


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



**DISEÑO DE UN ALGORITMO DE
EVALUACIÓN DEL RENDIMIENTO DE
MÓDULOS FOTOVOLTAICOS EN
OPERACIÓN BASADO EN ANÁLISIS DE
IMÁGENES**

ROBINSON DANIEL CAVIERES ABARCA

**MEMORIA PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE
LA INGENIERÍA MECÁNICA**

PROFESOR GUÍA : PhD. RODRIGO BARRAZA
PROFESOR CORREFERENTE (1): Dr. Ing. DANILO ESTAY
PROFESOR CORREFERENTE (2): PhD. JOSÉ BILBAO

ENERO 2021

Resumen

La energía solar fotovoltaica es una herramienta que está encontrando su lugar en el mercado, pero aún es necesario mejorar las técnicas de monitoreo para lograr un salto definitivo a ser una alternativa comercialmente atractiva para los inversionistas.

El objetivo de esta investigación es desarrollar un algoritmo de monitoreo de paneles solares basado en análisis de imágenes, capaz de evaluar el rendimiento de múltiples módulos en operación simultáneamente basándose en una imagen RGB capturada en el espectro visible. El modelo diseñado debe ser simple, eficaz y capaz de aplicarse en múltiples condiciones.

Para lograr este objetivo, se desarrollan dos enfoques principales, uno basado en arquitectura de redes neuronales artificiales, capaz de procesar características extraídas manualmente de las imágenes y usar la información para predecir el rendimiento de los módulos fotovoltaicos como un valor de carácter continuo. El algoritmo desarrollado muestra resultados prometedores para ensuciamiento de acumulación natural, con un R^2 de 0,96 y un error cuadrático medio de $4,87 \cdot 10^{-5}$ para el conjunto de validación, pero no es efectivo para sombreamiento parcial ni ensuciamiento de acumulación artificial.

El segundo enfoque se basa en arquitectura de redes neuronales convoluciones, capaz de identificar, segmentar y analizar cada módulo fotovoltaico presente en una imagen y evaluar el rendimiento individualmente, como un valor categórico. Este nuevo enfoque es capaz de pronosticar correctamente el desempeño de módulos sujetos a ensuciamiento natural, artificial y sombreamiento parcial, alcanzando una precisión de un 73 % sobre 8 categorías, y concentrando la mayor parte del error en categorías aledañas, logrando así una herramienta sólida para el diagnóstico de módulos fotovoltaicos.

Abstract

Photovoltaic solar power is a technology that is finding its place in global markets, but it is still necessary to improve monitoring approaches to achieve a definitive leap to being a commercially attractive alternative for investors.

The goal of this research is to develop an algorithm for monitoring solar panels based on image analysis, capable of evaluating the performance of multiple modules in operation simultaneously. The designed model must be simple, effective and capable of being applied in multiple conditions.

To achieve this goal, two main approaches are developed, one based on artificial neural network architecture, capable of processing characteristics extracted manually from the images and using the information to predict the performance of photovoltaic modules as a continuous value. The developed algorithm shows promising results for natural soiling, with an R^2 of 0,96 and a mean square error of $4,87 \cdot 10^{-5}$ for the test set, but it is not effective for partial shading or artificial soiling.

The second approach is based on convolutional neural network architecture, capable of identifying, segmenting and analyzing each photovoltaic module present in an image and evaluating the performance individually, as a categorical value. This new approach is capable of correctly predicting performance of modules subject to natural and artificial soiling and partial shading, scoring an accuracy of 73 % over 8 categories, and concentrating most of the error in neighboring categories, thus achieving a solid tool for PV module diagnostics.

Índice general

1. Introducción	1
1.1. Objetivos	2
1.1.1. Objetivo principal	2
1.1.2. Objetivo secundarios	3
2. Estado del arte	4
2.1. Técnicas de medición de Soiling	4
2.2. Análisis de imágenes	5
2.3. Monitoreo con análisis de imágenes	6
3. Montaje Experimental	10
3.1. Laboratorio de fallas	10
3.1.1. Módulos a analizar	10
3.1.2. Monitoreo de variables eléctricas	12
3.1.3. Monitoreo de variables ambientales	13
3.1.4. Almacenamiento de datos	14
3.1.5. Captura de imágenes	14
3.2. Creación del conjunto de datos	15
3.2.1. Filtrado de mediciones anómalas	15
3.2.2. Filtrado y procesamiento de imágenes	16
3.2.3. Validación del ensuciamiento natural	16
3.2.4. Etiquetado	17
3.2.5. Aplicación del conjunto Deep Solar Eye	19
4. Análisis Estadístico	20
4.1. Metodología	20
4.2. Pre-Análisis y Etiquetado	20

4.3. Extracción y Selección de Características	21
4.4. Aplicación en Deep Solar Eye	25
5. Análisis con Redes Neuronales	27
5.1. Metodología	27
5.2. Segmentación	28
5.3. Normalización	32
5.4. Análisis	35
5.4.1. Procesamiento Previo	36
5.4.2. Creación de la ANN	37
5.5. Resultados	40
5.6. Integración del Algoritmo	44
6. Conclusiones y recomendaciones	46

Índice de figuras

2.1. Descomposición matricial de una imagen RGB.	6
2.2. Funcionamiento de una red neuronal convolucional.	6
2.3. Descomposición espectral de (a) panel limpio y (c) sucio	7
2.4. Estado del arte en análisis de imágenes	8
3.1. Laboratorio de fallas en operación.	11
3.2. Módulos instalados en el laboratorio con sus respectivas tecnologías. . .	11
3.3. Estructura de soporte del módulo.	12
3.4. Esquema de medición de variables eléctricas.	13
3.5. Estación meteorológica.	14
3.6. Generación del módulo de referencia versus radiación el plano recibida para (a) datos brutos y (b) filtrados.	16
3.7. Panel sucio original (a) y con corrección de perspectiva (b).	17
3.8. Performance Ratio en el tiempo.	18
4.1. Etapas del algoritmo de análisis estadístico.	21
4.2. Panel en diferentes canales de color, (a) Original, (b) Escala de grises, (c) Matiz, (d) Saturación.	22
4.3. Extracción y selección de características de Balu sobre el conjunto de datos del laboratorio de fallas.	23
4.4. Red Neuronal Artificial usada para evaluar el ensuciamiento en paneles. . .	23
4.5. Comparación entre predicción y valor real para el conjunto de evaluación. .	24
4.6. Selección de características de Balu, aplicado al conjunto Deep Solar Eye.	25
4.7. Red neuronal aplicada al conjunto Deep Solar Eye.	26
4.8. Red neuronal entrenada en el conjunto Deep Solar Eye.	26

5.1. Esquema de operación del modelo propuesto	27
5.2. Detección, clasificación y segmentación	28
5.3. Ejemplo de Mask RCNN.	30
5.4. Muestras del conjunto de entrenamiento.	30
5.5. Validación del modelo entrenado.	31
5.6. Máscaras generadas a partir de la ilustración 5.5(b).	32
5.7. Imagen de prueba (a) con su respectiva máscara binaria (b).	33
5.8. Representación del algoritmo de hormiga.	34
5.9. Bordes capturados por el algoritmo de hormiga aproximado a un cuadrilátero.	35
5.10. Módulo 5.7(a) normalizado.	35
5.11. Muestras del conjunto de entrenamiento.	37
5.12. Esquema CNN original.	39
5.13. Enfoques de selección para una distribución de ejemplo.	39
5.14. Probabilidad máxima de cada decisión sobre el conjunto de validación.	41
5.15. Distribución del error de selección para octiles	42
5.16. Predicciones sobre el conjunto de validación para cada método de selección.	43
5.17. Validación del modelo integrado.	44

Índice de tablas

3.1. Paneles instalados con sus respectivos estados de operación.	10
4.1. Desempeño de la red sobre el conjunto de evaluación para diferentes profundidades.	24
5.1. Datos de entrenamiento del modelo	31
5.2. Etiquetas de clasificación.	36
5.3. Desempeño de las redes neuronales sobre el conjunto de validación. . .	40
5.4. Valores calculados y reales de la ilustración 5.17.	45

Capítulo 1

Introducción

Las plantas de energía solar fotovoltaica han alcanzado un destacado lugar en el mercado energético debido a sus bajos costos de operación, bajo impacto ambiental y políticas de fomento desarrolladas por algunos gobiernos [1]. En Chile, la potencia instalada a junio del 2020 alcanza una capacidad de 3,05 [GW] [2] y se espera que ese número siga creciendo en el futuro, proyectando hasta 20 [GW] al año 2050 [3]. Los fabricantes aseguran que un módulo fotovoltaico tiene una vida útil entre 25 y 30 años [4], lo que puede ser reducido debido a las condiciones de transporte, de instalación y de operación. Los módulos fotovoltaicos pueden ser afectados por diversos modos de falla [5], ya sean debido a factores ambientales, fenómenos eléctricos y mecánicos. Un módulo en falla traerá consigo una baja de la producción de energía, disminución de la vida útil y riesgos inminentes para otros componentes de la planta fotovoltaica. Para maximizar la generación eléctrica de sistemas fotovoltaicos y la vida útil de sus componentes es necesario desarrollar estrategias de operación y mantenimiento que sean capaces de detectar de manera temprana y responder de forma adecuada ante el deterioro de las condiciones de operación.

