (GADF) y Recurrence Plot (RP).....	29
	Gramian Angular Difference Field (GADF)	30
	Recurrence Plot (RP).....	31
3.4.4	Ventajas de los Métodos Automatizados.....	31
3.4.5	Limitaciones y Desafíos Actuales.....	32
4	Metodología.....	33
4.1	Caracterización Experimental de Módulos Fotovoltaicos.....	33
4.1.1	Módulos Fotovoltaicos Ensayados	33
4.1.2	Equipamiento Utilizado	33
4.1.3	Condiciones de Medición	35
4.1.4	Procedimiento Experimental.....	35
4.2	Desarrollo de la Base de Datos.....	37
4.2.1	Generación de Curvas Ideales.....	37
4.2.2	Adquisición de Curvas I-V	38
4.2.3	Normalización de Curvas I-V.....	39
	Proceso de Normalización	40
4.2.4	Transformación de Curvas a Imágenes GADF.....	41
	Método de Transformación GADF.....	41
	Generación de Imágenes GADF Ideales.....	42
	Relación Espacial entre la Curva I-V y la Imagen GADF.....	44
	Relación Espacial Imagen Transformada GADF I.....	45
	Relación Espacial Imagen Transformada GADF V	46

4.2.5	Organización y Consolidación del Dataset	47
4.3	Implementación de Modelos de Clasificación Automatizada	49
4.3.1	Clasificación mediante Redes Neuronales Convolucionales (CNN)	50
	Preprocesamiento de Imágenes para Entrenamiento	51
	Arquitectura de los Modelos CNN	52
	Justificación de la Arquitectura	53
	Entrenamiento de los Modelos	53
	Especialización de Modelos CNN por Tipo de Falla	56
4.3.2	Clasificación mediante Análisis de Porcentaje de Color	57
	Metodología General del Análisis Sectorial	57
	Clasificadores Implementados por Falla	58
5	Resultados y Discusión	63
5.1	Esquema General del Sistema Automatizado	63
5.1.1	Implementación del sistema en Python	64
5.1.2	Estructura del Diccionario de Resultados	66
5.2	Resultados de la Caracterización Experimental	68
5.3	Resultados de Clasificación por Análisis de Porcentaje de Color	69
5.4	Resultados de Clasificación mediante Redes Neuronales Convolucionales	72
5.4.1	Resultados para Clasificador EM1	73
	Clasificación Individual de Módulos EM1	74
5.4.2	Resultados para Clasificador Falla 3 (Disminución Rsh)	75
	Clasificación Individual de Módulos Falla 3	77
5.5	Generación de Reporte Automatizado por Módulo	78
	Estructura del Reporte por Módulo	78

5.6	Discusión General y Limitaciones.....	80
	Robustez del Sistema Propuesto	81
	Principales Limitaciones Identificadas	81
6	Conclusiones y Recomendaciones.....	82
6.1	Conclusiones Generales	82
6.2	Recomendaciones para Investigaciones Futuras	83
7	Bibliografía	85
8	ANEXOS	87
8.1	Ficha técnica de modulo policristalino Marca ASTRONERGY	87
8.2	Códigos fuente del algoritmo de clasificación automatizada	88
8.3	Reporte General de Fallas	89
8.4	Resultados entrenamiento de modelos CNN.....	91

INDICE DE FIGURAS

Figura 1: Capacidad neta instalada en Chile, renovables, ERNC y proyección a abril 2025. (CNE)	16
Figura 2: Forma general curva I-V	19
Figura 3: Diagrama de flujo de sistema automatizado de clasificación.	22
Figura 4: Deformaciones típicas de curvas I-V por tipo de falla (Barrenetxea Pascual, A)	25
Figura 5: Flujo del proceso de diagnóstico automatizado.	26
Figura 5: Algoritmos de machine learning aplicados al diagnóstico de módulos fotovoltaicos.	29
Figura 7: Flujo diagnóstico automatizado basado en GADF + CNN.	32
Figura 8: Simulador solar tipo TCLF del Laboratorio Solar Indoor UTFSM.	34
Figura 9: Protocolo de adquisición de curvas I-V con simulador TCLF.	36
Figura 10: Curvas I-V ideales generadas mediante función Lambert W.	38
Figura 11: Curva I-V módulo monofacial 1 respecto a su curva ideal STC.	39
Figura 12: Comparación entre curva I-V medida y curva normalizada para el módulo 1.	40
Figura 13: Transformadas GADF resultante para módulo 4.	42
Figura 14: Transformadas GADF resultante para módulo Astronergy ideal.	43
Figura 15: Transformadas GADF resultante para módulo SunEdison ideal.	44
Figura 16: Mapas de secciones Transformada GADF I y curva I-V modulo 4.	45
Figura 17: Mapas de secciones Transformada GADF V y curva I-V modulo 4.	46
Figura 18: Estructura del set de datos generado por módulo.	47
Figura 19: Ejemplo de imágenes transformada GADF generadas para el módulo 7,	48
Imagen GADF I (izquierda) e Imagen GADF V (derecha).	48
Figura 20: Estructura carpetas de preprocesamiento de imágenes.	51
Figura 21: Flujo de entrenamiento y clasificación CNN.	52
Figura 22: Ejemplo de imagen transformada GADF V sin error (izquierda) y con error (derecha).	54
Figura 23: Región de interés en imagen transformada GADF V para clasificación de la falla 3.	54

Figura 24: Ejemplo de recortes sector inferior izquierdo de imagen transformada GADF V módulo monofacial 9, correspondiente a recortes 3x3 hasta 8x8.....	55
Figura 25: Ejemplo de recortes sector inferior izquierdo contiguo (sector x_1) de imagen transformada GADF V módulo monofacial 9, correspondiente a recortes 3x3 hasta 8x8.	55
Figura 26: Imágenes generadas para modelo CNN falla 3, módulo monofacial 9.....	56
Figura 27: Flujo de análisis de porcentaje de color en imágenes GADF.	57
Figura 28: Cuadrante inferior izquierdo de imágenes seleccionadas para análisis falla 3, ejemplo módulo con error de medición (izquierda) y módulo sin error de medición (derecha).	58
Figura 29: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 1 presente mediante clasificación 1.....	59
Figura 30: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 1 presente mediante clasificación 1.....	59
Figura 31: Región inferior izquierda de la imagen GADF I, detalle sección 3_0 y 3_1 en grilla de 4x4.....	60
Figura 32: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 5 presente.....	61
Figura 33: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 5 presente.....	61
Figura 34: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 6 presente.....	62
Figura 35: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 6 presente.....	62
Figura 36: Ejemplo de la estructura del diccionario para módulo monofacial 1.....	67
Figura 37: Estructura del diccionario para módulo monofacial Astronergy (ideal) y SunEdison (ideal).....	67
Figura 38: Ejemplos de curvas con errores de medición.....	69
Figura 39: Estructura carpeta de reportes para módulos clasificados.....	79
Figura 40: Ejemplo reporte general automatizado para módulo 1.....	79
Figura 41: Ficha Técnica módulo policristalino marca Astronergy.....	88

ÍNDICE DE TABLAS

Tabla 1: Comparación de impacto de fallas en curvas I-V.....	26
Tabla 2: Relación entre tipo de falla y curva I-V.	26
Tabla 3: Impacto de distintas fallas sobre la curva I-V.	27
Tabla 4: Características de los módulos fotovoltaicos ensayados.....	33
Tabla 5: Descripción de scripts del sistema de clasificación automatizada	65
Tabla 6: Resumen resultados caracterización experimental 75 módulos	68
Tabla 7: Resultados de precisión de modelos CNN en validación.....	73
Tabla 8: Matriz de confusión para el modelo CNN EM1.....	74
Tabla 9: Reporte de clasificación del modelo EM1.	74
Tabla 10: Matriz de confusión para el modelo CNN Falla 3.....	76
Tabla 11: Reporte de clasificación del modelo Falla 3.	76
Tabla 12: Reporte general de clasificación de fallas por módulo.....	899
Tabla 13: Evolución de métricas durante el entrenamiento modelo CNN Falla 3	911
Tabla 14: Evolución de métricas durante el entrenamiento modelo CNN EM1	922

1 Introducción

La energía solar fotovoltaica se ha consolidado como una de las principales fuentes de energía renovable, desempeñando un papel crucial en la transición hacia un futuro más sostenible. La creciente preocupación por el cambio climático y la necesidad de reducir las emisiones de gases de efecto invernadero han impulsado la adopción de tecnologías de energía limpia, alineándose con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas, particularmente el ODS 7, que busca garantizar el acceso a una energía asequible, fiable, sostenible y moderna para todos (Naciones Unidas, 2015).

Chile, debido a sus condiciones climáticas privilegiadas, especialmente en la zona norte del país, se ha posicionado como líder regional en la generación solar fotovoltaica, destacando por su elevado factor de planta y radiación promedio. Este crecimiento ha impulsado la instalación de numerosas plantas solares a gran escala, cuya operación y mantenimiento requieren estrategias eficaces de monitoreo y diagnóstico para asegurar su funcionamiento óptimo durante toda su vida útil (Ministerio de Energía de Chile, 2023). No obstante, como en todo sistema tecnológico, los módulos fotovoltaicos están expuestos a procesos de degradación y fallas que pueden disminuir significativamente su rendimiento y afectar la rentabilidad de las instalaciones.

Las fallas en los módulos fotovoltaicos pueden originarse por múltiples causas, entre ellas defectos de fabricación, microfisuras generadas durante el transporte o instalación, o efectos de condiciones ambientales severas como alta radiación UV, humedad, polvo o ciclos térmicos. La detección temprana y caracterización precisa de estas fallas es esencial para minimizar pérdidas de eficiencia y garantizar el retorno de inversión en proyectos solares (Mellit, Tina & Kalogirou, 2018).

Entre las metodologías más utilizadas para la detección de fallas se encuentran la inspección visual, la termografía infrarroja, la electroluminiscencia y el análisis de curvas corriente-tensión (I-V). Esta última es una técnica no destructiva que permite evaluar el desempeño eléctrico del módulo bajo condiciones controladas, y ha sido ampliamente adoptada en contextos industriales y académicos por su confiabilidad y capacidad para identificar diversas tipologías de fallas (Livera et al., 2019).

Estudios recientes han combinado estas técnicas para mejorar la capacidad de diagnóstico, por ejemplo, integrando imágenes de electroluminiscencia con curvas I-V, lo cual ha demostrado ser eficaz, aunque requiere interpretación manual y puede estar sujeta a criterios subjetivos del operador. Para enfrentar estas limitaciones, investigaciones contemporáneas han comenzado a aplicar herramientas de inteligencia artificial, particularmente algoritmos de aprendizaje automático, para automatizar la detección y clasificación de fallas en módulos solares, utilizando como fuente primaria de información las curvas I-V (Li, Delpha, Migan-Dubois & Diallo, 2021).

La masificación de la energía solar en la matriz energética requiere contar con metodologías de diagnóstico más eficientes, robustas y objetivas, que permitan mantener la integridad y rendimiento de los sistemas fotovoltaicos en el tiempo. En este contexto, esta memoria tiene como propósito desarrollar un modelo automatizado para la clasificación de fallas en módulos fotovoltaicos monofaciales, basado en el análisis de curvas I-V obtenidas mediante ensayos en un simulador solar tipo "Temperature Controlled Laboratory Flasher" (TCLF), ubicado en el Laboratorio Solar Indoor de la Universidad Técnica Federico Santa María.

2 Objetivos

Objetivo General:

- Desarrollar un modelo de clasificación de fallas presentes en módulos fotovoltaicos monofaciales, mediante el análisis de sus curvas corriente-tensión (I-V) obtenidas a través de ensayos en simulador solar “Temperature Controlled Laboratory Flasher” (TCLF) presente en el Laboratorio Solar Indoor UTFSM.

Objetivos Específicos:

- Realizar una revisión bibliográfica del comportamiento de las curvas I-V según distintas fallas presentes en módulos fotovoltaicos monofaciales.
- Caracterizar módulos fotovoltaicos defectuosos a través de curva I-V mediante ensayos en simulador solar TCLF.
- Desarrollar una base de datos con imágenes estandarizadas de curvas I-V, que permita comparar el desempeño de cada módulo fotovoltaico defectuoso con respecto a su curva I-V ideal.
- Elaborar un modelo automatizado, utilizando técnicas de procesamiento de imágenes, que permitan relacionar las diferentes fallas típicas en módulos fotovoltaicos monofaciales con el comportamiento de las curvas I-V de la base de datos.

3 Estado del Arte

La energía solar se ha consolidado como una de las fuentes de energía renovable no convencional más prometedoras y de más rápido crecimiento a nivel global. Su principio de funcionamiento se basa en la conversión directa de la radiación solar en electricidad mediante el efecto fotovoltaico, proceso que ocurre en materiales semiconductores dentro de las celdas solares. Esta tecnología ha resultado fundamental en la transición hacia una matriz energética más limpia, al disminuir la dependencia de combustibles fósiles y reducir considerablemente las emisiones de gases de efecto invernadero (Naciones Unidas, 2015).

En las últimas décadas, la capacidad instalada de sistemas fotovoltaicos ha crecido de forma exponencial, impulsada por el desarrollo tecnológico, la disminución de costos de los módulos y componentes, y los compromisos internacionales para combatir el cambio climático (IEA-PVPS, 2014). En este contexto, Chile ha ocupado un rol destacado, especialmente gracias al excepcional nivel de irradiación solar del Desierto de Atacama. Esta ventaja comparativa ha permitido al país integrar con éxito la energía solar en su matriz energética, alcanzando una participación relevante en la generación eléctrica nacional y contribuyendo activamente a los Objetivos de Desarrollo Sostenible (ODS), en particular al ODS 7 sobre energía asequible y no contaminante (Ministerio de Energía de Chile, 2023).




Figura 1: Capacidad neta instalada en Chile, renovables, ERNC y proyección a abril 2025. (CNE)

Sin embargo, el crecimiento masivo de instalaciones solares también ha traído consigo nuevos desafíos operativos. Uno de los aspectos críticos en la operación de plantas fotovoltaicas es el diagnóstico temprano de fallas en los módulos, cuya presencia puede afectar significativamente la eficiencia del sistema, la producción de energía y la vida útil de los componentes (Chen et al., 2021). Estas fallas pueden originarse por defectos de fabricación, daño físico, procesos de degradación por envejecimiento, o condiciones ambientales extremas como humedad, polvo o temperatura elevada (IEA-PVPS, 2014; Dkhichi et al., 2021). Su detección temprana se ve reflejada en cambios observables en la curva corriente-tensión (I-V), una herramienta clave para la evaluación no destructiva del rendimiento eléctrico del módulo.

Tradicionalmente, el diagnóstico de fallas ha sido abordado mediante métodos como la inspección visual, la termografía infrarroja, y la electroluminiscencia. Sin embargo, estas técnicas presentan limitaciones cuando se trata de escalar su aplicación a grandes plantas o identificar fallas eléctricas incipientes (Yordanov, 2020). En este sentido, el análisis de curvas I-V ha ganado protagonismo como una técnica precisa, automatizable y ampliamente usada en laboratorios e instalaciones solares, particularmente en combinación con simuladores solares tipo flasher o xenón-LED (Krainak et al., 2018).

En años recientes, el desarrollo de herramientas basadas en procesamiento de imágenes y técnicas de inteligencia artificial ha revolucionado el campo del diagnóstico fotovoltaico. Métodos como la conversión de curvas I-V en matrices mediante Gramian Angular Difference Field (GADF) o Recurrence Plot (RP) han mostrado su utilidad para capturar patrones complejos de comportamiento eléctrico. Estas matrices, procesadas por redes neuronales artificiales (ANN, CNN), permiten clasificar automáticamente distintos tipos de fallas con alta precisión, incluso en presencia de ruido o condiciones variables (Li et al., 2021).

Este capítulo presenta una revisión detallada de los fundamentos de la tecnología fotovoltaica, las principales técnicas y herramientas utilizadas en el diagnóstico de fallas, los tipos de defectos más comunes en módulos fotovoltaicos, el impacto de estas fallas sobre las curvas I-V, y el avance en la aplicación de metodologías automatizadas para su detección y clasificación.

3.1 Fundamentos de la Energía Solar Fotovoltaica

La conversión de energía solar en electricidad mediante módulos fotovoltaicos se basa en el efecto fotovoltaico, un fenómeno físico en el cual la radiación solar incide sobre un material semiconductor —generalmente silicio— y genera una corriente eléctrica continua. Esta corriente se origina debido a la excitación de electrones que, al ser liberados por la energía de los fotones, se mueven a través de una unión tipo p-n, creando una diferencia de potencial utilizable en circuitos eléctricos (Mellit et al., 2018).