Existen varias técnicas de inspección para detectar fallas en instalaciones fotovoltaicas, partiendo desde las más convencionales que involucran mediciones de curvas I-V para detectar anomalías a nivel de strings o de módulos [6], modelos digitales del sistema llamados “Digital Twin” [7] que simulan la operación en condiciones ideales y entregan un punto de comparación de rendimiento, hasta plataformas de monitoreo en línea que recogen y analizan datos de operación en tiempo real para identificar cambios en la condición de operación que puedan ser producto de una falla [8]. Sin embargo, la operación y el mantenimiento de plantas fotovoltaicas ha resultado una tarea compleja

debido a que estos sistemas se componen de cientos de miles de módulos dispuestos en grandes superficies. Para evaluar el rendimiento en tiempo real de la instalación y gestionar el mantenimiento con precisión es necesario conocer la condición de operación detallada de cada activo y es en este punto donde las técnicas antes mencionadas presentan algunos inconvenientes. Las mediciones de curvas I-V parecen ser una herramienta útil una vez que se tiene identificada una zona acotada con problemas. Su aplicación masiva es costosa debido a la gran cantidad de módulos, la necesidad de desconexión de cada módulo y el personal capacitado dedicado a esta labor. Sistemas como el “Digital Twin” entregan un punto de comparación y pueden detectar una disminución de producción de energía, pero no son capaces de identificar la causa ni la ubicación del problema. Las plataformas de monitoreo en línea dependen exclusivamente de la información que reciben, por lo que, si no se capta información detallada (a nivel de string, combiner box, y de cada módulo), no es posible distinguir entre distintos modos de fallas y en la ubicación de estas mismas. Un sistema de monitoreo ideal debería ser capaz de recorrer un sistema con rapidez, entregar un gran nivel de detalle en cuanto a modos de falla y ubicación de los fenómenos y estimar cual es la pérdida de producción de energía [9]. Conociendo esta información, es posible orientar las acciones mantenimiento y optimizar la vida útil y el rendimiento económico de la planta

Este escenario ha llevado a la búsqueda de nuevas tecnologías métodos de monitoreo de plantas solares fotovoltaicas, enfocándose principalmente en alternativas económicas, de fácil implementación y sean capaces de aplicarse efectivamente en grandes instalaciones.

1.1. Objetivos

1.1.1. Objetivo principal

El objetivo principal de este trabajo es desarrollar una plataforma de análisis de imágenes capaz de evaluar el rendimiento de módulos fotovoltaicos en operación sujetos a ensuciamiento y sombreadamiento.

1.1.2. Objetivo secundarios

- Analizar el estado del arte relevante en cuanto a técnicas de medición del ensuciamiento y monitoreo de módulos fotovoltaicos por medio de análisis de imágenes.
- Crear una base de datos de imágenes de módulos fotovoltaicos etiquetados con variables ambientales y eléctricas.
- Desarrollar un modelo estadístico que relacione características extraídas de la imagen de un módulo y el rendimiento instantáneo.
- Desarrollar un algoritmo basado en redes neuronales convolucionales cumpliendo con las siguientes etapas:
 - Construir un modelo capaz de identificar y segmentar módulos fotovoltaicos en distintos pasajes.
 - Automatizar la corrección de perspectiva y dimensionamiento de los módulos segmentados.
 - Diseñar una red neuronal convolucional que tome como entrada la imagen de un módulo y estime el rendimiento instantáneo.

Capítulo 2

Estado del arte

En este capítulo se realiza una revisión de los aspectos generales relacionados a la medición y caracterización del ensuciamiento y su efecto sobre los módulos fotovoltaicos, y a su vez, se dan a conocer las principales aplicaciones en cuanto detección de fallas mediante análisis de imágenes en paneles solares.

2.1. Técnicas de medición de Soiling

Actualmente, el soiling se caracteriza por las alteraciones físicas a las condiciones de operación de la planta. Si bien el efecto siempre será el mismo, disminución de la generación de energía, es posible cuantificarlo gracias a otros fenómenos.

Enfoques descritos en [10] [11] cuantifican el ensuciamiento mediante la variación de la masa de un módulo. Cuando se depositan las partículas de polvo sobre la superficie del panel, equipos con un alto grado de precisión son capaces de captar la masa de muestras recogidas de la superficie de los módulos. Esta técnica resulta bastante útil para cuantificar la tasa de acumulación de ensuciamiento, pero ya que medir la masa del soiling no revela la distribución de las partículas de polvo y las propiedades de estas mismas, no es posible obtener una correlación directa entre masa y pérdida de potencia.

Otras técnicas se descritas en [12] [13] se basan el impacto que tiene el ensuciamiento sobre la transmisividad de la cara superior del módulo. Un haz de luz que cruza una superficie sucia sufrirá de una mayor dispersión y absorción, lo que se traducirá en una menor intensidad en el punto de medición. Usando herramientas como piranóme-

tros ubicados bajo cubiertas limpias y expuestas a ensuciamiento, es posible estimar cuanta radiación deja de recibir el módulo. Sin embargo, esta técnica depende fuertemente de la naturaleza del soiling. Un haz de luz proyectado sobre un piranómetro podrá medir con precisión sobre una pequeña superficie, y la medición será escalable solo si el patrón de ensuciamiento es uniforme sobre todo el módulo.

Aplicaciones más prácticas [14] [15] miden el impacto del soiling en las variables de operación eléctricas de la planta. Particularmente, la corriente de cortocircuito resulta un excelente indicador, ya que las variaciones de voltaje son mínimas frente a la disminución de irradiancia. Sin embargo, la corriente de cortocircuito es sensible a la temperatura de operación del módulo, por lo que, si no se corrige, las mediciones pueden arrojar resultados irregulares.

Todos los enfoques mencionados anteriormente sufren la desventaja de ser mediciones referenciales, donde el fenómeno del soiling se estudia sobre un área de control determinada, y los resultados se extrapolan al resto de la instalación. Los patrones de ensuciamiento no son necesariamente homogéneos a lo largo de toda la instalación y escalar la medición para abarcar una mayor cantidad de equipos resulta económicamente costoso.

2.2. Análisis de imágenes

En visión computacional, el píxel es la unidad fundamental indivisible que compone una imagen. Cada imagen puede ser representada como una matriz de dimensiones $M \times N$, donde M es el número de píxeles de ancho y N de largo. Dependiendo de la intensidad del color representado, cada píxel toma un valor distinto. Generalmente, las imágenes son procesadas en formato de 8 bits, lo que quiere decir que un píxel puede tomar un valor entre 0 y 256, y dependiendo del espacio de color analizado, pueden existir hasta 3 matrices de píxeles que compongan una imagen (ilustración 2.1 [16]).

Al procesar las imágenes como objetos matriciales, es posible aplicar operaciones matemáticas par encontrar patrones que ayuden a describir la imagen. Técnicas clásicas de análisis de imágenes usan estadística para procesar la información.

Recientemente el uso de redes neuronales convolucionales (CNN) ha permitido un análisis más profundo de imágenes, logrando grandes avances en el campo de visión computacional (ilustración 2.2 [17]).




Figura 2.1: Descomposición matricial de una imagen RGB.




Figura 2.2: Funcionamiento de una red neuronal convolucional.

2.3. Monitoreo con análisis de imágenes

La visión computacional aplicada a instalaciones fotovoltaicas es un campo actualmente en investigación. Con ayuda de cámaras digitales y estaciones de monitoreo ambiental, recursos disponibles en la gran mayoría de plantas solares en operación, sería posible construir una herramienta de mantenimiento basado en condición que permita monitorear una gran cantidad de equipos sin incurrir en mayores gastos económicos. Acoplando la cámara a una unidad de vuelo no tripulada, el radio de alcance del monitoreo aumentaría dramáticamente.

La figura 2.3, obtenida desde el laboratorio representa la descomposición espectral en 2 celdas distintas, una sana y otra sucia. Si bien a simple vista es posible distinguir cual es el sucio, es necesario explicar matemáticamente las diferencias entre ambas celdas. Los gráficos de la columna derecha representan el histograma de frecuencias de intensidad de píxeles en descomposición en canales RGB de ambas imágenes. El

análisis de imágenes en paneles busca relacionar la diferencia entre ambos gráficos con diversos modos de falla.




Figura 2.3: Descomposición espectral de (a) panel limpio y (c) sucio

La investigación reciente usando estas técnicas se puede resumir en la figura 2.4 . Cada recuadro representa un nivel dentro del análisis de imágenes y la información que se obtiene del algoritmo. Es importante destacar que no todos los modos de falla conocidos son visibles en todos los espectros. En la actualidad, se investigan 3 tipos de imágenes: Espectro Visible [18], Espectro Infrarrojo [19] y Electroluminiscencia [20].

Usando imágenes captadas mediante termografía infrarroja, [21] usa técnicas de procesamiento estadísticas para detectar automáticamente puntos calientes dentro de un módulo en operación. Aplicando detección de bordes acoplados a histogramas de

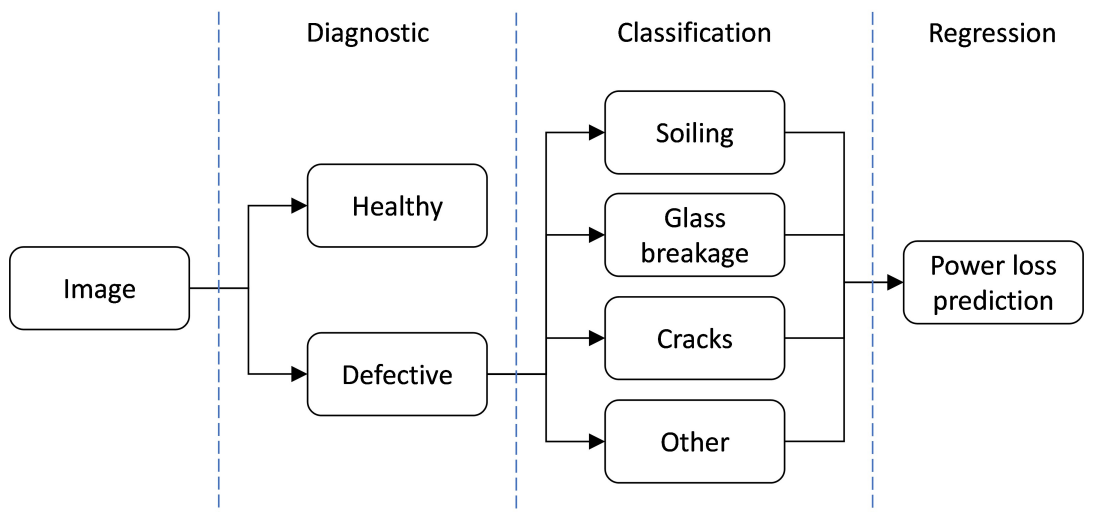


Figura 2.4: Estado del arte en análisis de imágenes

temperatura, es posible encontrar la formación de hotspots con una gran precisión. Sin embargo, el diagnóstico emitido por la herramienta es de carácter binario, solo discriminando entre celdas sanas y defectuosas.

Dentro del mismo enfoque de termografía, [22] extrae características como contraste, energía y entropía, para luego construir un clasificador bayesiano que calcula una probabilidad explícita para cada estado (sano y defectuoso). Al igual que en el caso anterior, la clasificación es binaria y no entrega información acerca de las pérdidas de producción de energía que experimenta el módulo.

En análisis en espectro visible, [23] usa histogramas de frecuencia de píxeles en canales RGB para localizar y determinar el nivel de ensuciamiento en paneles, ya sea puntual o distribuido sobre la superficie del módulo. Si bien el algoritmo muestra resultados prometedores a la hora de encontrar ensuciamiento, no hay una evaluación sobre la pérdida de producción de energía.

Finalmente, [14] extrae características como contraste, entropía y energía, y probando diferentes tipos de clasificadores como redes neuronales artificiales, máquinas de soporte vectorial y otros, las procesa para obtener una clasificación acerca del nivel de ensuciamiento del panel. Al igual que en el caso anterior, las etiquetas están asociadas a una métrica visual y no a la pérdida de producción de energía

El segundo recuadro involucra la clasificación, es decir, después de decidir si un módulo efectivamente es defectuoso, es capaz de clasificar la falla que se está experimentando. El uso de redes neuronales ha permitido distinguir distintos modos de falla dentro de una imagen, siempre y cuando se tenga información al respecto en la etapa de entrenamiento. El trabajo presentado en [24] aplica técnicas de Machine Learning y analiza imágenes de electroluminiscencia. Por medio de TensorFlow [25], se extraen características de cinco tipos de degradaciones diferentes en celdas solares con redes neuronales (CNN) y máquinas de soporte vertical (SVM). La validación cruzada arrojó que ambos clasificadores tenían una precisión sobre el 98 %. Usando el método de análisis de componentes principales, se filtraron las características más dominantes del conjunto obtenido. Con esta información se construyó un algoritmo no supervisado capaz de clasificar entre celdas degradadas y no degradadas, mostrando resultados prometedores.

El último nivel es un enfoque regresivo, que consiste en estimar el impacto del modo de falla identificado en la producción de energía. Para lograr un diagnóstico de este tipo, se requieren grandes bases de datos de imágenes etiquetadas con sus respectivos modos de falla, datos de generación y condiciones ambientales, por lo que hay pocos investigadores que han incursionado en esta etapa. El avance más significativo es la herramienta Deep Solar Eye [26], capaz de evaluar el impacto de diferentes tipos de soiling sobre los módulos, identificando el tipo de suciedad, la ubicación sobre el módulo, la pérdida estimada de producción de energía y una recomendación en acciones de mantenimiento correctivo. Dado que la segmentación de módulos es de carácter manual, el algoritmo se ve en desventaja a la hora de analizar múltiples módulos dentro de una misma imagen, lo que limita su aplicación en grandes instalaciones.

Capítulo 3

Montaje Experimental

3.1. Laboratorio de fallas

En esta sección se describirá la configuración experimental del laboratorio de fallas (ilustración 3.1), los módulos a analizar, el monitoreo de variables relevantes y la captura de imágenes. El montaje, la selección y la configuración de los equipos utilizados se puede ver con más detalle en Zelada [27].

3.1.1. Módulos a analizar

El laboratorio se compone de 8 módulos representados en la ilustración 3.2, con potencia nominal de 315[W]. Las marcas y tecnologías se pueden apreciar en la tabla 3.1, junto con la condición en la que operan en el laboratorio.

Todos los módulos a analizar se instalan sobre la estructura de soporte representada

Módulo	Marca	Código	Estado
Panel 1	SunEdison	FMB15060100737	Quebrado y sucio artificial
Panel 2	SunEdison	FMB15050801435	Sucio natural
Panel 3	SunEdison	FMB15060402341	Limpio
Panel 4	SunEdison	FMB15060901529	Quebrado y limpio
Panel 5	SunEdison	33641 33222200008	Limpio
Panel 6	SunEdison	FMB15032101652	Sucio artificial
Panel 7	ASTROENERGY	33679 33232203139	Limpio
Panel 8	ASTROENERGY	33800 33242202007	Sucio natural

Tabla 3.1: Paneles instalados con sus respectivos estados de operación.



Figura 3.1: Laboratorio de fallas en operación.




Figura 3.2: Módulos instalados en el laboratorio con sus respectivas tecnologías.




Figura 3.3: Estructura de soporte del módulo.

en la figura 3.3 . El ángulo de inclinación cenital de los módulos se ajusta al valor óptimo de acuerdo con la ubicación del laboratorio (33°). Para asegurar la repetibilidad del experimento, tanto la posición como el ángulo de inclinación de las estructuras se mantendrán fijos.

La configuración de operación de los módulos, explicada en la tabla 3.1, consta de variados módulos patrones que representan la generación óptima. Estos módulos se limpian diariamente para evitar la acumulación de soiling y se realizan mediciones de curva I-V semanalmente para asegurar la salud del panel. Los otros módulos del laboratorio experimentan ensuciamiento y modos de falla visible en el espectro infrarrojo.

Para lograr patrones de ensuciamiento similares a los que ocurren en instalaciones fotovoltaicas operacionales en el laboratorio, los módulos expuestos a acumulación de soiling forma natural no son limpiados pero si son evaluados semanalmente con curvas IV para asegurar que no están experimentando otros modos de falla . Por la misma razón, en caso de lluvia los módulos se cubrirán con una plancha protectora para evitar una limpieza accidental.

3.1.2. Monitoreo de variables eléctricas

Cada módulo cuenta con una conexión eléctrica individual, de tal forma que las diferentes condiciones de operación de cada módulo no interfieran entre sí. Por este

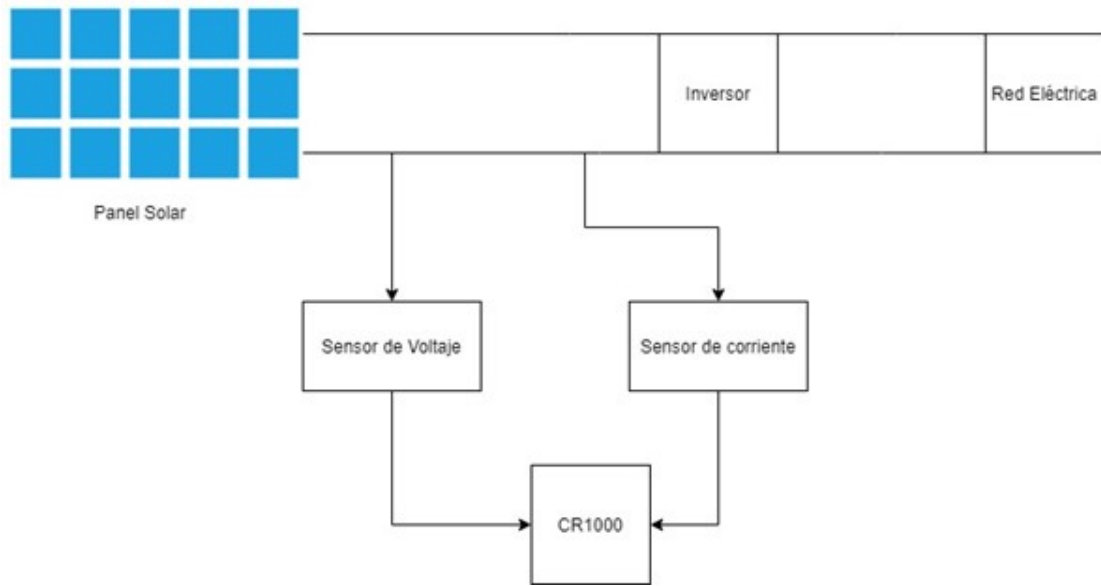


Figura 3.4: Esquema de medición de variables eléctricas.

motivo, el monitoreo de variables eléctricas se realiza a nivel individual, según el arreglo ilustrado en la figura 3.4.

El voltaje del módulo se mide mediante un divisor de tensión, mientras que la corriente se mide con una resistencia Shunt. Los sensores se instalan entre el panel y el microinversor. Ambas mediciones se transmiten a un datalogger modelo cr1000.

3.1.3. Monitoreo de variables ambientales

Paralelamente a la medición de variables eléctricas, una estación meteorológica (ilustración 3.5) monitorea las condiciones ambientales en que operan los módulos fotovoltaicos.

La medición de la radiación se da por en 2 configuraciones distintas. Midiendo radiación global horizontal se encuentran 2 piranómetros, el propio de la estación, modelo RSR2, y uno modelo CMP10 que contrasta y valida las mediciones. Para la radiación en el plano de inclinación de los módulos, un segundo piranómetro CMP10 se ubica en el mismo ángulo de inclinación que las estructuras.

Un sensor de variables medioambientales modelo 083E se encarga de medir temperatura ambiente y humedad relativa del aire, mientras que un anemómetro mide la velocidad del viento.



Figura 3.5: Estación meteorológica.

Al igual que en el caso de las variables eléctricas, los sensores envían la señal a un datalogger modelo CR1000

3.1.4. Almacenamiento de datos

El registro de datos del monitoreo de variables eléctricas y ambientales se hace en dataloggers modelo CR1000. Estos equipos están programados para registrar las mediciones que reciben de los sensores minuto a minuto, simultáneamente. Para su posterior uso, se genera un archivo de extensión csv, con todas las variables registradas para cada minuto de medición. Con los valores de intensidad de corriente y voltaje se obtiene la potencia que está generando el panel, valor que se calcula junto con las mediciones registradas.

3.1.5. Captura de imágenes

La captura de imágenes se realiza con una cámara programable, marca BOSCH, modelo MIC9000i. El equipo es una cámara de carácter estacionario, capaz de regis-

trar imágenes tanto en el espectro visible como en el infrarrojo, con la posibilidad de variar el ángulo cenital y azimutal. Se desarrolla un programa que automatiza la captura de imágenes; cada panel será enfocado y fotografiado individualmente en un ciclo de 10 minutos. Las imágenes resultantes se guardan en un computador con la etiqueta (ID)(AAAA)(MM)(DD)(HH)(MM) para su posterior análisis.