Un módulo fotovoltaico está compuesto por celdas solares conectadas en serie y paralelo, encapsuladas para protección contra condiciones ambientales. Cada celda genera típicamente entre 0.5 y 0.6 V, y la combinación de múltiples celdas permite alcanzar tensiones y corrientes útiles a escala comercial (IEA-PVPS, 2014).

El rendimiento de un módulo fotovoltaico se ve afectado por diversos factores, entre los cuales destacan:

- Irradiancia solar (G): mayor irradiancia incrementa la corriente generada.
- Temperatura del módulo (T_m): a mayor temperatura, disminuye la tensión en circuito abierto (VOC) y la eficiencia.
- Sombras parciales: pueden generar múltiples puntos de máxima potencia (MPP) y reducir el rendimiento global.
- Degradación material: como el oscurecimiento del encapsulante o corrosión en conexiones internas.

Para evaluar el comportamiento eléctrico de un módulo, se utiliza la curva corriente-tensión (I-V), la cual representa cómo varía la corriente entregada por el módulo en función del voltaje aplicado. A partir de esta curva se pueden determinar parámetros eléctricos claves como:

- Corriente de cortocircuito (ISC)
- Voltaje de circuito abierto (VOC)
- Punto de máxima potencia (VMPP, IMPP)
- Factor de llenado (FF)
- Eficiencia total del módulo (η)

Estas curvas se obtienen generalmente mediante instrumentos denominados trazadores de curvas I-V, y su interpretación constituye la base para el análisis del estado de salud de los módulos (Li et al., 2021).

Una curva I-V ideal presenta una forma característica compuesta por una región de corriente casi constante seguida por una caída abrupta de tensión, evidenciando la transición desde la región de potencia máxima hasta el corte de voltaje. Entre los puntos clave de esta curva se encuentran la corriente de cortocircuito (I_{sc}), el voltaje de circuito abierto (V_{oc}), el punto de máxima potencia (P_{mp}), y el factor de llenado (FF), los cuales permiten evaluar el estado eléctrico del módulo.




Figura 2: Forma general curva I-V.

La norma internacional IEC 60904-1:2020 establece el procedimiento estandarizado para la medición de curvas I-V de celdas y módulos fotovoltaicos bajo iluminación natural o simulada. Esta norma define los requisitos para las condiciones de medición, el equipamiento, la corrección de desviaciones respecto a condiciones estándar, y los criterios de incertidumbre para asegurar mediciones reproducibles y confiables. Asimismo, la norma establece que la curva I-V debe contener los puntos ISC y VOC, y entrega directrices para la obtención de parámetros eléctricos con mínimos errores relacionados con transitorios o no uniformidad en la irradiancia (IEC, 2020).

Este marco normativo es fundamental para asegurar que las mediciones de curvas I-V utilizadas en esta investigación se encuentren dentro de un contexto técnico internacionalmente validado, especialmente considerando que los ensayos experimentales fueron realizados en un simulador solar tipo flasher bajo condiciones controladas.

3.2 Diagnóstico de Falla en Módulos Fotovoltaicos.

El diagnóstico de fallas en módulos fotovoltaicos es esencial para garantizar la eficiencia, seguridad y durabilidad de las instalaciones solares. A lo largo de su vida útil, los módulos están expuestos a condiciones de operación variables, factores ambientales extremos y procesos de envejecimiento que pueden ocasionar distintos tipos de fallas. Estas fallas afectan el rendimiento del sistema, reducen la producción energética y, en algunos casos, pueden provocar daños irreversibles en el módulo.

3.2.1 Análisis de Curvas Corriente-Tensión (I-V)

El análisis de curvas I-V es una de las herramientas más utilizadas para el diagnóstico de fallas, tanto en condiciones de laboratorio como en terreno. Esta técnica se basa en la medición de la corriente que entrega un módulo en función del voltaje aplicado, generalmente bajo condiciones estándar de prueba (STC: 1000 W/m², 25 °C, AM1.5).

La curva resultante refleja el comportamiento eléctrico completo del módulo, permitiendo detectar anomalías tales como pérdidas de potencia, incremento en la resistencia serie, disminución de la corriente de cortocircuito (ISC) o del voltaje de circuito abierto (VOC), y la aparición de múltiples puntos de máxima potencia (MPP). Estas desviaciones pueden estar asociadas a fallas como microfisuras, delaminaciones, sombras parciales o puntos calientes (Li et al., 2021; IEC, 2020). Según la norma IEC 60904-1:2020, las mediciones I-V deben realizarse bajo condiciones cuidadosamente controladas, utilizando simuladores solares calibrados y estabilizando térmicamente el módulo antes de la prueba. La calidad de la curva medida es crítica, ya que errores o ruido en la adquisición pueden llevar a diagnósticos incorrectos. La norma define además las incertidumbres aceptables y el procedimiento para trazar la curva completa, incluyendo VOC e ISC (IEC, 2020). Más recientemente, el análisis automatizado de curvas I-V ha evolucionado hacia técnicas de aprendizaje automático, donde redes neuronales (ANN, CNN) clasifican directamente el tipo de falla a partir de la forma general de la curva o su transformación en imágenes tipo GADF o RP (Chen et al., 2019).

3.2.2 Electroluminiscencia

La electroluminiscencia es una técnica de inspección no destructiva basada en la emisión de luz cuando se aplica una corriente inversa a las celdas del módulo. Las áreas defectuosas (como microfisuras, celdas inactivas o daño estructural) emiten menos luz, apareciendo como zonas oscuras en la imagen EL. Esta técnica es altamente sensible y permite detectar defectos invisibles a simple vista o mediante termografía. Además, es capaz de identificar fallas tempranas durante el proceso de fabricación o provocadas por manipulación mecánica (Dkhichi et al., 2021). Aunque su principal limitación es que requiere condiciones controladas de laboratorio y acceso a ambos terminales del módulo, su precisión es superior y complementa eficazmente los datos eléctricos entregados por el análisis de curvas I-V.

3.2.3 Termografía Infrarroja

La termografía infrarroja permite visualizar el mapa térmico superficial del módulo fotovoltaico bajo condiciones de operación. Esta técnica detecta la presencia de puntos calientes (hot-spots), los cuales pueden ser indicativos de fallas como celdas dañadas, conexiones defectuosas, problemas en bypass o sombreado parcial. Es una técnica rápida y efectiva para inspecciones masivas, especialmente en plantas solares de gran escala, donde permite escanear cientos de módulos en minutos. Sin embargo, su precisión depende de factores como la resolución de la cámara, el ángulo de medición, la radiación solar disponible y la estabilidad térmica del sistema durante la inspección (Livera et al., 2019). Por su carácter térmico, la termografía es particularmente útil para detectar fallas que generan disipación no uniforme de energía, pero tiene menor sensibilidad a defectos eléctricos que no producen calentamiento visible.

3.2.4 Limitaciones y evolución hacia métodos automatizados

A pesar de su efectividad, las técnicas tradicionales presentan desafíos importantes: alto costo por unidad diagnosticada, dependencia del operador y poca escalabilidad. En este contexto, los modelos de diagnóstico basados en inteligencia artificial han ganado terreno, permitiendo clasificar fallas con alta precisión a partir de datos eléctricos, imágenes térmicas o señales transformadas. La combinación de técnicas (multimodalidad) y la aplicación de modelos entrenados sobre bases de datos reales abren nuevas posibilidades para sistemas de mantenimiento predictivo, diagnósticos remotos y control de calidad en tiempo real (Li et al., 2021; Chen et al., 2019).




Figura 3: Diagrama de flujo de sistema automatizado de clasificación.

3.3 Fallas Típicas en Módulos Fotovoltaicos y su Impacto en Curvas I-V

Los módulos fotovoltaicos, al estar expuestos de forma constante a condiciones ambientales adversas, esfuerzos mecánicos y procesos eléctricos intensivos, están sujetos a una serie de fallas que degradan su rendimiento y confiabilidad. Estas fallas se manifiestan de manera directa en las curvas corriente-tensión (I-V), las cuales constituyen una herramienta clave para su diagnóstico no destructivo.

Esta sección describe las principales fallas que afectan a los módulos fotovoltaicos y cómo estas impactan en la forma y parámetros de sus curvas I-V. Además, se integran consideraciones normativas y hallazgos relevantes reportados en la literatura, que sustentan el análisis automatizado de curvas defectuosas mediante técnicas de inteligencia artificial.

3.3.1 Clasificación General de Fallas

Las fallas pueden clasificarse de acuerdo con su origen físico y manifestación en:

- **Fallas eléctricas:** afectan la conducción o generación de corriente, incluyendo problemas como hot-spots, PID, fallas en diodos de bypass, o conexiones internas defectuosas.
- **Fallas ópticas:** reducen la capacidad de captación de luz, como la delaminación o el oscurecimiento del encapsulante.
- **Fallas mecánicas:** comprenden microfisuras, roturas estructurales o deformaciones del vidrio.

Estas categorías ayudan a establecer correlaciones entre la causa física de la falla y los efectos observados en la curva I-V.

3.3.2 Manifestación de Fallas en Curvas I-V

Cada tipo de falla genera patrones distintivos sobre la curva I-V. Bajo condiciones estándar de prueba (STC: 1000 W/m², 25 °C, espectro AM1.5), se espera una curva suave y continua, con un único punto de máxima potencia. La alteración de esta forma ideal puede evidenciar degradaciones internas, pérdidas de contacto, fallas en bypass o problemas ópticos.

Fallas eléctricas

- **Hot-spots:** generan una reducción localizada de I_{sc} , aparición de escalones o múltiples puntos de inflexión (Dkhichi et al., 2021).
- **PID:** provoca una caída continua en V_{oc} y factor de llenado (FF), afectando el desempeño general del módulo (Mellit et al., 2018).
- **Fallas en diodos de bypass:** producen cortes abruptos en la tensión, con forma escalonada en la curva (Köntges et al., 2017).
- **Desequilibrio de corriente:** distorsiona la zona del punto de máxima potencia (MPP), provocando pérdidas importantes.

Fallas ópticas

- **Delaminación:** afecta la transmisión de luz, disminuyendo I_{sc} (IEA-PVPS, 2014).
- **Oscurecimiento del encapsulante:** reduce la eficiencia del módulo al limitar la irradiancia efectiva.

Fallas mecánicas

- **Microfisuras:** reducen la corriente generada por secciones inactivas del módulo, visibles en la curva como pérdida de I_{sc} o forma irregular (Li et al., 2021).
- **Rotura del vidrio o fallas de soldadura:** generan discontinuidades eléctricas internas, provocando caídas abruptas de corriente.

3.3.3 Impacto de Fallas sobre la Curva I-V

La curva I-V representa todos los puntos operativos de un módulo fotovoltaico. Al ser una radiografía de su comportamiento eléctrico, cualquier anomalía se refleja directamente en su forma. Parámetros como I_{sc} , V_{oc} , P_{mp} , la resistencia serie (R_s) y la resistencia en paralelo (R_{sh}) son claves para el análisis técnico (International Electrotechnical Commission, 2020). Desde un enfoque ingenieril, la identificación de fallas se puede realizar mediante la comparación entre curvas ideales y medidas. Diversos autores señalan los siguientes indicadores:

- **1. Reducción de I_{sc} :** vinculada a degradación óptica o delaminación.
- **2. Variación de V_{oc} :** puede indicar PID o células cortocircuitadas.
- **3. Aumento de R_s :** asociado a fallas en contactos o soldaduras.
- **4. Disminución de R_{sh} :** sugiere presencia de shunts o caminos de fuga internos.
- **5. Escalonamientos:** típicos en presencia de microfisuras o diodos defectuosos.

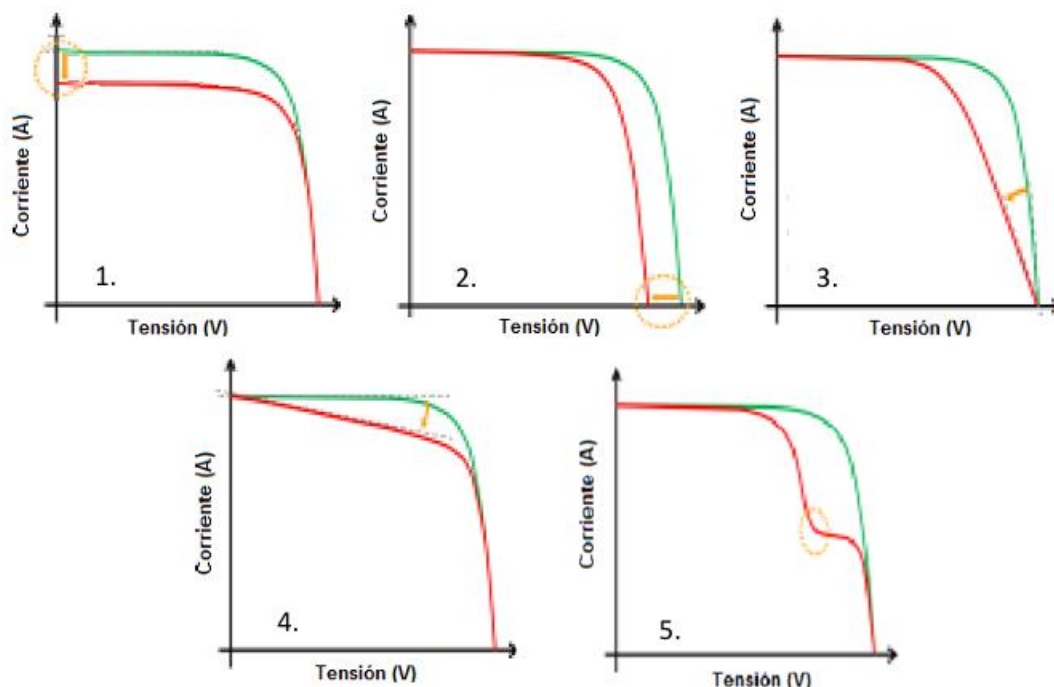


Figura 4: Deformaciones típicas de curvas I-V por tipo de falla (Barrenetxea Pascual, A).

La siguiente tabla resume los efectos más representativos de cada tipo de falla:

Tabla 1: Comparación de impacto de fallas en curvas I-V.

Tipo de Falla	Reducción Isc	Reducción Voc	Pérdida en Pmp	Aumento Rs	Disminución Rsh	Observación Principal
Sombreado parcial	Sí	No	Sí	No	Sí	Deformación tipo “rodilla”
Microfisuras	Sí	Sí (leve)	Sí	Posible	Posible	Comportamiento variable, pérdida de área activa
Degradación por PID	Sí	Sí	Sí	No	Sí	Reducción homogénea
Hot-spot	Sí	No	Sí	Sí	Posible	Activación de diodos bypass
Diodo bypass defectuoso	Parcial o No	Sí	Sí	No	No	Recorte brusco de Voc, forma escalonada
Conexión defectuosa	No	Sí	Sí	Sí	No	Pérdida de tensión, cortes irregulares

Este enfoque cualitativo, complementado con análisis numérico y transformaciones como GADF, permite alimentar modelos de clasificación automatizada que logran identificar estos patrones con alta confiabilidad, como se discute en los capítulos siguientes.




Figura 5: Flujo del proceso de diagnóstico automatizado.

Cada tipo de falla tiene una manifestación característica sobre la curva I-V:

Tabla 2: Relación entre tipo de falla y curva I-V.

Tipo de Falla	Manifestación en la curva I-V	Parámetros afectados
Hot-spot	Múltiples MPP o reducción de ISC	ISC, FF
PID	Caída progresiva del voltaje	VOC, FF
Microfisuras	Reducción escalonada, pérdida de área	ISC, FF
Diodo bypass	Curva escalonada, pérdida de potencia	VMPP, FF
Delaminación	Variabilidad térmica, reducción ISC	ISC

3.3.4 Consideraciones Normativas

La norma IEC 60904-1:2020 establece las condiciones técnicas para una correcta medición de curvas I-V. Entre sus requerimientos destacan:

- Corrección de los datos por temperatura e irradiancia usando la norma IEC 60891.
- Inclusión de puntos clave: I_{sc} , V_{oc} , V_{mp} , I_{mp} , FF.
- Medición bajo condiciones reproducibles y controladas, con validación del instrumento de ensayo.
- Evaluación del sesgo y la incertidumbre asociada a cada medición.

Estos lineamientos son esenciales para evitar errores de diagnóstico derivados de fallas instrumentales, y aseguran la validez del dataset empleado en esta investigación.

La forma de la curva I-V y su evolución bajo distintos tipos de fallas ofrece una herramienta robusta para el diagnóstico automático de fallos en módulos fotovoltaicos.

Tabla 3: Impacto de distintas fallas sobre la curva I-V.

Condición	Forma de la curva I-V	Parámetros afectados	Observaciones principales
Estado normal	Forma continua, un solo MPP	—	Curva suave, alta eficiencia
Hot-spot	Reducción ISC, escalones	ISC, FF	Disparo de diodos bypass
PID	Caída progresiva de voltaje	VOC, FF	Degradación progresiva
Sombreado parcial	Múltiples MPP	VMPP, FF	Activación selectiva de bypass
Microfisura	Reducción ISC localizada	ISC, FF	Dependiente de temperatura
Fallo de diodo	Escalones en la curva	VMPP, FF	Saltos bruscos de voltaje

3.4 Diagnóstico Automatizado de Fallas en Módulos Fotovoltaicos

El crecimiento acelerado en la escala de las plantas solares, junto con la necesidad de mantener una alta disponibilidad energética y reducir los costos de operación y mantenimiento (O&M), ha impulsado el desarrollo de métodos automatizados para el diagnóstico de fallas en módulos fotovoltaicos. Estos métodos permiten procesar grandes volúmenes de datos de manera eficiente, superando las limitaciones de los enfoques tradicionales basados en inspección visual, análisis manual de curvas I-V o imágenes térmicas (Chen et al., 2019; Dkhichi et al., 2021).

3.4.1 Evolución de los Métodos de Diagnóstico

Inicialmente, el diagnóstico fotovoltaico se realizaba mediante inspecciones visuales, termografía infrarroja y análisis manual de parámetros eléctricos extraídos de curvas I-V. Sin embargo, estos métodos presentan limitaciones en cuanto a escalabilidad, sensibilidad ante fallas incipientes y subjetividad del operador. La masificación de ensayos en laboratorios, el uso de simuladores solares y la digitalización de curvas I-V han habilitado el entrenamiento de modelos de aprendizaje automático (Machine Learning, ML), los cuales han demostrado mejoras sustanciales en velocidad, objetividad y precisión.

3.4.2 Machine Learning en Diagnóstico Fotovoltaico

Diversos algoritmos de ML han sido aplicados al diagnóstico de fallas a partir de curvas I-V. Entre los más comunes se encuentran:

- **Redes neuronales artificiales (ANN):** modelan relaciones no lineales complejas y son capaces de aprender patrones anómalos en la forma general de las curvas.
- **Support Vector Machines (SVM):** identifican hiperplanos óptimos que separan clases (falla/no falla) en base a características extraídas como I_{sc} , V_{oc} , FF o la pendiente en zonas críticas.

- **Árboles de decisión (DT) y Random Forest (RF):** ofrecen interpretabilidad y robustez, combinando múltiples predictores.
- **k-Nearest Neighbors (k-NN):** clasifica curvas nuevas comparándolas con ejemplos conocidos cercanos en el espacio de características.




Figura 5: Algoritmos de machine learning aplicados al diagnóstico de módulos fotovoltaicos.

3.4.3 Transformaciones de la Curva I-V: Gramian Angular Difference Field (GADF) y Recurrence Plot (RP)

Una de las innovaciones más relevantes en el diagnóstico automatizado ha sido el uso de transformaciones de curvas I-V en imágenes. Esto permite aplicar técnicas de visión computacional, como Redes Neuronales Convolucionales (CNN), ampliamente probadas en tareas de clasificación de imágenes (Li et al., 2021).

Gramian Angular Difference Field (GADF)

La transformación GADF convierte una serie temporal —como una curva I-V normalizada— en una matriz de imagen que representa las diferencias angulares entre todos los puntos de la curva. Específicamente, transforma el vector de entrada $X=[x_1, x_2, \dots, x_n]$, normalizado en el rango $[-1, 1]$, en una matriz cuadrada G donde cada elemento $G_{i,j}$ está dado por:

$$G_{i,j} = \cos(\phi_i - \phi_j), \text{ con } \phi_i = \arccos(x_i)$$

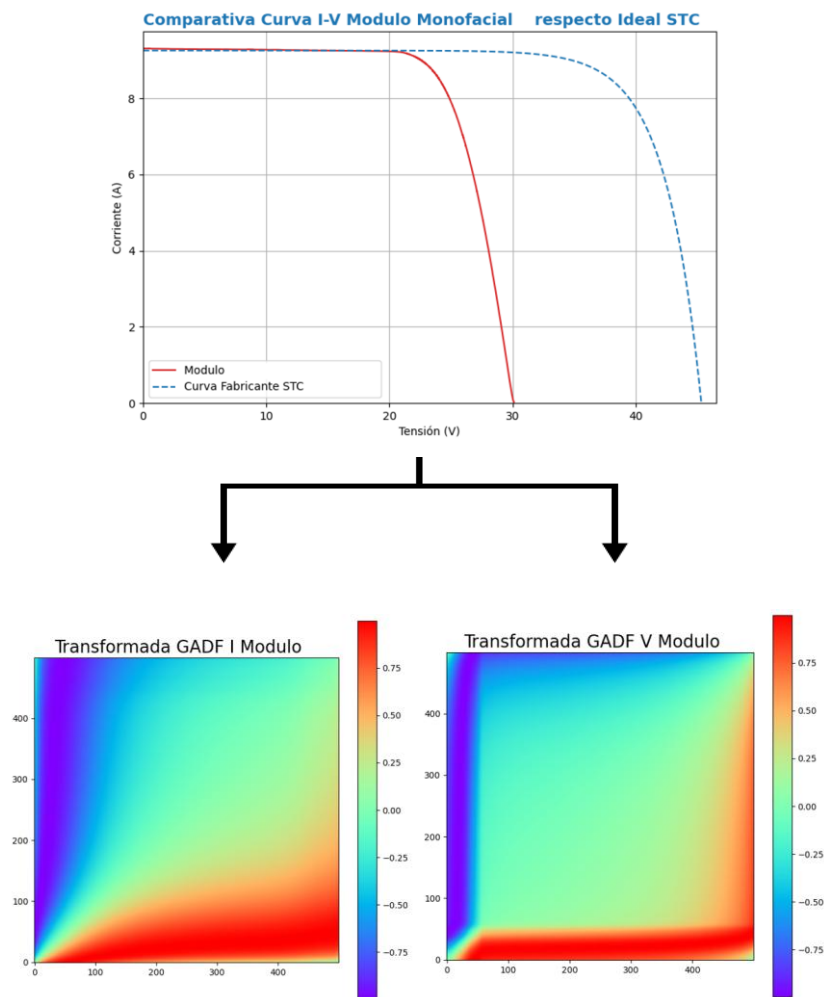


Figura 6: Proceso de transformación GADF aplicado a una curva I-V.

En esta memoria, el método GADF fue utilizado como técnica principal para transformar curvas de corriente y tensión en imágenes, generando una base de datos estandarizada para su posterior clasificación mediante modelos convolucionales.

Recurrence Plot (RP)

RP es otra técnica de visualización que convierte una serie en una imagen mediante la comparación de todos sus puntos consigo misma, generando una matriz binaria o continua que destaca la presencia de repeticiones, simetrías o patrones recurrentes. Si bien útil en otras aplicaciones de series temporales, su uso en este estudio fue exploratorio y no implementado en la metodología final.

3.4.4 Ventajas de los Métodos Automatizados

- Alta precisión: permiten detectar patrones complejos en curvas I-V que podrían pasar desapercibidos para el ojo humano.
- Velocidad de evaluación: posibilitan el diagnóstico masivo en segundos, especialmente útil en plantas de gran escala o bancos de prueba.
- Adaptabilidad: los modelos pueden ser entrenados con curvas de distintas tecnologías de módulos y distintos niveles de degradación.
- Reducción de subjetividad: eliminan el sesgo del operador en el proceso de análisis.

3.4.5 Limitaciones y Desafíos Actuales

A pesar de su potencial, los métodos automatizados enfrentan desafíos importantes:

- Detección de fallas incipientes: la desviación en la curva es muy leve, dificultando su discriminación incluso con redes profundas.
- Generalización de modelos: al cambiar la tecnología, fabricante o condiciones de prueba, el modelo debe ser recalibrado o reentrenado.
- Requerimientos computacionales: el entrenamiento de modelos basados en imágenes GADF puede ser intensivo si se manejan grandes volúmenes de datos.

Una línea de mejora relevante es la optimización del preprocesamiento, selección de características relevantes, y uso de técnicas de reducción de dimensionalidad que permitan mantener la precisión sin comprometer la eficiencia del modelo.




Figura 7: Flujo diagnóstico automatizado basado en GADF + CNN.

En resumen, las técnicas de diagnóstico automatizado basadas en aprendizaje automático y transformaciones como GADF representan un avance fundamental en la evaluación del estado de salud de módulos fotovoltaicos. Su integración en sistemas de monitoreo permite aumentar la confiabilidad operativa, mejorar la planificación de mantenimiento y reducir el costo nivelado de la energía (LCOE) en instalaciones solares modernas.

4 Metodología

4.1 Caracterización Experimental de Módulos Fotovoltaicos

4.1.1 Módulos Fotovoltaicos Ensayados

Los módulos ensayados corresponden a dos series comerciales ampliamente utilizadas en instalaciones solares. La siguiente tabla resume las principales características de los módulos analizados:

Tabla 4: Características de los módulos fotovoltaicos ensayados.

Marca	Modelo	Tipo de célula	Potencia Nominal (STC)	Número de módulos
Astronergy	CHSM6612P Series (315 Wp)	Poli-cristalino (72 celdas 6"x6")	315 Wp	65 módulos
SunEdison	P310BMC (multicrystalline)	Poliacristalino	310 Wp	10 módulos

Ambos conjuntos de módulos fueron previamente utilizados en campo, por lo que se esperaba encontrar una variedad de fallas asociadas a degradación por envejecimiento, manipulación o exposición ambiental.

4.1.2 Equipamiento Utilizado

Las mediciones se realizaron utilizando el equipo Temperature Controlled Laboratory Flasher (TCLF), ubicado en el Laboratorio de Energía Solar de la UTFSM. El TCLF es un simulador solar de laboratorio que cumple los requisitos de uniformidad espacial, estabilidad temporal y espectral establecidos en las normas IEC 60904-9 y IEC 60904-10, permitiendo la adquisición precisa de curvas I-V.

Las principales características del TCLF son:

- Fuente de luz tipo flash de corta duración (~10 ms).
- Control de temperatura mediante sistema de enfriamiento forzado.
- Variabilidad espacial menor al $\pm 2\%$.
- Medición simultánea de corriente y voltaje con alta resolución.

El TCLF utilizado cuenta con certificación de clase AAA según los criterios definidos por la norma IEC 60904-9, garantizando una alta precisión en la simulación solar al cumplir con los estándares de uniformidad espectral, estabilidad temporal y uniformidad espacial requeridos para ensayos eléctricos confiables en módulos fotovoltaicos.



Figura 8: Simulador solar tipo TCLF del Laboratorio Solar Indoor UTFSM.

4.1.3 Condiciones de Medición

Todas las curvas I-V fueron adquiridas bajo Condiciones Estándar de Prueba (STC), definidas según la norma IEC 60904-1:2020 como:

- Irradiancia: 1000 W/m² (con desviación máxima del $\pm 2\%$).
- Temperatura de celda: 25°C.
- Espectro de referencia: AM1.5.

Previo a cada medición, los módulos fueron estabilizados térmicamente en el interior del TCLF hasta alcanzar la temperatura de operación deseada, conforme a las recomendaciones de la norma.

Adicionalmente:

- La irradiancia fue controlada y registrada mediante un piranómetro calibrado.
- Se realizaron mediciones de voltaje en circuito abierto (VOC) y corriente de cortocircuito (ISC) como validaciones cruzadas.
- Se tomaron al menos tres mediciones consecutivas por módulo para garantizar la repetibilidad, aceptando curvas con variabilidad inferior al 2% en ISC.

4.1.4 Procedimiento Experimental

El procedimiento seguido en la caracterización experimental fue el siguiente:

1. Inspección visual preliminar de los módulos para registrar daños evidentes.
2. Posicionamiento del módulo en el banco de prueba del TCLF, asegurando su correcta alineación.
3. Estabilización térmica hasta alcanzar 25°C en la celda.

4. Exposición al pulso de luz flash del TCLF y adquisición de la curva I-V.
5. Verificación de parámetros clave (ISC, VOC, VMPP) en comparación con los valores nominales de fábrica.
6. Almacenamiento de datos de corriente, voltaje y potencia generada en archivos digitales.



Figura 9: Protocolo de adquisición de curvas I-V con simulador TCLF.

Las mediciones fueron organizadas de manera sistemática por grupos de módulos. En particular, se identificó un subconjunto de 11 módulos de la serie Astronergy que presentó errores o inconsistencias en la adquisición de curvas I-V, los cuales fueron registrados para su análisis posterior. Esta observación es considerada en el capítulo de Resultados y fue gestionada mediante revisión cruzada y exclusión de curvas no confiables en etapas posteriores del procesamiento de datos.

Este protocolo fue diseñado para minimizar las fuentes de error experimental y asegurar que las curvas I-V obtenidas fueran representativas del estado real de los módulos.

4.2 Desarrollo de la Base de Datos

Todo el procesamiento de datos, generación de curvas reales, normalizadas e imágenes GADF fue realizado mediante scripts en lenguaje Python. Esta herramienta permitió automatizar el análisis, garantizar la trazabilidad y reducir errores humanos en las diferentes etapas del procesamiento de datos.

4.2.1 Generación de Curvas Ideales

La generación de las curvas ideales se realizó a partir de los parámetros eléctricos típicos de cada tipo de módulo (extraídos de las hojas de datos y ensayos):

- Astronergy CHSM6612P Series: Potencia de 315 Wp, tensión de circuito abierto (VOC) de 45.5 V, corriente de cortocircuito (ISC) de 9.02 A, I_{mp} de 8.80 A y V_{mp} de 35.83 V.
- SunEdison P310BMC: Potencia de 310 Wp, tensión de circuito abierto (VOC) de 46.1 V, corriente de cortocircuito (ISC) de 8.75 A, I_{mp} de 8.61 A y V_{mp} de 36.0 V.

Para ello, se implementó una función denominada `lambert_w()`, la cual modela el comportamiento ideal de un módulo utilizando una solución analítica basada en la función de Lambert W. Esta aproximación permite calcular puntos de la curva I-V teórica considerando:

- Corriente de cortocircuito (ISC).
- Voltaje de circuito abierto (VOC).
- Corriente en punto de máxima potencia (IMPP).
- Voltaje en punto de máxima potencia (VMPP).
- Factores de ajuste de pendiente (alpha, beta).
- Número de celdas en serie (n_{ser}).

Esta metodología se encuentra alineada con estudios previos de modelamiento de curvas I-V para módulos fotovoltaicos.




Figura 10: Curvas I-V ideales generadas mediante función Lambert W.

4.2.2 Adquisición de Curvas I-V

El primer paso en el desarrollo de la base de datos consistió en la adquisición de las curvas corriente-tensión (I-V) de los 75 módulos fotovoltaicos monofaciales ensayados, utilizando el equipo Temperature Controlled Laboratory Flasher (TCLF), bajo condiciones estándar de prueba (STC).

Los datos de corriente y voltaje que representa la curva I-V fueron exportados en formato .csv, generándose archivos individuales nombrados de manera correlativa como "Monofacial X.csv", donde X representa el número de identificación del módulo (de 1 a 75). Cada archivo contenía dos columnas principales:

- Tensión (V): Voltaje aplicado sobre el módulo.
- Corriente (A): Corriente generada por el módulo a dicho voltaje.

Estos archivos constituyeron la base inicial de datos, proporcionando la medición experimental necesaria para la posterior normalización y análisis automatizado.

Para su correcto manejo y trazabilidad, los datos de cada módulo fueron graficados en comparativa a su modelo ideal STC (Astronergy o SunEdison).

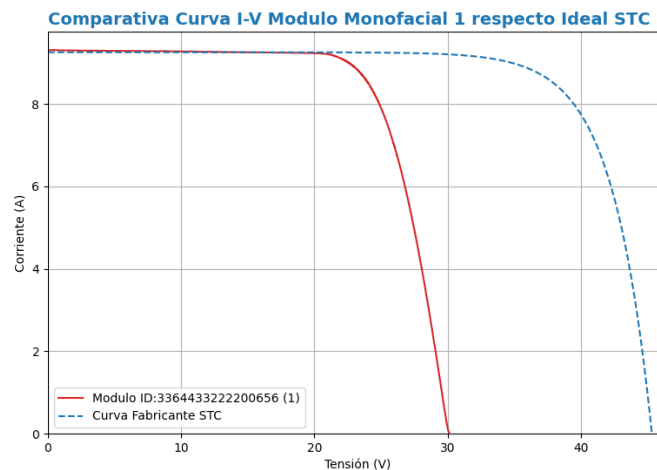


Figura 11: Curva I-V módulo monofacial 1 respecto a su curva ideal STC.