3.2. Creación del conjunto de datos

En esta sección se discutirán los procedimientos de filtrado y selección aplicados a los datos obtenidos en el laboratorio de fallas para su análisis en capítulos posteriores. Para este análisis, solo se considerarán los paneles 7 y 8 de la ilustración 3.2, los cuales de ahora en adelante se llamarán panel de referencia y panel sucio respectivamente.

3.2.1. Filtrado de mediciones anómalas

El filtrado de datos se hará respecto del panel de referencia. Este módulo representa la operación óptima y su comportamiento establecerá la comparación con el panel sucio. Por lo tanto, es necesario eliminar cualquier medición anómala que pueda llevar a una comparación errónea respecto de la condición de otros módulos. En la ilustración 3.6(a) se representa la producción de energía en función de la irradiancia recibida. Dado que hay una existe una relación lineal entre radiación que recibe un módulo y la potencia que produce, es posible identificar mediciones anómalas cuando se alejan del comportamiento esperado. Se descartan todas las mediciones que representen una producción anómala de energía o posibles sombreamientos transitorios. Solo los datos restantes serán válidos para contrastar el desempeño de los otros módulos. El método usado para descartar los datos anómalos consiste en aplicar una regresión lineal al conjunto, y eliminar los puntos más lejanos a la recta, en un margen de 25 % para considerar la variabilidad producto de la radiación reflejada y la temperatura de operación del módulo. Luego, con los puntos restantes, se aplica una nueva regresión lineal, y volviendo al conjunto inicial de datos, se eliminan los puntos que se alejan a la recta con el mismo criterio. El proceso se repite hasta que la pendiente de la regresión lineal ya no varíe, dando como resultado el gráfico 3.6(b).




Figura 3.6: Generación del módulo de referencia verus radiación el plano recibida para (a) datos brutos y (b) filtrados.

3.2.2. Filtrado y procesamiento de imágenes

Una imagen será considerada para análisis solo si cuenta con una medición válida de irradiación y potencia en el módulo de referencia. Si en la sección anterior se descartó alguna medición de potencia, cualquier imagen capturada en ese instante se descartará también.

Las imágenes son revisadas manualmente para eliminar cualquier oclusión de los módulos en caso de que el equipo de mantenimiento se encuentre realizando sus labores. Con el conjunto de imágenes definitivo, se ejecuta una corrección de perspectiva para cada escena, que aísla y resalta la región de interés del resto de la imagen (ilustración 3.7).

Durante la transformación, se busca que las imágenes queden con una resolución similar a la de los módulos originales para minimizar la pérdida de información. Cualquier redimensionamiento posterior sólo será para disminuir el tamaño de la imagen en caso de ser necesario.

3.2.3. Validación del ensuciamiento natural

Con los datos recogidos, es posible construir la métrica llamada Performance Ratio (PR), mediante la ecuación: 3.1:

$$PR = \frac{\frac{\text{Potencia Generada}}{\text{Radiación en el plano}}}{\frac{\text{Potencia Nominal}}{1000}} \quad (3.1)$$

Esta métrica relaciona la generación del módulo y la radiación recibida frente a las




Figura 3.7: Panel sucio original (a) y con corrección de perspectiva (b).

condiciones de placa. Un módulo sano debiera tener un PR cercano a 1, mientras que uno operando fuera de las condiciones normales verá disminuido su rendimiento. La ventaja de usar esta métrica es que engloba los parámetros de generación e radiación en una sola expresión. Para validar el fenómeno de acumulación de soiling, se compara la generación en el tiempo del panel de referencia con el expuesto a ensuciamiento. El comportamiento esperado reflejaría una disminución sostenida en el tiempo del panel sucio.

La figura 3.8 representa la evolución del PR para ambos paneles analizados. Se observa que el panel de referencia mantiene un PR constante a lo largo del experimento, mientras que el panel sucio experimenta un despegue sostenido en el tiempo, lo que se puede interpretar como la acumulación gradual de soiling sobre el módulo. De este gráfico se concluye el panel sucio efectivamente esta sometido a ensuciamiento.

3.2.4. Etiquetado

El etiquetado de las imágenes se hará con una métrica de rendimiento definida por la ecuación 3.2:

$$Loss = \frac{P_{ref} - P_{mod}}{P_{ref}} \quad (3.2)$$

Donde P_{ref} representa la generación del panel de referencia y P_{mod} la generación del panel sucio.

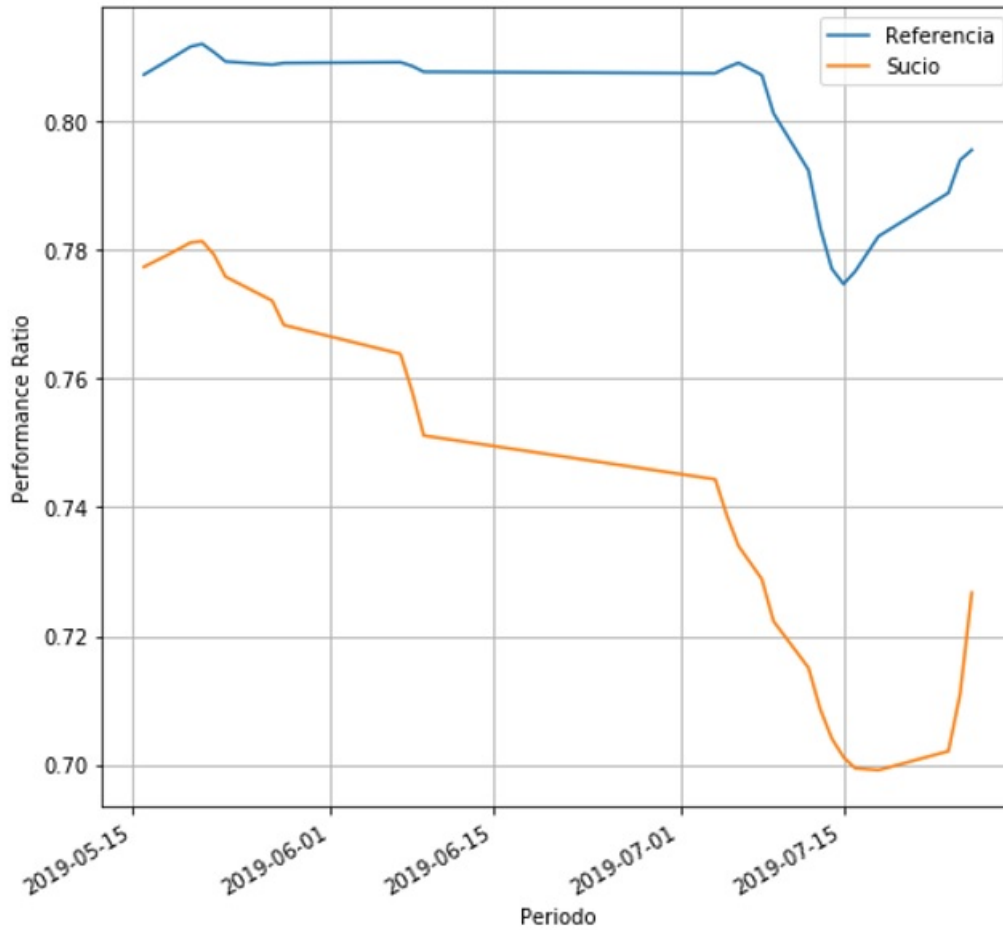


Figura 3.8: Performance Ratio en el tiempo.

Cada imagen del conjunto será etiquetada con la fecha y hora de la captura, el rendimiento instantáneo y la radiación en el plano. Si bien es posible extraer más información del laboratorio, los análisis posteriores se realizarán con los datos ya mencionados.

Cabe destacar que el panel sucio no fue sometido a los mismos criterios de limpieza de datos que el panel de referencia, por lo que será posible encontrar casos de sombreados parciales en el conjunto de imágenes. Este fenómeno también será estudiado en las futuras secciones.

3.2.5. Aplicación del conjunto Deep Solar Eye

El experimento Deep solar Eye [26] cuenta con una base de datos con más de 45000 imágenes de módulos experimentando ensuciamiento tanto natural como artificial, cada una etiquetada con la fecha y hora de la captura, la radiación en el plano en el y el rendimiento instantáneo del módulo respecto de un panel limpio y sano operando en las mismas condiciones. Las similitudes en el montaje experimental, como el uso de una cámara estacionaria, el etiquetado en función del rendimiento respecto del panel de referencia y el registro de la radiación en el plano permiten que el conjunto de imágenes de este experimento sea comparable con los datos obtenidos del laboratorio de fallas descrito a lo largo de todo este capítulo.

Capítulo 4

Análisis Estadístico

4.1. Metodología

Este capítulo propone un algoritmo de análisis de imágenes para estimar instantáneamente el impacto del ensuciamiento natural en paneles solares en operación. El funcionamiento del método (ilustración 4.1) se basa en 4 etapas principales que abarcan desde la captura de la imagen hasta la predicción del rendimiento del módulo. Una cámara digital capturará la imagen del módulo, la cual será previamente procesada para extraer la región de interés. Luego, se extraerán características de la imagen, las cuales serán evaluadas mediante una red neuronal artificial que relaciona los valores obtenidos con el desempeño del módulo. La métrica evaluada será la pérdida de potencia definida en la ecuación 3.2.

4.2. Pre-Análisis y Etiquetado

Al conjunto obtenido en la sección anterior se le aplicarán ciertos filtros para minimizar la variabilidad producto de factores externos al ensuciamiento.