4.2.3 Normalización de Curvas I-V

Debido a pequeñas variaciones experimentales inherentes a las mediciones de campo, fue necesario realizar una normalización de las curvas I-V reales respecto a curvas I-V ideales teóricas. Este proceso tuvo como objetivo estandarizar la escala de voltajes y corrientes, facilitando comparaciones posteriores y transformaciones de las curvas en matrices de imágenes.

Proceso de Normalización

Cada curva medida fue normalizada de la siguiente forma:

- Voltaje normalizado (V_{norm}): División del voltaje experimental por el voltaje de circuito abierto VOC del módulo ideal.
- Corriente normalizada (I_{norm}): División de la corriente experimental por la corriente de cortocircuito ISC del módulo ideal.

Esta transformación llevó todas las curvas a un dominio estandarizado de $[0,1]$, donde:

- $V_{norm} = 1$ representa el voltaje de circuito abierto.
- $I_{norm} = 1$ representa la corriente de cortocircuito.

La normalización se implementó mediante un script en Python, que procesa por lote todos los archivos Monofacial X.csv. Se generaron archivos nuevos de curvas normalizadas, los cuales fueron graficados y verificados visualmente para confirmar la correcta correspondencia de forma con la curva ideal esperada.




Figura 12: Comparación entre curva I-V medida y curva normalizada para el módulo 1.

4.2.4 Transformación de Curvas a Imágenes GADF

Una vez obtenidas y normalizadas las curvas I-V de los módulos fotovoltaicos, el siguiente paso fue la transformación de los valores de las series de corriente y voltaje de estas curvas en imágenes utilizando la técnica conocida como Gramian Angular Difference Field (GADF).

Esta transformación tiene como objetivo convertir la información unidimensional de los valores de la corriente y el voltaje de la curva I-V en una representación bidimensional (imagen), en la cual se conservan las relaciones angulares entre los puntos de la serie temporal. Este formato de imagen permite posteriormente aplicar técnicas de procesamiento de imágenes y redes neuronales convolucionales (CNN) para el diagnóstico automático de fallas.

Método de Transformación GADF

El procedimiento de conversión se implementó mediante la librería `pyts.image.GramianAngularField` en Python, siguiendo los pasos descritos a continuación:

1. Normalización angular: Cada curva I-V normalizada fue transformada en una serie de ángulos en el rango $[0, \pi]$, específicamente para los valores de las series de corriente y voltaje, mediante una transformación tipo arccoseno.

2. Construcción de la matriz GADF: A partir de los ángulos obtenidos, se generó una matriz de diferencias angulares entre todos los pares de puntos de cada serie correspondiente a cada curva. La matriz resultante representa las relaciones dinámicas internas de la curva, codificadas en forma de imagen.

3. Configuración del tamaño de salida: Todas las imágenes GADF fueron generadas con dimensiones fijas, preservando la estructura angular de las series de corriente y voltaje para su posterior análisis.

4. Almacenamiento de imágenes: Las imágenes resultantes fueron almacenadas en formato PNG, organizadas en carpetas diferenciadas por tipo de módulo (Astronergy y SunEdison), distinguiendo además la serie a la cual corresponde la transformada GADF (corriente / voltaje).

Este procedimiento se aplicó tanto para las curvas idealizadas como para las medidas, asegurando homogeneidad en la base de datos de imágenes generadas.

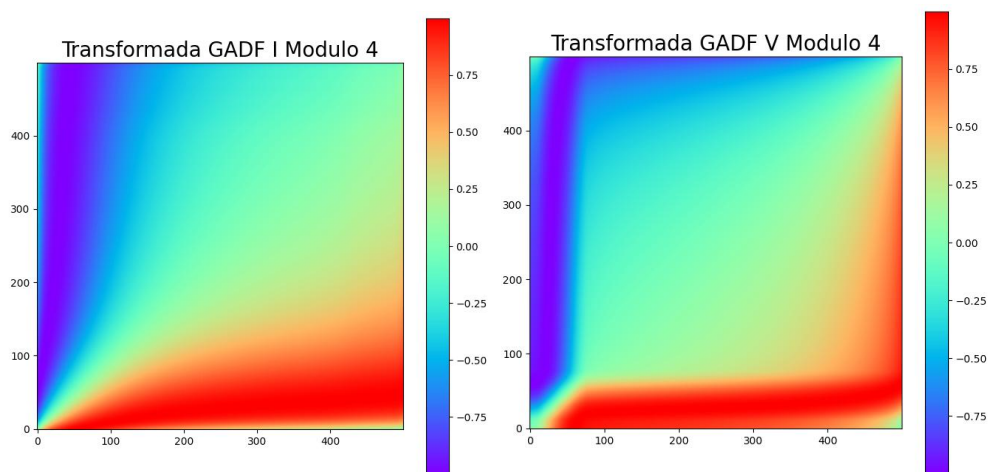


Figura 13: Transformadas GADF resultante para módulo 4.

Generación de Imágenes GADF Ideales

Además de las imágenes GADF generadas a partir de las curvas medidas experimentalmente, se construyó una base de datos de corriente y voltaje correspondientes a curvas I-V ideales, con el propósito de servir como patrón de referencia para la comparación visual y automática durante el proceso de diagnóstico.

Estas curvas ideales fueron generadas utilizando la función de Lambert W, a partir de los parámetros eléctricos nominales entregados por los fabricantes para condiciones estándar (STC), tanto para los módulos Astronergy como SunEdison.

A partir de dichas curvas, se aplicó el mismo procedimiento de transformación

descrito previamente, obteniendo imágenes GADF para la serie de corriente y para la de voltaje.

Las imágenes generadas presentan patrones simétricos, homogéneos y sin deformaciones estructurales, lo que permite identificar de forma clara las desviaciones presentes en módulos defectuosos. En particular:

- Las imágenes GADF de corriente ideal (I) exhiben un patrón de transición suave desde el eje inferior izquierdo hacia el superior derecho, sin distorsiones angulares.
- Las imágenes GADF de voltaje ideal (V) presentan una estructura uniforme y densa, especialmente en la diagonal principal, reflejo de la estabilidad de esta variable en condiciones ideales.

Estas imágenes fueron almacenadas de forma separada del conjunto de módulos defectuosos y utilizadas tanto como entrada de referencia en comparaciones por porcentaje de color, como también para establecer el estándar visual de entrenamiento y validación en los modelos de clasificación automática.

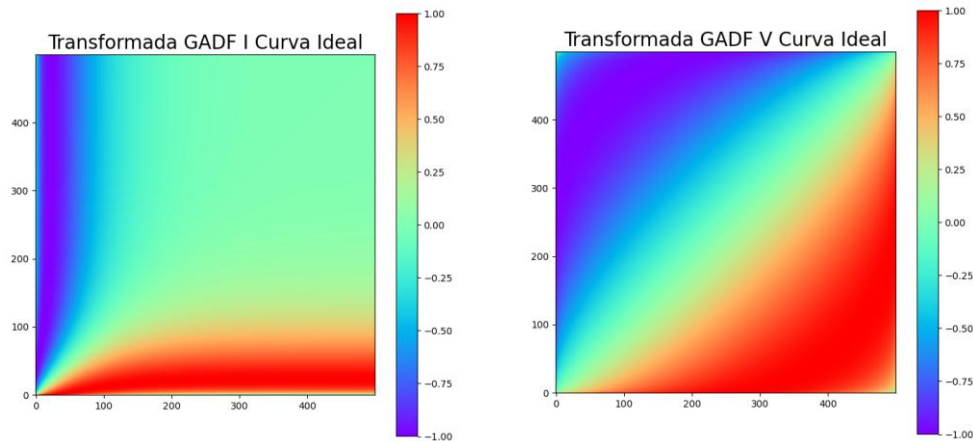


Figura 14: Transformadas GADF resultante para módulo Astronergy ideal.




Figura 15: Transformadas GADF resultante para módulo SunEdison ideal.

Relación Espacial entre la Curva I-V y la Imagen GADF

Cada punto de la curva I-V representa una combinación específica de corriente y voltaje bajo ciertas condiciones de operación. Al transformar esta curva en una imagen mediante GADF, estas combinaciones se convierten en diferencias angulares relativas entre todos los puntos de la curva. Por tanto, regiones características de la curva, como el tramo de cortocircuito, zona lineal o el punto de máxima potencia, se proyectan sobre distintas secciones de la imagen GADF.

Las Figuras 16 y 17 muestran una imagen GADF de corriente y una imagen GADF de voltaje, divididas en 16 bloques, los cuales permiten asociar visualmente sectores específicos de la curva I-V, con regiones particulares de la imagen transformada.

Esta relación es clave para identificar y diagnosticar patrones de falla mediante análisis visual o algoritmos de clasificación automática.

Relación Espacial Imagen Transformada GADF I

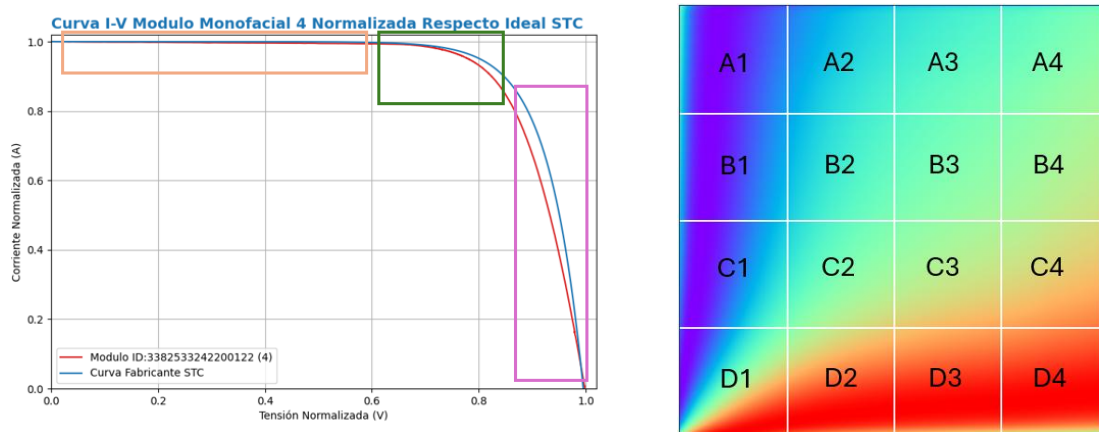


Figura 16: Mapas de secciones Transformada GADF I y curva I-V modulo 4.

- **Bloque D1 (esquina inferior izquierda):** Representa el comienzo de la curva I-V, es decir, el punto donde la tensión es cero y la corriente alcanza su valor máximo (I_{sc}), corresponde al primer sector de la curva I-V, recuadro naranja.
- **Bloques D2, C1 y C2:** Representan la interacción entre los primeros valores de corriente y los puntos intermedios de la curva I-V. Reflejan el comportamiento de la pendiente inicial, correspondiente a la zona anterior al MPP, corresponde al recuadro verde de la curva.
- **Bloques B1, B2, A1 y A2 (sector superior izquierdo):** Corresponden a la región de la curva donde se aproxima al punto de máxima potencia (MPP) y comienza la caída rápida hacia el V_{oc} . corresponde al recuadro verde de la curva.
- **Bloques A3, A4, B3 y B4 (sector superior derecho):** Representan el final de la curva, donde la corriente es prácticamente cero y se alcanza el voltaje de circuito abierto (V_{oc}), corresponde al tercer sector de la curva, recuadro morado.

Relación Espacial Imagen Transformada GADF V

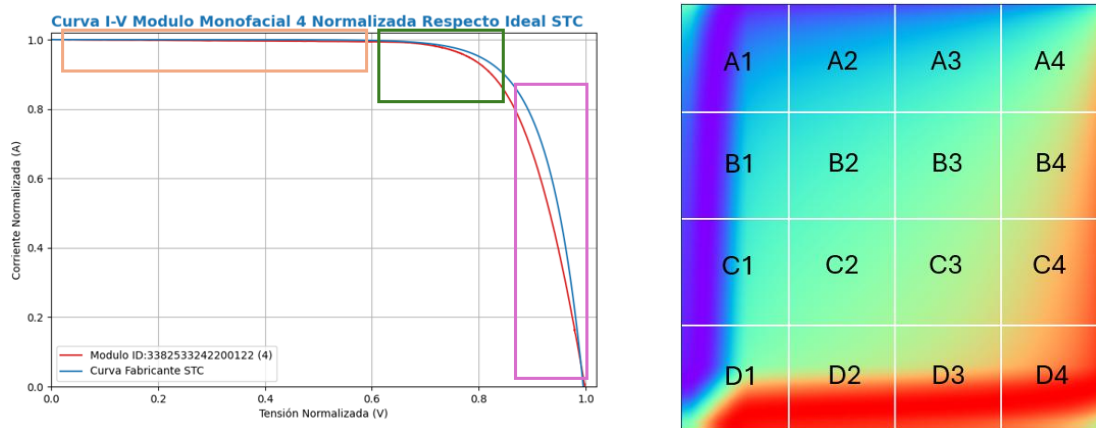


Figura 17: Mapas de secciones Transformada GADF V y curva I-V modulo 4.

- **Bloque D1 (esquina inferior izquierda):** Asociada a los primeros puntos de la curva I-V, primer sector de la curva señalado en naranja, zona de corriente alta (cercana a I_{sc}), voltaje baja.
- **Bloques D2–D3 (zona central):** Representa la transición de corriente decreciente y voltaje creciente, segundo sector de la curva I-V señalado en verde. tramo lineal donde se localiza el punto de máxima potencia (MPP).
- **Bloques D4–A4 (esquina inferior derecha – superior derecha):** Relacionada con las ultimas muestras de la curva —zona de corriente bajo, voltaje alto (cercano a V_{oc}), tercer sector de la curva I-V señalado en morado.

Esta correspondencia entre las regiones de la curva y las zonas de la imagen GADF permite utilizar esta representación como herramienta diagnóstica altamente efectiva para identificar desviaciones del comportamiento ideal y anomalías localizadas.

4.2.5 Organización y Consolidación del Dataset

Con el fin de facilitar el entrenamiento de modelos de clasificación automática y mantener la trazabilidad del flujo de trabajo, se estructuró el dataset resultante siguiendo un criterio jerárquico por tipo de módulo y número de identificación. Cada módulo cuenta con una carpeta que contiene:

Carpeta Curvas I-V

- Curva IV.png: grafica comparación visual con su curva ideal.
- Curva IV I normalizada.png: grafica curva normalizada.
- Curva IV normalizada.png: grafica comparación visual con su curva ideal normalizada.

Carpeta Imágenes GADF Curva I-V

- Imagen GADF I.png: transformada angular de corriente normalizada.
- Imagen GADF V.png: transformada angular de voltaje normalizado.
- Imagen GADF I-V.png: imagen resultante de la combinación entre Imagen GADF I e imagen GADF V.

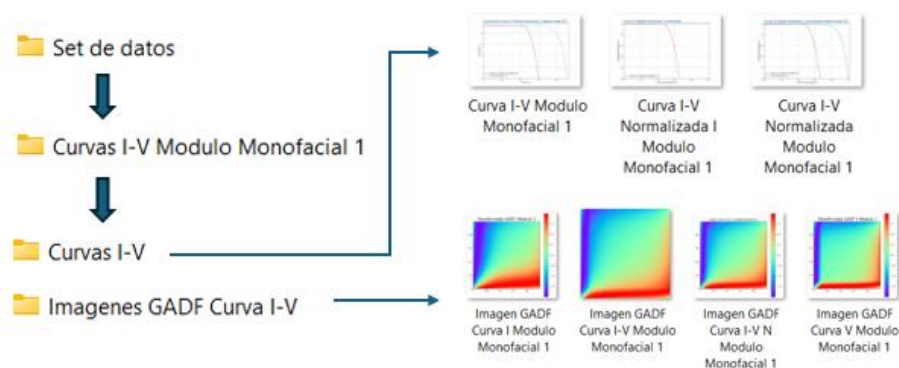


Figura 18: Estructura del set de datos generado por módulo.

Adicionalmente, se generó una carpeta general llamada “Imágenes GADF Análisis”, donde se recopilan todas las imágenes generadas mediante transformada GADF, para todos los módulos, las cuales serán procesadas por los modelos de clasificación.




Figura 19: Ejemplo de imágenes transformada GADF generadas para el módulo 7, Imagen GADF I (izquierda) e Imagen GADF V (derecha).