Se elige un rango de horas estable (13:00 a 15:00, UTC -4), donde se da por seguro que no hay sombreamientos parciales producto de la cámara o de algún edificio cercano, el sol no alcanza a reflejarse sobre los módulos respecto del punto de vista de la cámara, el cambio de posición del sol en el cielo tiene un efecto mínimo sobre el panel, y coincidentemente, hay un buen nivel de radiación en el plano. Para minimizar la variabilidad en la iluminación de la escena, se eligen instancias donde la radiación se encuentre entre 700 y 1000 [W/m^2], lo que también filtrará días nublados. El conjunto

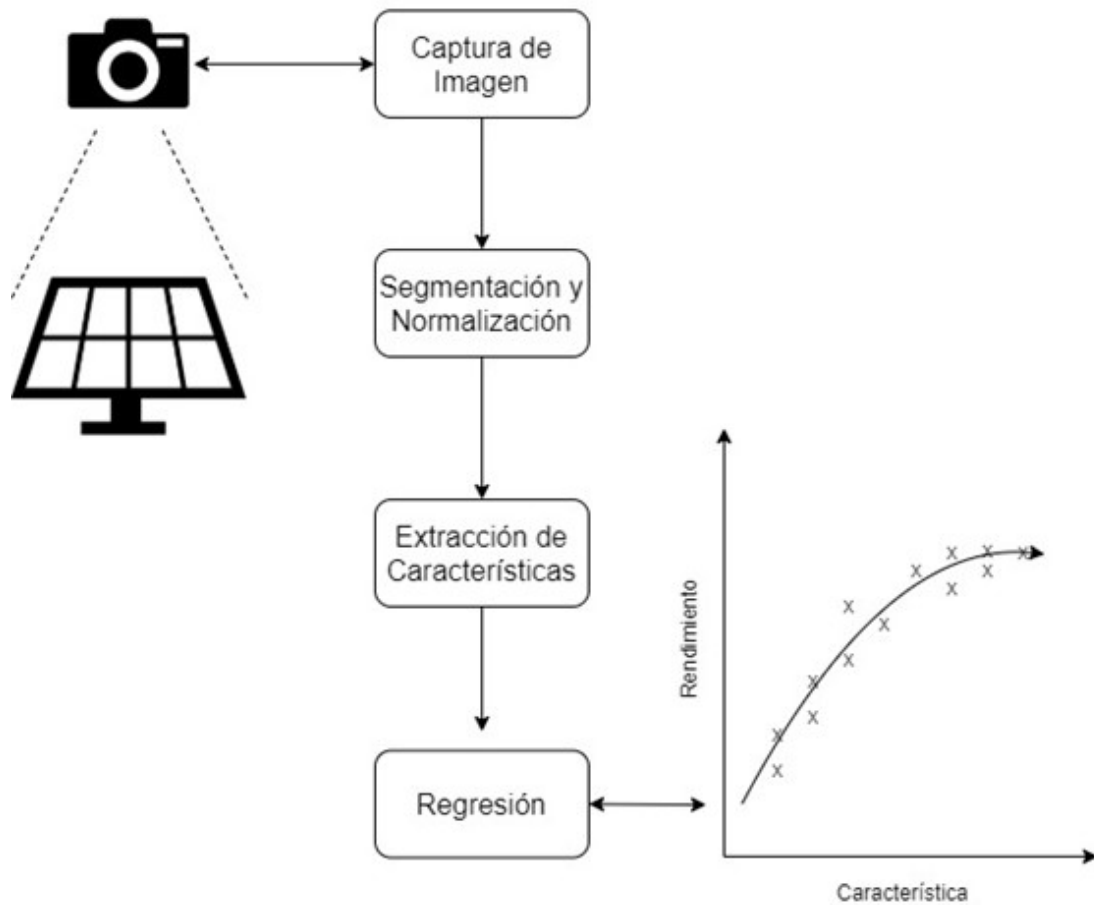


Figura 4.1: Etapas del algoritmo de análisis estadístico.

resultan cuenta con aproximadamente 400 imágenes del panel sucio en un periodo de 2 meses.

4.3. Extracción y Selección de Características

La base de datos resultante se procesa mediante la herramienta Balu [28], particularmente las rutinas de extracción y selección de características. Balu permite la automatización de extracción de características sobre un conjunto de imágenes. Para este caso, se obtuvieron características clásicas de color como promedios y sesgos, espectrales y de textura. Luego, con la herramienta de selección, se ejecutan análisis estadísticos para eliminar características redundantes o que no aportan al análisis. Los espacios de color analizados fueron RGB, HSV, escala de grises y Lab (ilustración 4.2).

La figura 4.3 muestra en orden de importancia descendente las características se-

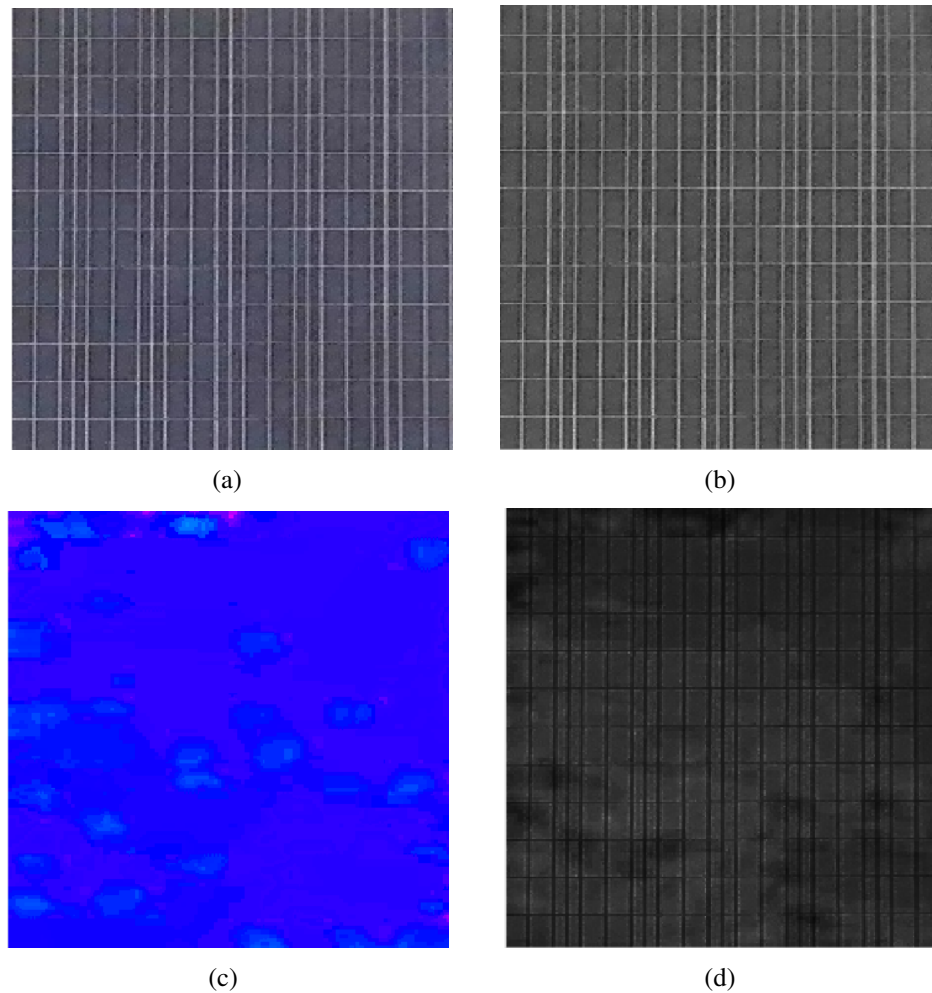


Figura 4.2: Panel en diferentes canales de color, (a) Original, (b) Escala de grises, (c) Matiz, (d) Saturación.

leccionadas por ambos criterios. Claramente se observa que, en ambos enfoques, la característica predominante es el sesgo de la intensidad en escala de grises. A simple vista, es posible estimar que hay una relación entre la información extraída y la etiqueta definida. Usando la información extraída es posible construir un clasificador que estime el impacto del ensuciamiento sobre un módulo. El clasificador construido consiste en una red neuronal artificial, ilustrada en 4.4. La capa de entrada tiene una dimensión de 18×1 , correspondiente al número de características entrantes, las capas ocultas son funciones de activación de carácter $\sum w_i x_i + b$, encargadas de procesar las características de manera no lineal. Finalmente, una capa de salida, de dimensión 1×1 entrega una predicción de carácter continuo del rendimiento del módulo según la etiqueta definida

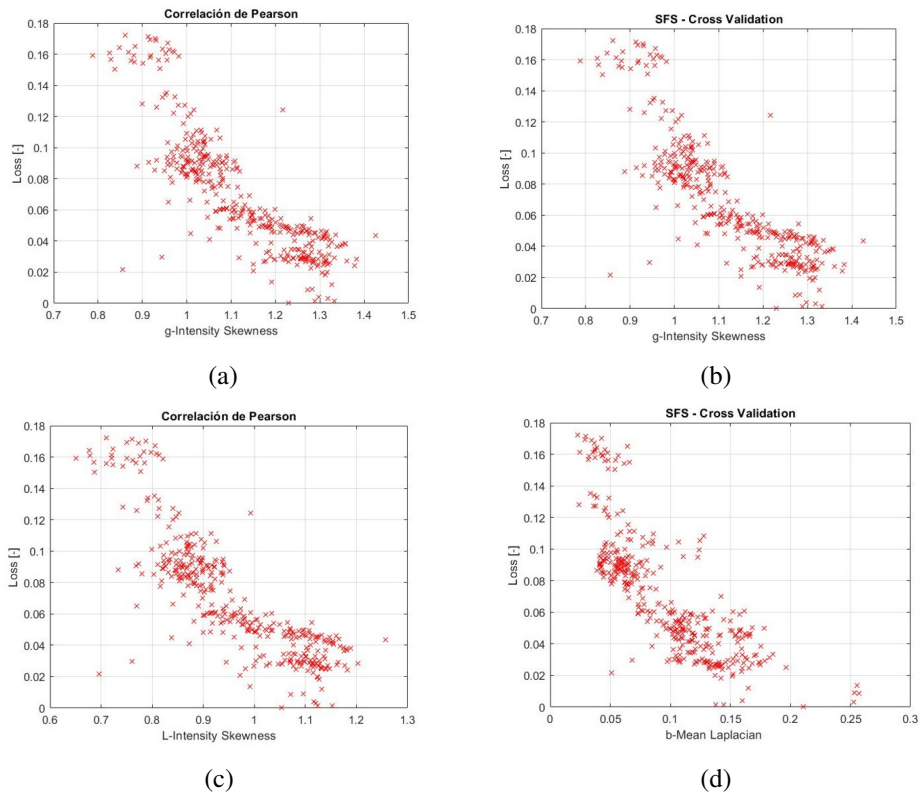


Figura 4.3: Extracción y selección de características de Balu sobre el conjunto de datos del laboratorio de fallas.

en la ecuación 3.2.