Finalmente, el siguiente flujo resume el procedimiento completo de generación del dataset:

1. Lectura de datos curva I-V medida desde archivo CSV.
2. Normalización de voltaje y corriente en relación con curva ideal correspondiente.
3. Graficado de la curva I-V real y normalizada para control visual.
4. Transformación GADF de la corriente normalizada.
5. Transformación GADF del voltaje normalizado.
6. Almacenamiento de todas las representaciones gráficas en carpetas organizadas por número de módulo.
7. Almacenamiento de imágenes de transformadas GADF I, V e I-V de cada módulo en carpeta especializada para futuro análisis de fallas.

Esta estructura consolidada de datos permitió establecer una base sólida para la implementación y validación de modelos de diagnóstico automático que se desarrollan en el siguiente capítulo.

4.3 Implementación de Modelos de Clasificación Automatizada

La identificación temprana de fallas y errores de medición en módulos fotovoltaicos es un aspecto crítico para garantizar su desempeño óptimo y prolongar su vida útil en instalaciones solares.

En este proyecto, se implementaron metodologías de clasificación automatizada basadas en el análisis de imágenes derivadas de curvas corriente-tensión (I-V) obtenidas mediante ensayos experimentales en condiciones estándar de prueba (STC).

La estrategia adoptada combinó dos enfoques complementarios:

- El uso de redes neuronales convolucionales (CNN), diseñadas y entrenadas para la clasificación automática de fallas específicas y errores de medición a partir de imágenes GADF generadas de las curvas I-V.
- El desarrollo de métodos basados en el análisis del porcentaje de color en sectores definidos de las imágenes, permitiendo una clasificación más simple y rápida en ciertos casos donde las fallas presentan patrones visuales dominantes.

En total, se abordó la detección automatizada de ocho tipos de condiciones particulares en los módulos, incluyendo:

- Dos clasificadores destinados a la detección de errores de medición:
 - EM1: Error de medición 1.
 - EM2: Error de medición 2.

- Seis clasificadores enfocados en identificar fallas específicas en el comportamiento de las curvas I-V:
 - Falla 1: Disminución del voltaje de circuito abierto (V_{oc}).
 - Falla 2: Disminución de corriente de cortocircuito (I_{sc}).
 - Falla 3: Reducción de la resistencia paralelo (R_{sh}).
 - Falla 4: Aumento de la resistencia serie (R_s).
 - Falla 5: Escalonamiento de la curva I-V.
 - Falla 6: Escalonamiento doble de la curva I-V.

Esta combinación de técnicas avanzadas de machine learning y procesamiento de imágenes permitió establecer un sistema de diagnóstico automatizado, capaz de identificar patrones sutiles o evidentes de falla en los módulos fotovoltaicos, minimizando la intervención manual y mejorando la eficiencia del proceso de evaluación.

En las siguientes secciones se describen detalladamente los procesos de preprocesamiento de datos, las arquitecturas de clasificación empleadas, los criterios de validación y los resultados obtenidos para cada tipo de metodología implementada.

4.3.1 Clasificación mediante Redes Neuronales Convolucionales (CNN)

La utilización de redes neuronales convolucionales (CNN) ha demostrado ser una técnica altamente eficiente para la clasificación de patrones complejos en imágenes, incluyendo aquellas generadas a partir de curvas corriente-tensión (I-V) de módulos fotovoltaicos. En esta memoria, se implementaron modelos CNN especializados para la detección de fallas y errores de medición en módulos monofaciales, utilizando imágenes generadas mediante la transformación Gramian Angular Difference Field (GADF) a partir de datos normalizados.

Preprocesamiento de Imágenes para Entrenamiento

Antes del entrenamiento de los modelos CNN, fue necesario realizar un preprocesamiento específico de las imágenes GADF, con el objetivo de resaltar las zonas de interés y optimizar la capacidad de generalización de los modelos.

El flujo general de preprocesamiento fue el siguiente:

- A partir de las curvas I-V normalizadas, se generaron las imágenes GADF correspondientes para corriente (I) y voltaje (V).
- De las imágenes GADF, se realizaron recortes localizados de sectores específicos, seleccionados por su relevancia en la identificación de anomalías eléctricas.
- Los recortes fueron de distintos tamaños según el tipo de falla analizada, variando entre 3×3 y 10×10 píxeles.
- Posteriormente, las imágenes recortadas fueron normalizadas en tamaño para cumplir con los requisitos de entrada de la red CNN.
- Generación de carpetas de recortes GADF I y recortes GADF V, de estructura similar, que guarda los recortes generados para cada módulo.

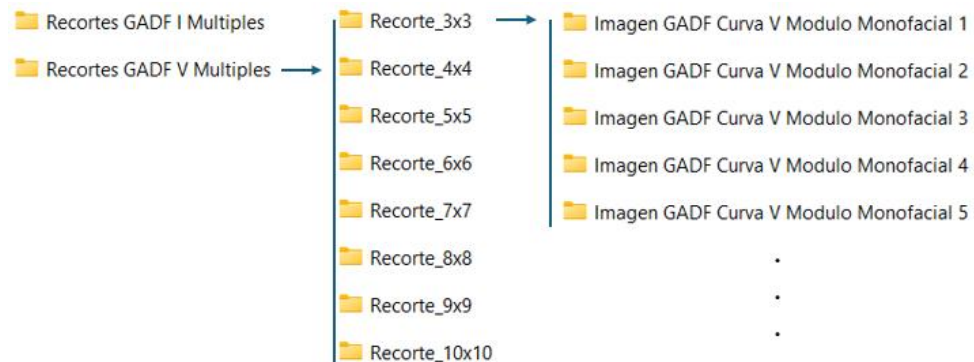


Figura 20: Estructura carpetas de preprocesamiento de imágenes.

Arquitectura de los Modelos CNN

Cada red neuronal convolucional utilizada en esta memoria fue diseñada para el análisis específico de imágenes generadas a partir de curvas I-V normalizadas y transformadas mediante GADF.

La estructura general de las redes implementadas fue la siguiente:

- Entrada: Imágenes normalizadas de tamaño uniforme, provenientes de recortes de imágenes GADF. Dimensiones aproximadas: 10×10 .
- Primera Capa Convolutiva: 32 filtros de 3×3 píxeles, función de activación ReLU.
- Segunda Capa Convolutiva: 64 filtros de 3×3 píxeles, función de activación ReLU.
- Capa de Pooling: MaxPooling2D con tamaño de ventana 2×2 .
- Flatten Layer: Aplanamiento de la salida convolutiva.
- Primera Capa Densa: 64 neuronas, activación ReLU.
- Capa de Salida:
 - Para clasificación binaria: 1 neurona de salida con activación Sigmoid.
 - Para clasificación multiclase: N neuronas de salida con activación Softmax.




Figura 21: Flujo de entrenamiento y clasificación CNN.

Justificación de la Arquitectura

- Se eligió una arquitectura compacta pero profunda para adaptarse al pequeño tamaño de las imágenes recortadas.
- El uso de filtros pequeños (3x3) permite capturar detalles locales relevantes en las imágenes GADF.
- La inclusión de capas de pooling ayuda a reducir la complejidad computacional y mejora la capacidad de generalización.
- La capa de salida se adapta al tipo de problema: clasificación binaria (error de medición) o multiclase (falla específica).
- El optimizador Adam se seleccionó por su efectividad en adaptarse dinámicamente al gradiente de la función de pérdida.

Entrenamiento de los Modelos

El entrenamiento de los modelos CNN se realizó bajo la siguiente configuración:

- División de datos: 80% de las imágenes para entrenamiento y 20% para validación.
- Número de épocas: 20 épocas completas de entrenamiento.
- Métrica principal de evaluación: Accuracy.
- Función de pérdida:
 - Categorical Crossentropy para problemas de clasificación multiclase.
 - Binary Crossentropy para problemas de clasificación binaria.

El entrenamiento fue realizado en diferentes sesiones, especializando cada modelo CNN en el tipo de fallo o condición a detectar:

Modelo CNN EM1

Dedicado a la detección de errores de medición en las curvas I-V. Su entrenamiento se basa en el análisis de similitudes estructurales en imágenes “GADF V” que presentan un comportamiento visual anómalo con respecto a imágenes de datos correctamente obtenidos.




Figura 22: Ejemplo de imagen transformada GADF V sin error (izquierda) y con error (derecha).

Modelo CNN Falla 3

Entrenado sobre recortes de imágenes “GADF V”, con interés en el sector inferior izquierdo de cada imagen, las cuales son replicadas en diferentes versiones pixeladas, para aumentar la cantidad de datos y con ello detectar patrones anómalos asociados a la Falla 3.




Figura 23: Región de interés en imagen transformada GADF V para clasificación de la falla 3.

La selección de recorte GADF V a analizar para cada módulo se toma en base al recorte contiguo a los recortes del sector inferior izquierdo, que van desde el 3x3 hasta el 10x10, donde se clasifica el porcentaje de color rojo presente en la imagen, si este es superior o igual al 80% se selecciona el recorte inferior izquierdo de la grilla “nxn” a la cual pertenece el recorte contiguo, con el fin de poder identificar que imagen presenta datos más representativos de la región a analizar. Este recorte contiguo corresponde a la sección x_1 de cada grilla de recorte de la imagen GADF V.




Figura 24: Ejemplo de recortes sector inferior izquierdo de imagen transformada GADF V módulo monofacial 9, correspondiente a recortes 3x3 hasta 8x8.




Figura 25: Ejemplo de recortes sector inferior izquierdo contiguo (sector x_1) de imagen transformada GADF V módulo monofacial 9, correspondiente a recortes 3x3 hasta 8x8.

Seleccionado el recorte inferior izquierdo a analizar, se procesa generando versiones pixeladas, las cuales toman en cuenta distintos porcentajes de dominancia de color RGB para decidir el color de cada pixel, las imágenes resultantes presentan la siguiente forma.




Figura 26: Imágenes generadas para modelo CNN falla 3, módulo monofacial 9.

Especialización de Modelos CNN por Tipo de Falla

Cada CNN fue entrenada de forma específica para identificar:

- Error de Medición (EM1): Detecta si una curva I-V presenta una alteración generalizada atribuible a error de medición en laboratorio.
- Falla 3: Detecta comportamientos anómalos sutiles en regiones específicas de la curva I-V, asociados a pérdidas parciales o microdefectos en la continuidad de su primera región de la curva, lo cual se relaciona con la reducción de la resistencia paralelo (Rsh).

4.3.2 Clasificación mediante Análisis de Porcentaje de Color

La clasificación automática de fallas en módulos fotovoltaicos no se limitó únicamente al uso de redes neuronales convolucionales. En esta memoria también se desarrollaron clasificadores simples basados en el análisis del porcentaje de color presente en sectores definidos de las imágenes GADF generadas a partir de curvas I-V. Este enfoque permitió realizar detecciones eficientes y rápidas en aquellos casos donde ciertas fallas se manifiestan mediante patrones visuales dominantes en regiones específicas de la imagen.

Metodología General del Análisis Sectorial

El procedimiento general para este tipo de clasificación se resume en el siguiente flujo:

- A partir de las curvas I-V normalizadas, se generaron las imágenes GADF correspondientes a corriente (I) o voltaje (V).
- Cada imagen fue dividida en secciones predefinidas (por ejemplo: part_0_2, part_0_10, etc.).
- Para cada sección, se calculó el porcentaje de un color específico (Rojo, Azul o Verde) dominante en los píxeles RGB.
- Se aplicó un umbral de decisión: si el porcentaje supera (o cae por debajo de) cierto valor, se concluye que la curva presenta la falla asociada.

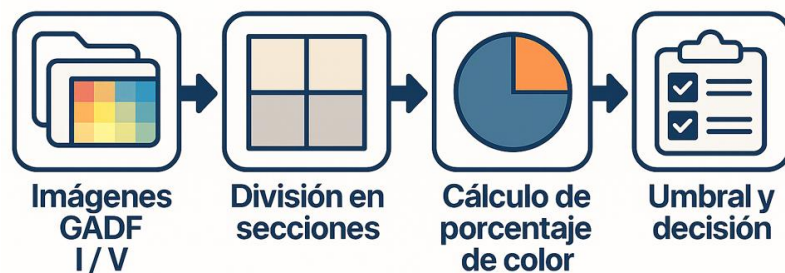


Figura 27: Flujo de análisis de porcentaje de color en imágenes GADF.

Clasificadores Implementados por Falla

Clasificación de Error de Medición 2 (EM2)

Identifica errores de medición presente en los datos obtenidos en laboratorio, los cuales presentan un sector característico que indica la presencia de estos.

- Imagen analizada: Recorte de imagen GADF de Voltaje (falla 3).
- Sector: Región inferior izquierda de la imagen, sección 1_0 en grilla 2x2 de la imagen seleccionada para el análisis de la falla 3 de cada módulo.
- Color evaluado: Verde.
- Lógica: Un recuadro inferior izquierdo que aparece completamente verde sugiere que no se generó curva I-V de la manera correcta (error total de medición).
- Clasificación: $> 98\%$ verde \rightarrow Se clasifica como “Presenta EM2”.




Figura 28: Cuadrante inferior izquierdo de imágenes seleccionadas para análisis falla 3, ejemplo módulo con error de medición (izquierda) y módulo sin error de medición (derecha).

Clasificación de Falla 1

Identifica la falla correspondiente a la disminución del voltaje de circuito abierto (Voc) en la curva I-V. Esto se hace analizando un sector en particular de la imagen GADF V en conjunto a los datos de Voc obtenidos mediante TCLF correspondiente a cada módulo.

- Imagen analizada: GADF de Voltaje.
- Sector: Región superior derecha de la imagen, sección 0_2 en grilla 3x3.
- Color evaluado: Rojo.
- Lógica 1: Un porcentaje bajo de rojo indica alteración de los datos medidos en el último sector de la curva I-V.
- Clasificación 1: porcentaje de rojo en sector $< 25\%$ rojo en sección 0_2 \rightarrow Se clasifica como “Presenta Falla 1”.
- Lógica 2: Comparación directa con dato Voc obtenido desde TCLF.
- Clasificación 2: Si el valor medido de Voc es $< 90\%$ del Voc Ideal \rightarrow Se clasifica como “Presenta Falla 1”.




Figura 29: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 1 presente mediante clasificación 1.




Figura 30: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 1 presente mediante clasificación 1.

Clasificación de Falla 2

Identifica la falla correspondiente a la disminución de la corriente de cortocircuito (I_{sc}) en la curva I-V. Esto se hace analizando un sector en particular de la imagen GADF I en conjunto a los datos de I_{sc} obtenidos mediante TCLF correspondiente a cada módulo.

- Imagen analizada: GADF de Corriente.
- Sector: Región inferior izquierda de la imagen, sección 3_0 y 3_1 en grilla de 4x4.
- Color evaluado: Rojo.
- Lógica: cálculo del porcentaje de aumento de color rojo presente entre sección 3_0 y 3_1.
- Clasificación: Si el porcentaje de aumento de color rojo entre la sección 3_0 a 3_1 es $\geq 63\%$ \rightarrow Se clasifica como “Presenta Error de Medición (EM1)”.
- Lógica 2: Comparación directa con dato I_{sc} obtenido desde TCLF.
- Clasificación 2: Si el valor medido de I_{sc} es $< 90\%$ del I_{sc} Ideal \rightarrow Se clasifica como “Presenta Falla 1”.




Figura 31: Región inferior izquierda de la imagen GADF I, detalle sección 3_0 y 3_1 en grilla de 4x4.

Clasificación de Fallas 5

Identifica la falla correspondiente a escalonamiento de la curva I-V. Esto se hace analizando un sector en particular de la imagen GADF V.

- Imagen analizada: GADF de Voltaje.
- Sector: Región superior derecha de la imagen, sección 0_2 en grilla de 3x3.
- Color evaluado: Rojo.
- Lógica: Un alto porcentaje de rojo en este sector indica distorsiones de alto impacto en la dirección continua de la curva de I-V.
- Clasificación: Porcentaje de rojo en sector $> 40\%$ \rightarrow Se clasifica como “Presenta Falla 5”.




Figura 32: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 5 presente.




Figura 33: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 5 presente.

Clasificación de Fallas 6

Identifica la falla correspondiente a escalonamiento de la curva I-V. Esto se hace analizando un sector en particular de la imagen GADF V.

- Imagen analizada: GADF de Voltaje.
- Sector: Región superior derecha de la imagen, sección 0_9 en grilla de 10x10.
- Color evaluado: Rojo.
- Lógica: Un alto porcentaje de rojo en este sector indica distorsiones de alto impacto en la dirección continua durante dos secciones de la curva de I-V.
- Clasificación: Porcentaje de rojo en sector $> 40\%$ \rightarrow Se clasifica como “Presenta Falla 6”.