Figura 4.4: Red Neuronal Artificial usada para evaluar el ensuciamiento en paneles.

El entrenamiento de la red es de carácter supervisado, dividiendo el dataset aleatoriamente en 3 conjuntos, un 70 % usado para entrenar la red, un 15 % usado para validar la red al final de cada ciclo de entrenamiento, y el 15 % restante se usa para evaluar el desempeño de la red ya entrenada. Para definir el número de capas ocultas empleados, se realizan experimentos con diferentes profundidades, estudiando el error cuadrático medio y el factor R^2 para el conjunto de evaluación del desempeño.

Numero de Capas Ocultas	Error Cuadrático Medio $\cdot 10^{-4}$	R^2
1	3,89	0,88
5	2,55	0,91
10	1,32	0,93
15	0,72	0,94
20	0,48	0,96
30	0,62	0,95

Tabla 4.1: Desempeño de la red sobre el conjunto de evaluación para diferentes profundidades.

De acuerdo con los resultados presentados en la tabla 4.1, se observa que el mejor desempeño ocurre cuando la red neuronal artificial cuenta con 20 capas ocultas de profundidad, tanto para error cuadrático medio como coeficiente R^2 . El desempeño de la red sobre el conjunto de evaluación se observa en la ilustración 4.5. La línea roja representa el caso ideal, donde las predicciones calzan perfectamente con los valores reales. Se observa que las predicciones se acercan bastante al caso ideal, alcanzando un error cuadrático medio de $4,87 \cdot 10^{-5}$, por lo que se puede considerar que el clasificador se desempeña correctamente.




Figura 4.5: Comparación entre predicción y valor real para el conjunto de evaluación.

4.4. Aplicación en Deep Solar Eye

Aprovechando las similitudes entre el conjunto Deep Solar Eye [26], se aplica el mismo análisis a las imágenes, manteniendo los criterios de ventana temporal y de radiación en el plano. Se extraen características con Balu en los espacios de color antes mencionados, y se aplican los mismos clasificadores:




Figura 4.6: Selección de características de Balu, aplicado al conjunto Deep Solar Eye.

En la ilustración 4.6, las características que sobresalen con los métodos de selección son descriptores de textura y espectrales, y dado el comportamiento de los datos, ya no se observa una relación directa entre la etiqueta y la característica extraída. La ilustración 4.7 muestra la aplicación de la red neuronal desarrollada en el punto anterior sobre el conjunto Deep Solar Eye. Se observa que las predicciones no se acercan a los valores objetivo, llegando incluso a generar valores negativos. El siguiente enfoque consta en entrenar una nueva red neuronal usando los datos extraídos de Deep Solar Eye. Manteniendo los mismos criterios en cuanto a diseño de la red, selección de características y profundidad de la red. La ilustración 4.8 muestra el desempeño de la nueva red sobre el

conjunto de evaluación. Se observa que las predicciones no se acercan al caso ideal. Se concluye que este método de redes neuronales artificiales no es efectivo para evaluar ensuciamiento de carácter artificial.




Figura 4.7: Red neuronal aplicada al conjunto Deep Solar Eye.




Figura 4.8: Red neuronal entrenada en el conjunto Deep Solar Eye.

Capítulo 5

Análisis con Redes Neuronales

5.1. Metodología

La metodología propuesta se esquematiza en la ilustración 5.1, en la cual se expresa la función de cada paso dentro del algoritmo y como se relaciona con las demás etapas. La unidad de segmentación se encargará de procesar la imagen original, detectar cada módulo y generar una máscara. La unidad de normalización recibe las máscaras y las usa para extraer la región de interés de cada módulo y generar una imagen en un formato definido para cada instancia. La unidad de análisis recibe la imagen normalizada junto con la radiación incidente y predice la pérdida de potencia que está sufriendo el módulo en el instante de captura.

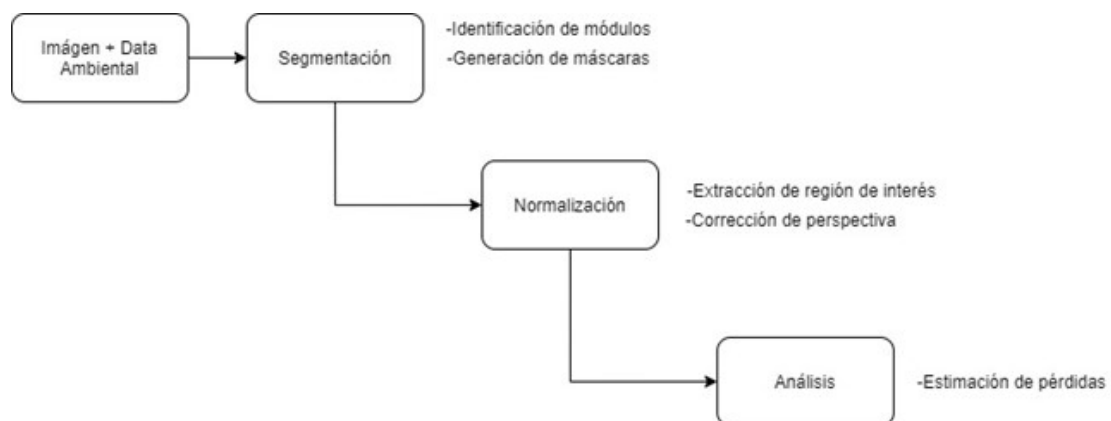


Figura 5.1: Esquema de operación del modelo propuesto

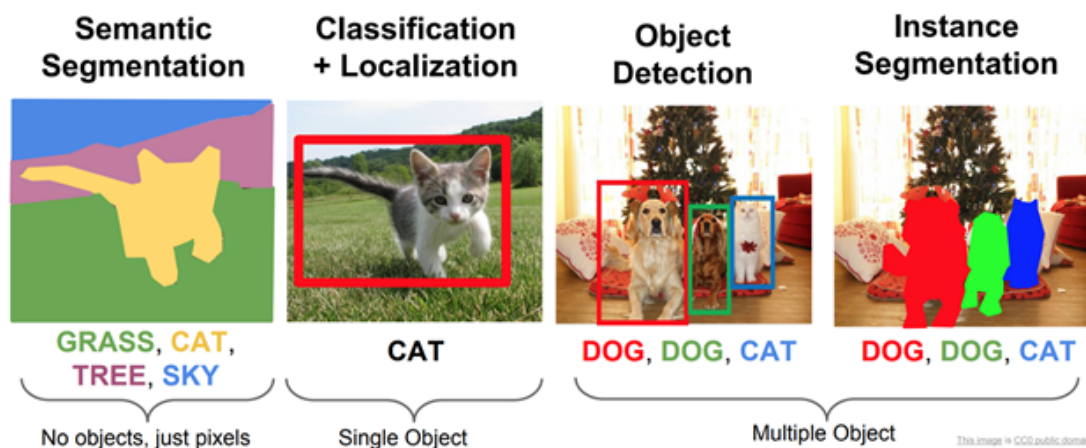


Figura 5.2: Detección, clasificación y segmentación

5.2. Segmentación

Las tareas de un algoritmo de visión computacional se pueden describir de acuerdo con ilustración 5.2 [29]. La clasificación consiste en identificar y categorizar una imagen según el objeto predominante. La detección de objetos abarca la identificación, clasificación y ubicación (usando una caja delimitadora) de cada elemento conocido dentro de la imagen. La segmentación semántica se basa en la categorización de los objetos conocidos dentro de la imagen para cada píxel. Finalmente, la segmentación instancial es capaz de identificar y separar diferentes objetos pertenecientes a una misma categoría.

En los últimos años, diversos grupos de investigadores se han dedicado a la tarea de desarrollar herramientas de visión computacional capaces de lograr las tareas descritas anteriormente. Google desarrolló DeepLab [30], especializada en segmentación semántica, que se caracteriza por el uso de convolución dilatada, un tipo de matriz de kernel que permite mirar una mayor cantidad de píxeles sin aumentar sustancialmente el costo computacional. El resultado es una categorización individual de cada píxel dentro de la imagen, asignando una etiqueta según la clase a la que pertenezca. Una de las desventajas principales de este algoritmo es que la clasificación de los píxeles es a nivel global. Cada píxel tiene una categoría determinada y en la representación final todos los píxeles que pertenezcan a esa categoría son tratados como miembros de un único conjunto, por lo que no es posible distinguir entre múltiples objetos pertenecientes a la misma clase. Plataformas como YOLO [31] se especializan en la detección y clasificación de objetos dentro de una imagen. La arquitectura se basa en una sola red neuronal convolucional que divide la imagen en una malla de dimensión $s \times s$ y

cada celda realiza una predicción de la localización de un objeto, junto con las coordenadas de un rectángulo delimitador y la probabilidad de que el objeto identificado se encuentre en la región. Las capas superiores de la red se encargan de agrupar y seleccionar las predicciones de mayor confiabilidad para finalmente entregar la región de interés que contiene el objeto junto con la probabilidad de acierto. Cabe destacar que este algoritmo no es capaz de segmentar el objeto identificado del fondo de la imagen. YOLO se caracteriza principalmente por su velocidad de procesamiento. Las limitaciones espaciales de este algoritmo se manifiestan a la hora de detectar múltiples objetos dentro de una misma celda. Uno de los avances más recientes es el desarrollo de Mask RCNN [32], desarrollada por Facebook AI Research. Este algoritmo combina la segmentación instancial con la detección de objetos. Basándose en la arquitectura Fast RCNN [33], especializada en detección y clasificación de objetos, Mask RCNN añade una rama de segmentación instancial, entregando finalmente una región delimitada, una etiqueta de clase y una máscara propuesta para cada objeto identificado. La mayor desventaja de este algoritmo es el alto costo computacional, limitando su desempeño en situaciones de tiempo real. Los algoritmos de visión computacional basados en Deep Learning han demostrado ser alternativas competitivas en tareas de análisis de imágenes, desde reconocimiento facial [34], identificación de polígonos de hielo en el ártico [35], detección de lesiones en tomografía dental [36] hasta vehículos con piloto automático [37].