Figura 34: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo con falla 6 presente.




Figura 35: Región superior derecha de la imagen GADF V, detalle sección 0_2 en grilla 3x3, modulo sin falla 6 presente.

5 Resultados y Discusión

Este capítulo presenta los resultados obtenidos a partir de la caracterización experimental de 75 módulos fotovoltaicos monofaciales mediante ensayos realizados en el simulador solar TCLF bajo condiciones estándar de prueba. A partir de estos datos, se aplicaron dos metodologías de clasificación automatizada de fallas: una basada en el análisis de porcentaje de color en imágenes GADF y otra mediante redes neuronales convolucionales (CNN). Se describen también los reportes generados automáticamente por módulo, así como las métricas de validación utilizadas para evaluar el desempeño de los clasificadores.

Los resultados se organizan en seis secciones que abordan: el análisis visual de curvas I-V, los resultados obtenidos con cada tipo de clasificador, la generación automatizada de reportes, y una discusión general sobre la efectividad, limitaciones y potencial futuro del sistema propuesto.

5.1 Esquema General del Sistema Automatizado

Antes de presentar los resultados obtenidos por cada componente del sistema, es fundamental comprender cómo se interconectan los distintos procesos involucrados en el diagnóstico automatizado de fallas. Para ello, se elaboró un esquema general que representa el flujo completo desde la adquisición de datos experimentales hasta la generación final de un informe por módulo. El sistema propuesto se compone de cinco etapas principales:

- **Adquisición de datos:** Las curvas I-V de 75 módulos fotovoltaicos monofaciales fueron obtenidas mediante ensayos en el simulador solar TCLF, bajo condiciones estándar de prueba (STC). Estas curvas representan el punto de partida del análisis.
- **Preprocesamiento y transformación:** Las curvas I-V se normalizaron y sus datos se transformaron en imágenes GADF utilizando técnicas de codificación angular.

Se generaron imágenes por separado para corriente, voltaje, e imágenes combinadas.

- **Clasificación de fallas:** Se aplicaron dos enfoques de clasificación.
 - **Análisis de porcentaje de color:** basado en patrones cromáticos dominantes en regiones específicas de las imágenes.
 - **Modelos de redes neuronales convolucionales (CNN):** entrenados para detectar fallas específicas, especialmente aquellas con patrones más sutiles o difíciles de identificar visualmente en la curva I-V, mediante análisis estructural de las imágenes.
- **Consolidación de diagnóstico:** Los resultados de ambos métodos se comparan y combinan para determinar la condición final del módulo, identificando fallas EM1, EM2, fallas técnicas 1 a 6, consolidando los resultados en un archivo tipo diccionario .json, el cual resume la información de cada módulo clasificado.
- **Generación de reporte automático:** Se genera un informe PDF por cada módulo, integrando curva real vs ideal, imágenes GADF, valores eléctricos medidos y clasificación final. Este reporte permite una rápida interpretación y trazabilidad técnica.

5.1.1 Implementación del sistema en Python

El sistema fue implementado íntegramente en Python, utilizando un conjunto de scripts organizados modularmente. El núcleo del análisis está conformado por un script principal que gestiona la carga de datos e imágenes, la ejecución de clasificadores, el etiquetado automático de cada módulo y la generación de resultados.

Los códigos generados se presentan como anexo, específicamente en la carpeta “Programa de clasificación automatizada”. Esta carpeta cuenta con los siguientes códigos.

Tabla 5: Descripción de scripts del sistema de clasificación automatizada.

Nombre del script	Función principal
[0] Generador de diccionario.py	Crea un diccionario .json que consolida el estado de fallas por módulo, junto a sus datos eléctricos
[1] Curva Ideal Astronergy [I].py	Genera la curva I-V ideal junto a imágenes GADF para módulos Astronergy.
[2] Curva Ideal SunEdison [I].py	Genera la curva I-V ideal junto a imágenes GADF para módulos SunEdison.
[3] Curvas I-V [M] Astronergy.py	Carga y genera curvas I-V reales junto a imágenes GADF para módulos Astronergy caracterizados (TCLF).
[4] Curvas I-V [M] SunEdison.py	Carga y genera curvas I-V reales junto a imágenes GADF para módulos SunEdison caracterizados (TCLF).
[5] Recortes de imagenes GADF V.py	Divide imágenes GADF de tensión en recortes estructurados.
[6] Recortes de imagenes GADF I.py	Divide imágenes GADF de corriente en recortes estructurados.
[7] Selector Img GADF V Analisis Falla 3.py	Selecciona imágenes de entrada para análisis de Falla 3.
[8] Pre Entrenamiento CNN Falla 3.py	Prepara datos e inicializa entrenamiento de red CNN para Falla 3.
[9] Entrenamiento CNN Falla 3.py	Entrena modelo CNN para detectar Falla 3 en curvas GADF.
[10] Clasificacion Falla 3.py	Clasifica módulos con Falla 3 y genera resultados.
[11] Entrenamiento CNN EM1.py	Entrena modelo CNN para detección de EM1.
[12] Clasificacion EM1.py	Clasifica módulos con EM1 y genera resultados.
[13] Clasificacion Falla EM2.py	Detecta Falla EM2 y genera resultados.
[14] Clasificacion Falla 5 y 6.py	Clasifica simultáneamente Falla 5 y Falla 6. Genera resultados.
[15] Clasificacion Falla 1.py	Clasifica módulos con Falla 1 y genera resultados.
[16] Clasificacion Falla 2.py	Clasifica módulos con Falla 2 y genera resultados.
[17] Reporte General de Fallas.py	Consolida resultados y genera reporte general de fallas.
[18] Generador Reporte por modulo.py	Genera reporte PDF detallado por cada módulo fotovoltaico.

Cada función está especializada para una tarea específica y su ejecución es en orden creciente según su número indicador principal, esto en conjunto permite reutilizar y escalar el sistema fácilmente a otros conjuntos de datos o tipos de módulos.

Por cada falla analizada (EM1, EM2, Falla 1 a Falla 6), el sistema genera los siguientes resultados:

- Un archivo .txt con los resultados individuales de la falla analizada por módulo.
- Una entrada en un diccionario .json con el estado de falla de cada módulo.
- Reportes visuales con las imágenes de soporte (curvas, GADF, predicciones).
- Estadísticas generales de clasificación (accuracy, matriz de confusión, etc.).
- Un informe PDF con todos los elementos consolidados.

Este enfoque modular y automatizado permitió procesar eficientemente volúmenes de datos en poco tiempo, garantizando trazabilidad, replicabilidad y claridad en cada etapa del análisis.

5.1.2 Estructura del Diccionario de Resultados

Como parte del proceso de consolidación del diagnóstico, el sistema genera un archivo en formato .json que contiene el resumen de fallas detectadas por módulo. Este archivo actúa como una base de datos estructurada que puede ser reutilizada por otros scripts para análisis adicional y generación de reportes.

La estructura general del diccionario para cada módulo es la siguiente:

```

"Modulo Monofacial 1": {
  "Isc TCLF": "9.30802",
  "Voc TCLF": "30.1039",
  "EM1": "No",
  "EM2": "No",
  "Recortes": "9x9",
  "falla 1": "Si",
  "falla 2": "No",
  "falla 3": "No",
  "falla 4": "No",
  "falla 5": "No",
  "falla 6": "No",
  "Imp TCLF": "8.72511",
  "Vmp TCLF": "23.5284",
  "Tipo": "Astronergy",
  "Id": "336443322200656 (1)"
},

```

Figura 36: Ejemplo de la estructura del diccionario para módulo monofacial 1.

Cada entrada identifica el módulo y contiene los resultados por cada tipo de falla evaluada, además de los valores medidos de corriente y voltaje extraídos desde las curvas I-V ensayadas. Esta estructura permite acceder fácilmente a la información, exportarla o integrarla con interfaces gráficas, plataformas de mantenimiento o sistemas externos. Este diccionario además integra los datos correspondientes las curvas ideales de los dos tipos de módulos analizados.

```

"Modulo Monofacial Astronergy": {
  "Isc TCLF": "9.02",
  "Voc TCLF": "45.55",
  "EM1": "No",
  "EM2": "No",
  "Recortes": "3x3",
  "falla 1": "No",
  "falla 2": "No",
  "falla 3": "No",
  "falla 4": "No",
  "falla 5": "No",
  "falla 6": "No",
  "Imp TCLF": "8.8",
  "Vmp TCLF": "35.83"
},
"Modulo Monofacial SunEdison": {
  "Isc TCLF": "8.75",
  "Voc TCLF": "46.1",
  "EM1": "No",
  "EM2": "No",
  "Recortes": "3x3",
  "falla 1": "No",
  "falla 2": "No",
  "falla 3": "No",
  "falla 4": "No",
  "falla 5": "No",
  "falla 6": "No",
  "Imp TCLF": "8.61",
  "Vmp TCLF": "36.0"
},

```

Figura 37: Estructura del diccionario para módulo monofacial Astronergy (ideal) y SunEdison (ideal).

5.2 Resultados de la Caracterización Experimental

Se ensayaron 75 módulos fotovoltaicos monofaciales utilizando el simulador solar de laboratorio TCLF bajo condiciones estándar de prueba (STC: 1000 W/m², 25 °C, AM 1.5). Dentro de este grupo de módulos se presentaron los siguientes resultados, los cuales se muestran en detalle en el Anexo “Reporte General de Fallas”.

Tabla 6: Resumen resultados caracterización experimental 75 módulos.

Tipo de Falla	Descripción	Cantidad
EM	Error de medición	11
Falla 1	Disminución del voltaje de circuito abierto (Voc).	46
Falla 2	Disminución de corriente de cortocircuito (Isc).	4
Falla 3	Reducción de la resistencia paralelo (Rsh).	16
Falla 4	Aumento de la resistencia serie (Rs).	0
Falla 5	Escalonamiento de la curva I-V.	1
Falla 6	Escalonamiento doble de la curva I-V.	1

En los módulos en buen estado, las curvas medidas coinciden estrechamente con la forma ideal, mientras que en módulos con fallas se observan desviaciones significativas, tales como:

- Reducción de corriente de cortocircuito (Isc) o voltaje de circuito abierto (Voc).
- Puntos de máxima potencia desplazados o disminuidos.
- Escalonamientos o quiebres en la curva (síntoma de sombreado parcial o bypass).
- Deformaciones suaves en la pendiente de la primera sección de la curva I-V asociada Rsh.

Adicionalmente, se detectaron inconsistencias atribuibles a errores de medición en 11 módulos, caracterizadas por curvas con forma que pierde continuidad, saltos abruptos o registros fuera del dominio esperado. Estos módulos corresponden al tipo Astronergy y pertenecen a un grupo completo caracterizado en TCLF durante el

mismo día, lo que nos indica que efectivamente los errores se asocian a errores al momento de medir.




Figura 38: Ejemplos de curvas con errores de medición.

Estos módulos fueron etiquetados como casos con Error de Medición (EM1 o EM2) y considerados de forma diferenciada en los clasificadores posteriores, si bien también se les realiza los análisis de falla, al presentar EM1 y EM2 estos análisis no son tomados en cuenta en el veredicto final del módulo.

Estos resultados experimentales constituyen la base para la aplicación de los métodos de clasificación automática descritos en las siguientes secciones.

5.3 Resultados de Clasificación por Análisis de Porcentaje de Color

La clasificación por análisis de porcentaje de color se aplicó sobre las imágenes GADF generadas a partir de datos de corriente y voltaje de las curvas I-V normalizadas, con el objetivo de identificar de forma rápida y eficiente ciertas fallas visualmente evidentes mediante patrones cromáticos localizados.

Este método no requiere entrenamiento y se basa en umbrales definidos empíricamente, asociados al porcentaje de color rojo o verde en sectores específicos de cada imagen.

Se definieron regiones de interés (ROIs) sobre cada imagen dividida en una grilla 3x3, 4x4 o 10x10 según el caso, evaluando la intensidad de color en cada sección. Las reglas de clasificación se construyeron a partir del análisis visual de múltiples imágenes GADF, identificando patrones recurrentes en módulos defectuosos. Los porcentajes utilizados en la metodología para cada falla se basan en la proporción de colores en regiones específicas de las imágenes, considerando si su comportamiento se incrementa o disminuye cuando la falla está presente.

A continuación, se detallan los resultados obtenidos para cada tipo de falla detectada con este método:

- **EM2 (Error de Medición 2):**

- *Criterio:* Distorsión extrema de la imagen GADF, se evalúa sección 1_0 (inferior izquierda) de recorte 4x4 imágenes seleccionadas para análisis de falla 3, con más del 98% de color verde dominante.
- *Resultado:* Detección de 11 módulos con error de medición, 100% precisa en todos los casos verificados.

- **Falla 1 (Disminución del Voc):**

- *Criterio 1:* Análisis imagen GADF V, se evalúa sección 0_2 (superior derecha) de recorte 3x3, con al menos 25% de color rojo dominante.
- *Resultado:* Detección de 7/46 módulos con falla 1 presente.
- *Criterio 2:* Comparación directa con dato Voc obtenido desde TCLF.
- *Resultado:* Detección de 39/46 módulos con falla 1 presente.

- **Falla 2 (Disminución de Isc):**
 - *Criterio 1:* Análisis imagen GADF I, cálculo del porcentaje de aumento de color rojo presente entre sección 3_0 (inferior izquierda) y 3_1 para recortes 4x4, con al menos 63% de aumento.
 - *Resultado:* Detección de 2/4 módulos con falla 2 presente.
 - *Criterio 2:* Comparación directa con dato Isc obtenido desde TCLF
 - *Resultado:* Detección de 2/4 módulos con falla 2 presente.

- **Falla 5 (Escalonamiento de la curva I-V):**
 - *Criterio:* Análisis imagen GADF V, se evalúa sección 0_2 (superior derecha) de recorte 3x3, con al menos 40% de color rojo dominante.
 - *Resultado:* Detección de 1/1 módulos con falla 5 presente, precisión del 100%. Región superior izquierda de la imagen, sección 0_2 en grilla de 3x3.

- **Falla 6 (Escalonamiento doble de la curva I-V):**
 - *Criterio:* Análisis imagen GADF V, se evalúa sección 0_9 (superior derecha) de recorte 10x10, con al menos 40% de color rojo dominante.
 - *Resultado:* Detección de 1/1 módulos con falla 6 presente, precisión del 100%.
 - *Condición adicional:* El módulo debe presentar detección de falla 5 para un posterior análisis de presencia de falla 6.

Estos resultados se resumen en la Tabla 11, la cual compila criterios aplicados y aciertos por tipo de falla. La simplicidad del método y su bajo costo computacional lo convierten en una herramienta útil para analizar módulos con fallas que presentan comportamientos sectoriales en imágenes GADF.

Caso particular de la Falla 4, asociado al aumento de la resistencia serie (Rs):

No se presenta metodología y tampoco clasificación para este tipo de falla, debido a que en el conjunto de datos no se presentan módulos con este comportamiento tan marcado, no permitiendo distinguir los patrones característicos asociados a este tipo de falla en imágenes GADF V ni en imágenes GADF I. Lo anterior puede explicarse porque, en los módulos ensayados, los valores de Rs no alcanzan niveles suficientemente elevados como para generar deformaciones significativas en la curva I-V, tales como una inclinación más pronunciada en el tramo inicial de la curva o una reducción evidente del factor de llenado (FF). En consecuencia, al no existir un patrón angular claramente reconocible en las transformadas GADF, ni una evidencia empírica de módulos con este tipo de degradación acentuada, no fue posible implementar un clasificador confiable para esta falla en el presente estudio.

5.4 Resultados de Clasificación mediante Redes Neuronales Convolucionales

Con el objetivo de detectar fallas de tipo estructural de imágenes, se entrenaron modelos de redes neuronales convolucionales (CNN) sobre subconjuntos de imágenes GADF seleccionadas. Se trabajó con modelos binarios para dos casos específicos, donde el conjunto de datos fue balanceado manualmente, y se utilizó una arquitectura CNN sencilla con dos capas convolucionales y activación ReLU, seguida de capas densas para clasificación. Las clasificaciones se realizaron mediante etiquetado de módulos buenos y módulos malos, donde el 80% de los datos se utilizó para entrenamiento y el 20% para validación.

Todos los modelos CNN desarrollados en esta memoria fueron implementados utilizando la biblioteca Keras, con TensorFlow como backend, lo que permitió una configuración flexible de las capas y un entrenamiento eficiente sobre los conjuntos de imágenes transformadas mediante GADF.