En esta investigación, los objetos de estudio son módulos fotovoltaicos que requieren detección y luego segmentación. El algoritmo a utilizar debe ser capaz de identificar y extraer la región de interés dentro de una imagen con precisión, identificando cada módulo y así facilitar su diagnóstico. Mask RCNN es una alternativa prometedora para la aplicación propuesta, ya que el uso de segmentación instancial permite distinguir y procesar cada módulo individualmente dentro de una instalación fotovoltaica.

El primer paso del sistema se basa en la plataforma de segmentación instancial Mask RCNN [38] (ilustración 5.3). Este algoritmo es una red convolucional preentrenada capaz de distinguir y segmentar diferentes clases de objetos dentro de una misma imagen. Para cada instancia de objeto detectada dentro de una escena, el algoritmo entrega una máscara de segmentación, una etiqueta de clasificación con su respectivo intervalo de confianza y una caja delimitadora. El modelo utilizado se entrenó con el dataset COCO [39] y es capaz de detectar personas, animales, autos y una variedad de alimentos y objetos domésticos.

Para adaptar esta herramienta a la aplicación propuesta, y así detectar módulos fo-




Figura 5.3: Ejemplo de Mask RCNN.

tovoltaicos, es necesario reentrenar el modelo con un conjunto de datos con paneles segmentados y clasificados manualmente. Mediante la técnica de webscouting, se descargan diversas imágenes con la etiqueta de “paneles solares” (ilustración 5.4), se filtran fotos obstruidas o que no tengan relación con la etiqueta definida, y finalmente, con la ayuda de la herramienta VGG Anotator [40], se segmenta y clasifica manualmente cada imagen utilizada y se crea el dataset en el formato requerido para usarse dentro de Mask RCNN.



(a)



(b)

Figura 5.4: Muestras del conjunto de entrenamiento.

Luego, se modifican las rutinas de entrenamiento del modelo para admitir la nueva clase de objeto, se divide la base de datos en un conjunto de entrenamiento y validación y se procede al entrenamiento del modelo.

Una vez finalizado el entrenamiento (Tabla 5.1), se guardan los parámetros y pesos

Parámetros de Entrenamiento Mask RCNN	
Imágenes conjunto de entrenamiento	208 (1248 con de aumentado de datos)
Imágenes conjunto de validación	52 (312 con de aumentado de datos)
Ciclos	50
Tiempo total	52 Horas
Pérdida	0,237

Tabla 5.1: Datos de entrenamiento del modelo

en que se basará la red neuronal para su uso final o refinaciones posteriores. Se editan las rutinas de detección y clasificación del modelo para que ignore todas las clases preentrenadas y se limite a la instancia definida por los módulos fotovoltaicos.

Para validar el modelo y los parámetros de la red neuronal, se debe estudiar su comportamiento en imágenes que no formen parte del conjunto de datos usado en el entrenamiento. Dado que no se usaron imágenes del laboratorio de fallas en el dataset, se cuenta con la plataforma ideal para evaluar el modelo. Como se observa en la ilustración 5.5, el modelo es capaz de detectar con certeza cada módulo individualmente, independiente de la iluminación y ángulo de captura. En algunos casos, la cámara captura módulos incompletos y aun así el modelo es capaz de segmentar correctamente las regiones correspondientes. Cabe destacar que los colores usados por Mask RCNN en esta etapa no representan características del panel y su única función es distinguir entre instancias detectadas.




Figura 5.5: Validación del modelo entrenado.

De los resultados que entrega Mask RCNN mencionados anteriormente, en los siguientes pasos solo se usarán las máscaras. Este objeto es una matriz de dimensiones

(A, L, NI) , donde A y L representan el largo y el ancho en píxeles de la imagen analizada respectivamente y NI representa el número de instancias detectadas, vale decir, cuántos módulos pudo detectar el algoritmo dentro de la imagen. El contenido de la matriz es un conjunto de carácter binario, donde a cada píxel se le asigna un valor de 1 si cae dentro de la categoría evaluada (módulo), y 0 en cualquier otro caso. Dado que la clasificación se realiza píxel por píxel, las máscaras entregadas no necesariamente abarcarán completamente el módulo, y tampoco tendrán asegurada la forma de cuadrilátero característica del panel. La aplicación de las máscaras se puede observar en la ilustración 5.6. Cabe destacar que es posible combinar ambas máscaras dentro de una sola matriz, pero en el trabajo aquí desarrollado, cada máscara se procesará individualmente.




Figura 5.6: Máscaras generadas a partir de la ilustración 5.5(b).

5.3. Normalización

En esta etapa se procesan las instancias detectadas en la etapa anterior para obtener la región de interés en un formato homogéneo. Habiendo ya procesado una foto en el modelo Mask RCNN, se obtiene la matriz de máscaras para cada instancia detectada (ilustración 5.7). El objetivo de esta etapa es aproximar la nube de puntos representada en los objetos matriciales a un cuadrilátero, y mediante una transformación de perspectiva, usar las esquinas de dicho cuadrilátero para extraer el área de interés en un formato homogéneo. Las máscaras, como se observa en la ilustración 5.7(b), son áreas

continuas, los píxeles clasificados en la instancia de módulo se encuentran en una sola región dentro de la matriz, y al interior de dicha región no hay elementos que no pertenezcan a la instancia.




Figura 5.7: Imagen de prueba (a) con su respectiva máscara binaria (b).

El proceso diseñado para encontrar los bordes de la máscara se esquematiza en la ilustración 5.8. El algoritmo identifica una esquina de la imagen y recorre cada borde perpendicularmente buscando el primer valor distinto de 0. Se comienza en la esquina inferior izquierda y primero se recorre el borde inferior, evaluando cada elemento de cada columna hasta encontrar la frontera de la región. Cuando se encuentra el valor, se guarda la posición y se pasa a la siguiente columna. Luego, se recorre el borde izquierdo desde la misma esquina, evaluando cada elemento de cada fila, y de la misma forma, cuando se encuentra la frontera de la región, se guarda la posición y se salta a la próxima fila. Para recorrer los bordes restantes, la referencia cambia a la esquina superior derecha y se navegan las filas y columnas de la misma forma. Con este método, se obtienen cuatro vectores de la forma $(x, f(x))$ que encapsulan exclusivamente la




Figura 5.8: Representación del algoritmo de hormiga.

región donde se encuentra el módulo.

Al describir los bordes de la máscara como curvas en un espacio de dos dimensiones, es posible aplicar métodos numéricos para procesar los datos. Primero, para suavizar el ruido de cada borde tentativo, se aplica un filtro de caja gaussiano que elimina altas frecuencias y aproxima las curvas a funciones de carácter más suaves. Luego, continuando con el procesamiento de las curvas, se busca eliminar cualquier esquina y posible curvatura que se haya identificado inicialmente. Para ello, se calcula la derivada de segundo orden usando un esquema centrado de diferencias finitas sobre cada par de datos. Ya que se desea aproximar los bordes capturados a curvas con pendiente constante, todos los puntos donde dicha derivada tenga un valor distinto de 0 son filtrados.

Cuando los cuatro bordes tentativos están libres de ruido y de posibles esquinas, se aplican regresiones lineales en cada una de las curvas. Estas rectas representan la mejor aproximación a un cuadrilátero de las máscaras. Finalmente, se calculan las intersecciones de estas rectas y se obtienen los puntos que mejor describen las esquinas del módulo en cuestión. La ilustración 5.9 muestra los bordes obtenidos de la máscara de la imagen 5.7(b), las rectas que mejor describen el cuadrilátero y las intersecciones de dichas rectas. Una vez que las esquinas del módulo han sido aproximadas, se ejecuta una transformación afín que extrae la región de interés de cada panel detectado en la etapa de segmentación, y se llevará al formato necesario para la etapa de análisis (ilustración 5.10).




Figura 5.9: Bordes capturados por el algoritmo de hormiga aproximado a un cuadrilátero.



Figura 5.10: Módulo 5.7(a) normalizado.

5.4. Análisis

La etapa más compleja del algoritmo incluye la creación y etiquetado de un conjunto de entrenamiento, el diseño de la red neuronal de procesamiento, el entrenamiento de dicha red y la validación sobre imágenes de prueba. La red neuronal recibe como datos de entrada la imagen de un módulo y la radiación en el plano en el instante que se

Categoría	Cuartiles	Quintiles	Octiles	Deciles
1	0-25	0-20	0-12.5	0-10
2	25-50	20-40	12.5-25	10-20
3	50-75	40-60	25-37.5	20-30
4	75-100	60-80	37.5-50	30-40
5	-	80-100	50-62.5	40-50
6	-	-	62.5-75	50-60
7	-	-	75-87.5	60-70
8	-	-	87.5-100	70-80
9	-	-	-	80-90
10	-	-	-	90-100

Tabla 5.2: Etiquetas de clasificación.

capturó la imagen, y como salida, se entrega un valor categórico que clasifica la condición del módulo de acuerdo con el nivel de pérdida de producción de energía respecto del módulo sano.

5.4.1. Procesamiento Previo

Las imágenes usadas para este experimento, al igual que en la sección de Análisis Estadístico, provendrán tanto del laboratorio de fallas discutido en la sección de Montaje Experimental como el conjunto obtenido del experimento Deep Solar Eye.

El etiquetado en este caso es de carácter categórico, el rango de pérdidas de 0 a 1 se divide en percentiles de igual longitud y, según la tabla 5.2, la categoría corresponde a la posición ordinal del percentil en que se encuentra la pérdida relativa del módulo analizado. Para este trabajo se dividió el rango de pérdidas en cuartiles, quintiles, octiles y deciles.

De acuerdo con la experiencia del laboratorio, se observa que el impacto del soiling y el sombreamiento son simétricos respecto de los ejes horizontales y verticales del módulo, por lo que es posible aplicar técnicas de aumentado de datos tales como rotaciones en 180° y reflexiones sobre los ejes ya mencionados, manteniendo las etiquetas de radiación y percentiles originales. Dependiendo del número imágenes con las que cuenta cada categoría, se ejecutan las operaciones de aumentado de datos. De esta forma, las imágenes de los percentiles menos representados experimentan una mayor cantidad de transformaciones, y de ser necesario, se descartan imágenes de las categorías más populosas para equilibrar la cantidad de muestras. El resultado final (ilustración

5.11) es un conjunto de datos con muestras de ensuciamiento artificial, ensuciamiento natural y sombreado parcial, con una distribución uniforme de imágenes para cada percentil.