- EM1: módulos con errores de medición (curvas inválidas), manifestado por distorsión anómala de la estructura de la imagen GADF V. Este modelo fue entrenado utilizando imágenes GADF V.
- Falla 3: asociada a disminución de resistencia shunt (Rsh), manifestada por una leve curvatura anormal en la zona cercana a Isc, lo que se refleja en imágenes GADF V, específicamente en la zona inferior izquierda de la imagen. Este modelo fue entrenado mediante recortes de imágenes GADF V de módulos Astronergy que no presentan errores de medición (EM1 y EM2), los cuales cumplen la condición presentada en la metodología. Con el fin de aumentar la cantidad de datos, se procedió a realizar diversas versiones de estos recortes mediante pixelado.

Tabla 7: Resultados de precisión de modelos CNN en validación.

Modelo	Accuracy Validación	Observaciones
CNN Falla EM1	0.88	Clasificación binaria robusta; pequeñas dificultades en recall de clase positiva.
CNN Falla 3	0.91	Alta precisión en la identificación de fallas tras recorte y procesamiento GADF-V.

5.4.1 Resultados para Clasificador EM1

El modelo de clasificación para la falla EM1 (Error de Medición 1) fue entrenado con imágenes GADF V, logrando una precisión final de validación de 88.46%. Este modelo fue diseñado para detectar distorsiones severas en la forma de la curva I-V, típicas de errores de medición en el proceso de adquisición de datos. Durante el entrenamiento, se observó una rápida convergencia, alcanzando una precisión del 100% en las primeras épocas, con una validación consistente en torno al 88%, lo cual se muestra en la Tabla 13 del Anexo.

La matriz de confusión correspondiente se presenta a continuación, mostrando un buen equilibrio entre la detección de verdaderos positivos y verdaderos negativos.

Tabla 8: Matriz de confusión para el modelo CNN EM1.

-	Predicho No	Predicho Sí
Verdadero No	12	0
Verdadero Sí	3	11

El modelo mostró una alta capacidad de discriminación, evidenciada también en el reporte de clasificación:

Tabla 9: Reporte de clasificación del modelo EM1.

Clase	Precisión	Recall	F1-score	Soporte
EM1 = No (0)	0.80	1.00	0.89	12
EM1 = Sí (1)	1.00	0.79	0.88	14
Promedio macro	0.90	0.89	0.88	26
Promedio ponderado	0.91	0.88	0.88	26

Estos valores indican que el modelo es altamente confiable para identificar correctamente los módulos sin falla (recall = 1.00 para clase 0), y también eficaz para detectar la mayoría de los casos con falla (precisión = 1.00 para clase 1), aunque con algunos falsos negativos en el límite del umbral.

Clasificación Individual de Módulos EM1

Para evaluar la aplicabilidad del modelo en condiciones reales, se aplicó el clasificador entrenado sobre los módulos del 1 al 75. La condición EM1 se determinó según los siguientes criterios:

- **Probabilidad > 0.6** → EM1 = No (sin falla)
- **Probabilidad < 0.52** → EM1 = Sí (con falla)
- **Probabilidad entre 0.52 y 0.6** → No clasificado (zona de incertidumbre)

Los resultados finales indicaron que:

- 12 módulos fueron clasificados como con falla EM1, todos con distorsiones visibles en sus curvas I-V e imágenes GADF.
- 57 módulos fueron clasificados como sin falla EM1, presentando curvas e imágenes GADF normales.
- 6 módulos quedaron sin clasificación, al presentar probabilidades en el rango de incertidumbre.

Este comportamiento evidencia que el modelo puede detectar con alta precisión distorsiones severas, mientras se mantiene conservador al evitar clasificar casos ambiguos. De esta manera al combinar este modelo con el modelo de clasificación EM2 se tiene la información suficiente para discriminar cuando los módulos presentan error de medición, y así no clasificar erróneamente fallas en módulos clasificados.

5.4.2 Resultados para Clasificador Falla 3 (Disminución Rsh)

El modelo CNN desarrollado para la detección de la Falla 3 fue entrenado utilizando recortes de imágenes GADF V, específicamente del sector inferior izquierdo de cada imagen, las cuales son replicadas en 4 versiones pixeladas. Este tipo de falla es difícil de identificar mediante inspección visual directa, por lo que el enfoque mediante redes neuronales fue especialmente útil.

Durante el entrenamiento, el modelo alcanzó una precisión de validación final de 0.91. En las primeras épocas se evidenció una mejora rápida tanto en la pérdida como en la precisión, manteniéndose un rendimiento estable y elevado a lo largo de las 20 épocas de entrenamiento, lo cual se muestra en la Tabla 12 del Anexo.

La matriz de confusión obtenida al finalizar el entrenamiento se presenta a continuación, en la que se observa un bajo número de falsos positivos y una buena capacidad de generalización, lo que confirma la robustez del modelo para distinguir entre módulos con y sin esta falla específica.

Tabla 10: Matriz de confusión para el modelo CNN Falla 3.

-	Predicho No	Predicho Sí
Verdadero No	30	1
Verdadero Sí	3	9

El modelo mostró una alta capacidad de discriminación para la detección de la Falla 3, evidenciada en el siguiente reporte de clasificación:

Tabla 11: Reporte de clasificación del modelo Falla 3.

Clase	Precisión	Recall	F1-score	Soporte
Falla 3 = No (0)	0.91	0.97	0.94	31
Falla 3 = Sí (1)	0.90	0.75	0.82	12
Promedio macro	0.90	0.86	0.88	43
Promedio ponderado	0.91	0.91	0.90	43

Estos resultados indican que el modelo es altamente preciso al identificar correctamente los módulos sin falla (clase 0), con un recall de 0.97, lo que implica una baja tasa de falsos positivos. Para la clase con Falla 3 (clase 1), el modelo logra una precisión del 0.90, es decir, pocas predicciones incorrectas cuando clasifica un módulo como defectuoso, aunque con un recall más bajo (0.75), lo que sugiere que algunos módulos con falla no fueron detectados, lo cual es posible, teniendo en cuenta que se presentan 4 versiones de imágenes por cada recorte original para análisis de falla 3. El F1-score promedio ponderado de 0.90 confirma un rendimiento equilibrado y sólido del modelo en el conjunto de validación.

Clasificación Individual de Módulos Falla 3

El modelo fue aplicado a un conjunto de 75 módulos, donde cada módulo fue evaluado en base a la clasificación de cuatro imágenes pixeladas generadas desde recortes de imágenes GADF V. Se establecieron los siguientes umbrales de decisión para cada imagen:

- **Probabilidad > 0.9** → Presenta Falla 3
- **Probabilidad < 0.1** → No presenta Falla 3
- **Probabilidad entre 0.1 y 0.9** → No clasificado (zona de incertidumbre)

Cada módulo se clasifica si presenta o no la Falla 3 solo si al menos tres de sus cuatro imágenes clasificadas presentan la misma decisión.

Los resultados obtenidos fueron:

- 15 módulos fueron clasificados como “presenta Falla 3”, evidenciando alteraciones en Rsh.
- 45 módulos fueron clasificados como “no presenta Falla 3”, presentando curvas regulares.
- 15 módulos quedaron sin clasificación, al presentar valores en el rango de incertidumbre.

Este comportamiento muestra que el modelo posee una alta capacidad de discriminación, mientras se mantiene conservador en casos ambiguos, favoreciendo la precisión por sobre la sobre-clasificación.

En general las CNN demostraron ser especialmente útiles para detectar patrones suaves o difíciles de cuantificar visualmente, como caídas graduales de corriente o distorsiones leves de forma. Además, su aplicación posterior es instantánea y escalable a gran número de imágenes.

5.5 Generación de Reporte Automatizado por Módulo

Con el fin de consolidar los resultados obtenidos por cada módulo y facilitar su revisión, se desarrolló un script en Python que permite generar reportes en formato PDF de manera automática. Cada reporte resume tanto la caracterización eléctrica como el resultado del análisis de fallas, integrando múltiples elementos visuales y cuantitativos.

Este informe es especialmente útil para tareas de mantenimiento preventivo, selección de módulos defectuosos, o trazabilidad del comportamiento de cada unidad ensayada.

Estructura del Reporte por Módulo

Cada PDF generado contiene:

- **Curva I-V real vs curva ideal:** sobreposición gráfica que permite evaluar visualmente desviaciones de comportamiento.
- **Imágenes GADF:** versiones transformadas de la curva de corriente y voltaje del módulo y su referencia ideal.
- **Valores medidos de I_{sc} , V_{oc} , I_{mp} y V_{mp} :** obtenidos mediante TCLF por módulo.
- **Clasificación del módulo:** resultado obtenido por el sistema de diagnóstico, indicando si se detectó alguna falla (EM1, EM2, Falla 1 a 6).
- **Veredicto de estado:** diagnóstico final del módulo.

El script recorre una carpeta base donde se almacenan los datos por módulo (curvas, imágenes, resultados de clasificación) y genera un documento PDF individual por cada uno. Los archivos se guardan en una carpeta específica para reportes y presenta la siguiente disposición.

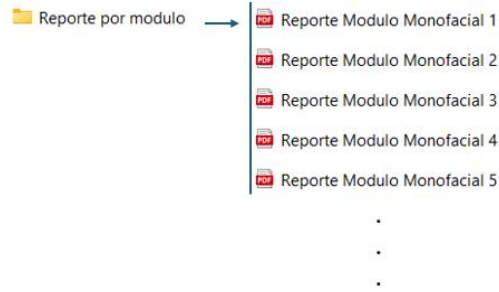



Figura 39: Estructura carpeta de reportes para módulos clasificados.

1. Datos Generales Del Módulo

Número de Módulo: 1
 Tipo de Módulo: Astronergy
 ID: 336443322200656 (1)
 Isc TCLF: 9.30802 A
 Voc TCLF: 30.1039 V
 Imp TCLF: 8.72511 A
 Vmp TCLF: 23.5284 V



2. Datos Generales Del Módulo Ideal STC

Disminución Isc: 9.02 A
 Disminución Voc: 45.55 V





Disminución Imp: 8.8 A
 Disminución Vmp: 35.83 V

3. Estado General Del Módulo

Error de Medición: No / No
 Disminución Isc: No
 Caída escalonada curva I-V: No

Disminución Voc: Si
 Reducción Rsh: No
 Caída escalonada doble curva I-V: No

4. Transformada GADF



5. Veredicto de Estado

El Módulo 1 presenta disminución del voltaje de circuito abierto (Voc).

Figura 40: Ejemplo reporte general automatizado para módulo 1.

Aplicación práctica

Este tipo de reporte permite a un técnico o ingeniero:

- Visualizar rápidamente si un módulo está en condiciones operativas normales.
- Identificar patrones de falla sin necesidad de inspección manual extensa.
- Generar documentación de respaldo para decisiones de reemplazo o intervención técnica en módulo.
- Facilitar el monitoreo histórico si se repite el proceso de clasificación con módulos en intervalos regulares.

5.6 Discusión General y Limitaciones

La implementación del sistema propuesto confirma que el uso de la curva I-V completa como fuente de información constituye una estrategia altamente efectiva para la detección de fallas en módulos fotovoltaicos, en concordancia con lo reportado en la literatura reciente, donde se ha demostrado que el uso de la curva I-V completa mejora significativamente la precisión en la detección de fallas frente a métodos basados en parámetros parciales. A diferencia de enfoques tradicionales basados en parámetros característicos (V_{oc} , I_{sc} , MPP), el uso de representaciones completas y transformadas (como GADF) permite capturar patrones no lineales y distribuidos a lo largo de toda la curva, aumentando significativamente la capacidad discriminativa del modelo.

Esto se debe a que dichas transformaciones proyectan la información en espacios de mayor dimensión, donde las separaciones entre clases se vuelven más evidentes, facilitando la detección de fallas presentes en curvas I-V. Este comportamiento ha sido observado también en estudios donde el uso de la curva completa supera significativamente a los métodos basados en características parciales.

Robustez del Sistema Propuesto

- El sistema mostró alta capacidad de detección para fallas con patrones visuales distintivos, como acumulaciones de color rojo o verde en zonas localizadas (Falla 1, 2, 5, 6, EM2).
- Las redes neuronales convolucionales resultaron especialmente útiles en escenarios donde la degradación era leve, dispersa o afectaba suavemente la forma de la curva (Falla 3), ofreciendo una solución más sofisticada para patrones no lineales.
- La generación automática de reportes estandarizados proporciona un recurso práctico y directo para apoyo en mantenimiento técnico, con potencial de integración a sistemas de gestión de activos fotovoltaicos.

Principales Limitaciones Identificadas

- **Sensibilidad reducida a fallas incipientes:** Algunas fallas con alteraciones mínimas en la curva (por ejemplo, microfisuras no reflejadas aún en el desempeño eléctrico) no generan distorsiones visibles en las imágenes GADF ni afectan los parámetros como I_{sc}/V_{oc} de forma significativa. Su detección requeriría técnicas de mayor resolución o entrenamiento multicategoría más extenso.
- **Conjunto de datos limitado y específico:** El sistema fue entrenado y validado utilizando un conjunto de 75 módulos monofaciales, exclusivamente de las marcas Astronergy (66 módulos) y SunEdison (11 módulos), lo cual corresponde a una cantidad muy baja de datos. Esto reduce la capacidad de generalización del modelo a otros fabricantes, tecnologías (como bifaciales o PERC), o módulos con historial de uso prolongado.

- **Dependencia del preprocesamiento:** Tanto la clasificación por color como el entrenamiento de redes CNN dependen fuertemente de una correcta segmentación de imágenes GADF, recortes definidos y escalas de color normalizadas. Variaciones en estos parámetros podrían afectar el rendimiento del sistema si no se ajustan adecuadamente.
- **Detección binaria por falla:** Actualmente cada CNN está diseñada como clasificador binario (falla sí/no), lo que impide realizar clasificación simultánea de múltiples fallas en un mismo módulo o trabajar con una sola red multicategoría más optimizada.

Estas limitaciones no invalidan los resultados obtenidos, pero sí definen los márgenes actuales del sistema desarrollado y orientan la formulación de futuras investigaciones para expandir su aplicabilidad y robustez.

6 Conclusiones y Recomendaciones

Este capítulo presenta las conclusiones principales derivadas del desarrollo e implementación de un sistema de diagnóstico automatizado de fallas en módulos fotovoltaicos, a partir del análisis de curvas corriente–tensión (I-V). Se proponen líneas futuras de investigación que podrían fortalecer y ampliar el enfoque utilizado.

6.1 Conclusiones Generales

- Se realizó una revisión bibliográfica del comportamiento de la curva I-V al presentar distintas fallas.
- Se caracterizaron 75 módulos defectuosos mediante ensayo de curva I-V en simulador solar TCLF.

- Se logró desarrollar un sistema automatizado de caracterización de fallas en módulos fotovoltaicos monofaciales a partir de curvas I-V obtenidas mediante ensayos en el simulador solar TCLF.
- La transformación de curvas I-V a imágenes GADF permitió una representación visual útil y eficaz para aplicar técnicas de clasificación tanto manuales como automáticas.
- Los clasificadores por porcentaje de color demostraron ser una herramienta rápida y precisa para identificar fallas evidentes con patrones cromáticos localizados.
- Los modelos de redes neuronales convolucionales (CNN) ofrecieron una solución robusta para detectar distorsiones sutiles, con niveles de precisión superiores al 90% en los casos evaluados (EM1 y Falla 3).
- La combinación de ambos métodos (porcentaje color + CNN) permitió una cobertura más amplia y eficaz del espectro de fallas, maximizando tanto velocidad como precisión.
- La generación automatizada de reportes por módulo se consolidó como una herramienta práctica y escalable, facilitando la interpretación de resultados y la toma de decisiones técnicas.

En conjunto, el sistema desarrollado constituye una base sólida para el diagnóstico inteligente de módulos fotovoltaicos en ambientes de laboratorio, con potencial de extensión hacia condiciones de campo y escalamiento industrial.

6.2 Recomendaciones para Investigaciones Futuras

A partir de los resultados obtenidos y las limitaciones identificadas en este estudio, se proponen las siguientes líneas de investigación para ampliar, robustecer y adaptar el

sistema de diagnóstico desarrollado a nuevas condiciones y tecnologías:

- **Entrenamiento de modelos multicategoría:** Desarrollar redes neuronales capaces de clasificar múltiples tipos de fallas simultáneamente, utilizando una única arquitectura CNN o mediante redes tipo multitarea. Esto permitiría una clasificación más completa y una detección de combinaciones de fallas dentro de un mismo módulo. Para ellos es necesario tener una cantidad de datos considerable.
- **Ampliación de la base de datos con mayor diversidad:** Incorporar módulos en mayor cantidad, de diferentes fabricantes, tecnologías (como bifaciales, PERC, vidrio-vidrio), estados de envejecimiento y condiciones de operación reales. Esto fortalecería la capacidad de generalización del sistema y su robustez frente a variaciones de fabricación o uso prolongado.
- **Validación en condiciones reales de campo:** Aplicar el sistema en instalaciones fotovoltaicas operativas para evaluar su desempeño frente a variables externas no presentes en el laboratorio, como acumulación de polvo, humedad, temperaturas extremas, sombreado dinámico o degradación inducida por el tiempo.
- **Mejoras en la interpretación física del diagnóstico:** Complementar la clasificación automática con un sistema de inferencia que relacione cada tipo de distorsión detectada con causas físicas específicas (como desconexión interna, microfisuras, PID, bypass degradado, etc.), apoyándose en literatura y evidencia experimental.
- **Integración de otros parámetros eléctricos o ambientales:** Incluir en el sistema variables adicionales como el factor de forma (FF), potencia máxima (Pmp), eficiencia, o incluso datos climáticos del entorno, para enriquecer el diagnóstico y habilitar sistemas de mantenimiento predictivo más complejos.

Estas recomendaciones buscan no solo mejorar el sistema actual, sino también proyectarlo hacia aplicaciones reales en la industria fotovoltaica, alineándose con las tendencias globales en mantenimiento predictivo, digitalización y automatización del monitoreo de activos energéticos.

7 Bibliografía

- [1] Astronergy. (2015). *CHSM6612P-295~315W Polycrystalline PV Module Datasheet*. Astronergy/Chint Solar.
- [2] Barrenetxea Pascual, A. (2021). *Estudio de los defectos en módulos fotovoltaicos* [Trabajo de Fin de Máster, Universidad del País Vasco].
- [3] Chen, Z., Chen, Y., Wu, L., Cheng, S., & Lin, P. (2019). Deep residual network based fault detection and diagnosis of photovoltaic arrays using current-voltage curves and ambient conditions. *Energy Conversion and Management*, 198, 111793.
- [4] Comisión Nacional de Energía. (2025). *Reporte de proyectos - Enero 2025*.
- [5] Dkhichi, A., Boulouma, S., Chebab, H., & Akhazzane, M. (2021). Fault diagnosis of visual faults in photovoltaic modules: A review. *Energies*, 15(3961), 1–17.
- [6] González, V. (2022). *Desarrollo de métodos automáticos para el diagnóstico de fallas en módulos solares usando curvas I-V* [Memoria de título, Universidad Técnica Federico Santa María].
- [7] Guajardo, D. (2022). *Caracterización experimental de módulos fotovoltaicos para diagnóstico de fallas mediante análisis de curvas I-V* [Memoria de título, Universidad Técnica Federico Santa María].
- [8] IEA-PVPS. (2014). *Review of Failures of Photovoltaic Modules*. IEA PVPS Task 13, Report T13-01:2014.
- [9] International Electrotechnical Commission. (2020). *IEC 60904-1:2020 - Photovoltaic devices – Part 1: Measurement of photovoltaic current-voltage characteristics*.

- [10] Köntges, M., Oreski, G., Herz, M., Hacke, P., & Paggi, M. (2017). Assessment of photovoltaic module failures in the field. *IEA-PVPS T13-09:2017*.
- [11] Krainak, M., Babin, T., & Ptak, A. (2018). Comparisons of I-V curves obtained from xenon and LED-based solar simulators. *IEEE Transactions on Instrumentation and Measurement*, 67(8), 1–8.
- [12] Li, B., Delpha, C., Migan-Dubois, A., & Diallo, D. (2021). Fault diagnosis of photovoltaic panels using full I–V characteristics and machine learning techniques. *Energy Conversion and Management*, 248, 114785.
- [13] Livera, A., Theristis, M., Makrides, G., & Georghiou, G. E. (2019). Recent advances in failure diagnosis techniques based on performance data analysis for grid-connected photovoltaic systems. *Renewable Energy*, 133, 126–143.
- [14] Mellit, A., Tina, G. M., & Kalogirou, S. A. (2018). Fault detection and diagnosis methods for photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*, 91, 1–17.
- [15] Ministerio de Energía de Chile. (2023). *Reporte Energía Renovable y Almacenamiento 2023*.
- [16] Naciones Unidas. (2015). *Transformar nuestro mundo: la Agenda 2030 para el Desarrollo Sostenible*.
- [17] Wang, Z., Yan, W., & Oates, T. (2015). Time Series Classification from Scratch with Deep Neural Networks: A Strong Baseline. *International Joint Conference on Neural Networks (IJCNN)*.

8 ANEXOS


8.1 Ficha técnica de modulo policristalino Marca ASTRONERGY



Datasheet

Crystalline PV Module

CHSM6612P Series



300
305
310
315
320

EN

ELECTRICAL SPECIFICATIONS					
STC rated output (P_{nom})*	300 Wp	305 Wp	310 Wp	315 Wp	320 Wp
PTC rated output (P_{PTC})**	273.2 Wp	277.9 Wp	282.5 Wp	287.2 Wp	291.9 Wp
Standard sorted output	0/+5 Wp				
Warranted power output STC ($P_{nominal}$)	300 Wp	305 Wp	310 Wp	315 Wp	320 Wp
Rated voltage (V_{mp}) at STC	35.74 V	35.77 V	35.80 V	35.83 V	35.86 V
Rated current (I_{mp}) at STC	8.40 A	8.53 A	8.68 A	8.80 A	8.93 A
Open circuit voltage (V_{oc}) at STC	45.16 V	45.29 V	45.42 V	45.55 V	45.68 V
Short circuit current (I_{sc}) at STC	8.91 A	8.95 A	8.99 A	9.02 A	9.06 A
Module efficiency	15.5%	15.8%	16.0%	16.3%	16.5%
Rated output (P_{NOCT}) at NOCT	209.5 Wp	213.0 Wp	216.5 Wp	220.0 Wp	223.5 Wp
Rated voltage (V_{mp}) at NOCT	32.63 V	32.67 V	32.70 V	32.71 V	32.74 V
Rated current (I_{mp}) at NOCT	6.42 A	6.52 A	6.62 A	6.73 A	6.82 A
Open circuit voltage (V_{oc}) at NOCT	41.44 V	41.56 V	41.68 V	41.80 V	41.92 V
Short circuit current (I_{sc}) at NOCT	6.89 A	6.92 A	6.95 A	6.98 A	7.01 A
Temperature coefficient (P_{mp})	- 0.408%/K		Maximum system voltage (UL/IEC)		1000 V _{oc} ***
Temperature coefficient (I_{sc})	+0.050%/K		Number of diodes		6 (or 3)
Temperature coefficient (I_{mp})	- 0.003%/K		Maximum series fuse rating		15 A
Temperature coefficient (V_{mp})	- 0.406%/K				
Temperature coefficient (V_{oc})	- 0.311%/K				
Normal operating cell temperature (NOCT)	46±2°C				

* Measurement tolerance: ±1-2%
** Performance

*** Option: 1500V_{oc} for special requirement in advance

RELATED PARAMETERS		QUALIFICATION AND LINEAR WARRANTIES	
Cell type	polycrystalline	Product standard	IEC 61215, 61730 / UL 1703
Number of cells / cell arrangement	72 / 6 x 12	Extended product warranty	10 years
Cells dimension	6"	Output decline 2.5%/year performance P_{year} (STC)	1 st year
Packing unit	25 modules	Output decline 0.7%/year performance P_{year} (STC)	2 nd - 25 th years
Weight of packing unit	703 kg / 1550 lbs		

MECHANICAL SPECIFICATIONS	
Outer dimensions (L x W x H)	1954 x 990 x 40 mm 76.93 x 38.98 x 1.57 in
Frame technology	Aluminum, silver anodized
Module composition	Glass / EVA / Backsheet (white)
Weight (module only)	25.8 kg / 56.9 lbs
Front glass thickness	4.0 mm / 0.16 in
Junction box IP rating	IP 65 (above)
*Cable length (UL/IEC)	1150 mm / 45.28 in
Cable diameter (UL/IEC)	12 AWG / 4 mm ²
Maximum load capacity	5400 Pa
Fire performance (UL/IEC)	Type 1 (UL) or Class C (IEC)
Connector type (UL/IEC)	MC type 4 compatible

ARTICLE NUMBER (per panel)-CHSM66 12P Series		
Model	Article No. (IEC)	Article No. (UL)
CHSM6612P-300	200532	200537
CHSM6612P-305	200533	200538
CHSM6612P-310	200534	200539
CHSM6612P-315	200535	200540
CHSM6612P-320	200536	200541

Linear Performance Warranty

* Option: 1000 mm for defined projects in advance.

Figura 41: Ficha Técnica módulo policristalino marca Astronergy.

8.2 Códigos fuente del algoritmo de clasificación automatizada

Debido a su extensión, los códigos fuente correspondientes al algoritmo de clasificación automatizada se adjuntan en la carpeta “Programa de clasificación automatizada”, la cual contiene los archivos en formato .py junto con sus respectivas impresiones en formato .pdf, según lo descrito en la Tabla 5. Además, se incluyen los resultados generados por cada script: gráficos, imágenes, salidas de clasificación, el diccionario de fallas, modelos entrenados de redes neuronales convolucionales (CNN), archivos de resultados en formato .txt, y reportes individuales por módulo en formato .pdf.

8.3 Reporte General de Fallas

Tabla 12: Reporte general de clasificación de fallas por módulo.

Módulo	EM1	EM2	Falla 1	Falla 2	Falla 3	Falla 4	Falla 5	Falla 6
Modulo Monofacial Astronergy	No	No	No	No	No	No	No	No
Modulo Monofacial SunEdison	No	No	No	No	No	No	No	No
Modulo Monofacial 1	No	No	Si	No	No	No	No	No
Modulo Monofacial 2	No	No	No	No	Si	No	No	No
Modulo Monofacial 3	No	No	Si	No	No	No	No	No
Modulo Monofacial 4	No	No	No	No	No	No	No	No
Modulo Monofacial 5	No	No	Si	No	No	No	No	No
Modulo Monofacial 6	No clasificado	No	No	Si	No	No	No	No
Modulo Monofacial 7	No	No	Si	No	No	No	No	No
Modulo Monofacial 8	No	No	Si	No	No	No	No	No
Modulo Monofacial 9	No	No	Si	No	No	No	No	No
Modulo Monofacial 10	No	No	Si	No	No	No	No	No
Modulo Monofacial 11	No	No	Si	No	No	No	No	No
Modulo Monofacial 12	No	No	Si	No	Si	No	No	No
Modulo Monofacial 13	No	No	Si	No	Si	No	No	No
Modulo Monofacial 14	No	No	Si	No	No	No	No	No
Modulo Monofacial 15	No	No	Si	No	Si	No	No	No
Modulo Monofacial 16	No	No	Si	No	Si	No	No	No
Modulo Monofacial 17	No	No	Si	No	Si	No	No	No
Modulo Monofacial 18	No	No	Si	No	No	No	No	No
Modulo Monofacial 19	No	No	Si	No	No	No	No	No
Modulo Monofacial 20	No	No	Si	No	No	No	No	No
Modulo Monofacial 21	No	No	Si	No	No	No	No	No
Modulo Monofacial 22	No	No	Si	No	No	No	No	No
Modulo Monofacial 23	No	No	Si	No	No	No	No	No
Modulo Monofacial 24	No clasificado	No	Si	No	Si	No	No	No
Modulo Monofacial 25	No	No	No	No	No	No	No	No
Modulo Monofacial 26	No	No	Si	No	No	No	No	No
Modulo Monofacial 27	No	No	Si	No	No	No	No	No
Modulo Monofacial 28	No	No	Si	No	No	No	No	No
Modulo Monofacial 29	No	No	Si	No	No	No	No	No
Modulo Monofacial 30	No	No	Si	No	No	No	No	No
Modulo Monofacial 31	No clasificado	No	No	No	No	No	No	No

Módulo	EM1	EM2	Falla 1	Falla 2	Falla 3	Falla 4	Falla 5	Falla 6
Modulo Monofacial 32	No	No	Si	No	No	No	No	No
Modulo Monofacial 33	No	No	Si	No	Si	No	No	No
Modulo Monofacial 34	No	No	No	No	No	No	No	No
Modulo Monofacial 35	No	No	Si	No	No	No	No	No
Modulo Monofacial 36	No	No	Si	No	Si	No	No	No
Modulo Monofacial 37	No clasificado	No	No	No	No	No	No	No
Modulo Monofacial 38	No clasificado	No	No	No	Si	No	No	No
Modulo Monofacial 39	No	No	Si	No	No	No	No	No
Modulo Monofacial 40	No	No	Si	No	No	No	No	No
Modulo Monofacial 41	No	No	Si	No	No	No	No	No
Modulo Monofacial 42	No clasificado	No	Si	Si	No	No	No	No
Modulo Monofacial 43	No	No	Si	No	No	No	No	No
Modulo Monofacial 44	No	No	Si	No	No	No	No	No
Modulo Monofacial 45	No	No	Si	No	No	No	No	No
Modulo Monofacial 46	No	No	Si	No	No	No	No	No
Modulo Monofacial 47	No	No	Si	No	Si	No	No	No
Modulo Monofacial 48	No	No	Si	No	No	No	No	No
Modulo Monofacial 49	No	No	Si	No	Si	No	No	No
Modulo Monofacial 50	No	No	Si	No	No	No	No	No
Modulo Monofacial 51	No	No	Si	No	Si	No	No	No
Modulo Monofacial 52	No	No	Si	No	Si	No	No	No
Modulo Monofacial 53	No	No	Si	No	No	No	No	No
Modulo Monofacial 54	No	No	Si	No	No	No	No	No
Modulo Monofacial 55	Si	Si	No	Si	No clasificado	No	No	No
Modulo Monofacial 56	Si	Si	No	Si	No clasificado	No	No	No
Modulo Monofacial 57	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 58	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 59	Si	Si	No	Si	No clasificado	No	No	No
Modulo Monofacial 60	No clasificado	Si	No	Si	Si	No	No	No
Modulo Monofacial 61	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 62	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 63	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 64	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 65	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 66	Si	Si	Si	Si	No clasificado	No	No	No
Modulo Monofacial 67	No	No	No	No	No clasificado	No	No	No

Módulo	EM1	EM2	Falla 1	Falla 2	Falla 3	Falla 4	Falla 5	Falla 6
Modulo Monofacial 68	No	No	Si	No	No clasificado	No	No	No
Modulo Monofacial 69	No	No	No	No	No clasificado	No	No	No
Modulo Monofacial 70	No	No	No	No	No clasificado	No	No	No
Modulo Monofacial 71	No	No	No	Si	Si	No	Si	No
Modulo Monofacial 72	No	No	No	No	No clasificado	No	No	No
Modulo Monofacial 73	No	No	No	No	No clasificado	No	No	No
Modulo Monofacial 74	No	No	No	No	No clasificado	No	No	No
Modulo Monofacial 75	No	No	No	Si	No clasificado	No	No	Si

8.4 Resultados entrenamiento de modelos CNN

Tabla 13: Evolución de métricas durante el entrenamiento modelo CNN Falla 3.

Época	Accuracy Entrenamiento	Accuracy Validación	Loss Validación
1.0	0.5917	0.7442	0.4865
2.0	0.6982	0.7442	0.4726
3.0	0.8876	0.9070	0.3805
4.0	0.9290	0.8837	0.4347
5.0	0.9349	0.8837	0.4756
6.0	0.9645	0.8837	0.5368
7.0	0.9408	0.8837	0.7245
8.0	0.9467	0.9302	0.8587
9.0	0.9290	0.8837	0.7315
10.0	0.9704	0.8837	0.7393
11.0	0.9763	0.9302	1.0536
12.0	0.9408	0.8605	0.6330
13.0	0.9467	0.8605	0.6400
14.0	0.9645	0.8837	0.8830
15.0	0.9645	0.9070	0.6610
16.0	0.9704	0.9070	0.7622
17.0	0.9704	0.9070	0.7894
18.0	0.9704	0.8837	0.8553
19.0	0.9704	0.9070	0.8394
20.0	0.9763	0.9070	0.9555

Tabla 14: Evolución de métricas durante el entrenamiento modelo CNN EM1.

Época	Accuracy Entrenamiento	Accuracy Validación	Loss Validación
1.0	0.8846	0.8462	0.5545
2.0	1.0000	0.8462	0.4804
3.0	1.0000	0.8846	0.4401
4.0	1.0000	1.0000	0.4406
5.0	1.0000	0.5385	0.4778
6.0	1.0000	0.5385	0.5480
7.0	1.0000	0.5385	0.6395
8.0	1.0000	0.5385	0.7565