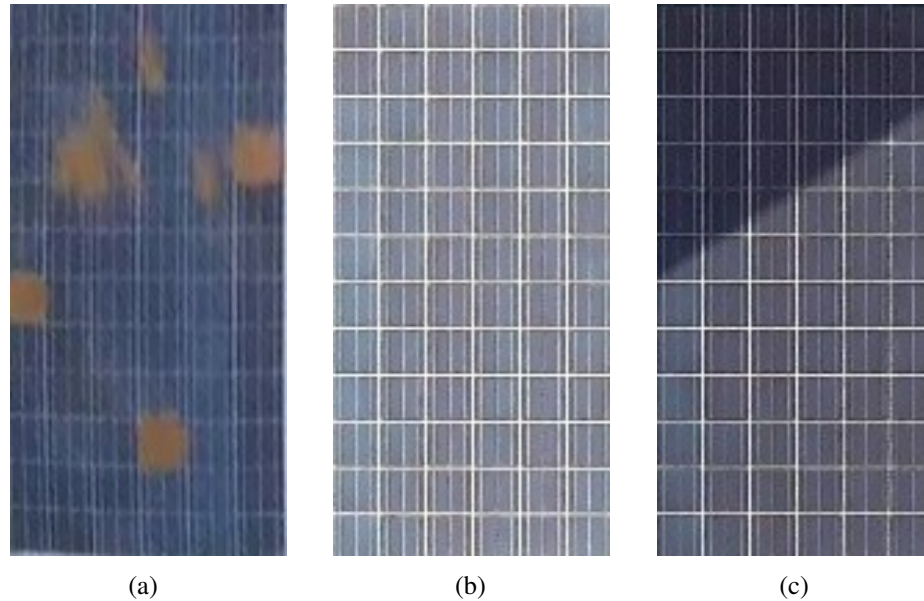


Figura 5.11: Muestras del conjunto de entrenamiento.

Al momento de cargar el conjunto de datos, se recomienda escalar los valores de la imagen y de la irradiancia dentro del mismo rango para asegurar que alguna discrepancia en la magnitud de los valores no afecte el desempeño de la red neuronal.

5.4.2. Creación de la ANN

La red neuronal consta de dos ramas principales de procesamiento. La primera es un perceptrón multicapa que recibe la característica continua de la radiación en el plano. Esta rama cuenta con dos capas con función de activación “ReLU” y la salida será concatenada con la otra rama. La segunda rama se encarga del procesamiento de la imagen y se basa en una arquitectura CNN. Para este caso, se probó con diferentes modelos de redes convolucionales, ya sea basándose en trabajos preexistentes o diseñando desde el comienzo una red original.

La red diseñada para este experimento (ilustración 5.12) se subdivide en tres unidades de análisis que recaban información a distintos niveles de detalle incluyendo:

- Una matriz de kernel convolucional de dimensión 3x3 que recorre toda la imagen

buscando características útiles.

- Una capa de activación de función “Relu” [41] que relaciona la información obtenida de manera no lineal.
- Una capa de “Batch Normalization” [41] que normaliza los valores entregados por la capa de activación para evitar sesgos.
- Una capa de Pooling para reducir la información espacial y disminuir la carga computacional.
- Finalmente, una capa de descarte que desconecta aleatoriamente nodos en las capas para evitar el fenómeno del overfitting.

Cada unidad de análisis se conecta con la anterior, disminuyendo el tamaño espacial y aumentando el nivel de detalle a medida que se profundiza sobre las capas de la red neuronal. Al final, se agrega una última unidad de análisis compuesta por una capa completamente conectada que se une a cada capa de la red descrita previamente, una nueva capa de “Batch Normalization”, una unidad de descarte y una última capa de activación “Relu”.

Para el caso de las redes prediseñadas, se experimenta con los modelos RESNETV50 [42] e INCEPTIONV3 [43], cuyas arquitecturas se encuentran descritas en sus respectivas publicaciones. Sea cual sea la arquitectura usada, la última capa se concatena con la información extraída de la radiación, y el diagnóstico final se ejecuta mediante una capa de activación “softmax” con un número de categorías igual a la cantidad de percentiles del conjunto de entrenamiento, más una categoría extra donde se clasificará la imagen en caso de que el modelo no pueda realizar un diagnóstico.

Al momento de entrenar la red, cada imagen etiquetada es asignada aleatoriamente al conjunto de entrenamiento, con el que se ajustan los parámetros de la red, o de validación, que se usa para comprobar la precisión de la red. La salida de la red neuronal es un vector de dimensión igual al número de categorías, donde cada valor contenido representa la probabilidad de pertenecer al percentil en cuestión. Es muy importante tener en cuenta la forma de la distribución de probabilidades. En caso de no haber una categoría que no predomine evidentemente sobre las demás, se complica bastante elegir una categoría definitiva. Para traducir esa distribución de probabilidades en una predicción se aplican 3 enfoques, una selección basada en la probabilidad máxima, selección calculando el valor esperado (centro de masa de la distribución de probabilidades), y,

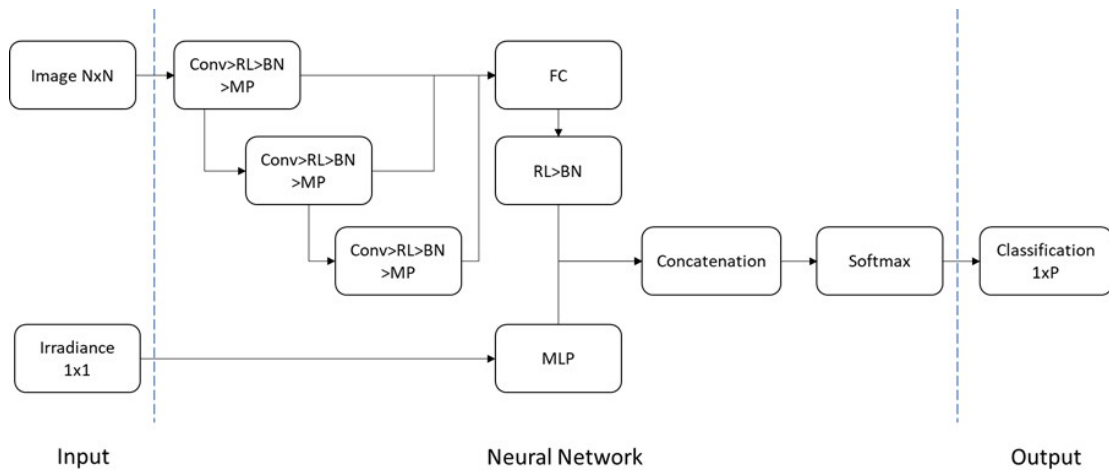


Figura 5.12: Esquema CNN original.

por último, selección basada en la mediana de la distribución. En el caso de que haya una probabilidad que sea notoriamente mayor que las demás, el valor máximo, la mediana y el valor esperado se encontrarán en la misma categoría, por lo que no habrá discrepancia entre los tres modelos de predicción. En caso contrario, donde no haya una mayoría absoluta, los criterios de selección entregarán predicciones distintas. Con esta configuración, se dan dos posibilidades, enfocarse principalmente en los aciertos y usar el criterio que tenga una mayor precisión, o enfocarse en el error, y minimizar la distancia entre la categoría predicha y la real.

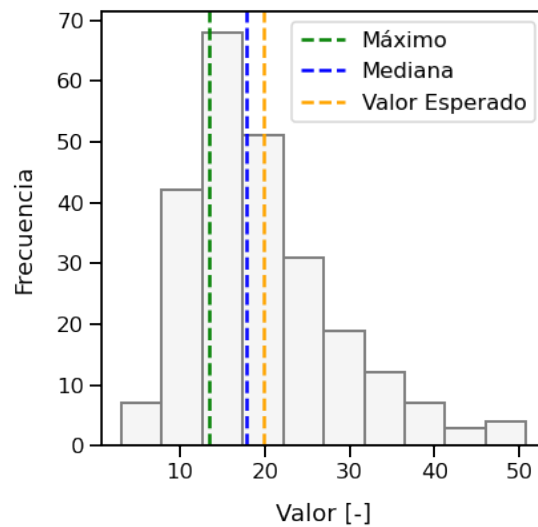


Figura 5.13: Enfoques de selección para una distribución de ejemplo.

5.5. Resultados

Las redes neuronales fueron entrenadas usando un conjunto de aproximadamente 24000 imágenes RGB de 224x224 píxeles, dejando un 80 % de las imágenes para entrenamiento y un 20 % para validación. Para mantener la proporción de imágenes en los conjuntos de entrenamiento y validación, la división aleatoria se realizó individualmente para cada categoría del dataset. De esta forma, cada categoría se encuentra igualmente representada tanto en el conjunto de entrenamiento como en el de validación. En la tabla 5.3 se observa la precisión sobre el conjunto de validación de cada una de las redes construidas al cabo de 50 ciclos por el conjunto de imágenes. La última columna muestra el número de parámetros entrenables (en millones) de cada modelo, lo que se puede traducir en que tan compleja es la red utilizada. Un mayor número de parámetros representa más costo computacional y un mayor tiempo de cálculo. Se observa que el desempeño de la red original es bastante similar al de RESNET 50 e INCEPTION V3, con un número significativamente menor de parámetros entrenables, por lo que se puede concluir que la red diseñada es efectiva para la tarea en cuestión.

	Cuartiles	Quintiles	Octiles	Deciles	Parámetros
Red Original	86, 8	83, 4	73, 2	70, 1	3, 32 <i>MM</i>
RESNET 50	87, 1	—	72, 1	69, 9	23, 57 <i>MM</i>
INCEPTION V3	—	—	—	70, 3	21, 83 <i>MM</i>

Tabla 5.3: Desempeño de las redes neuronales sobre el conjunto del validación.

Para visualizar la confiabilidad de la red original en 8 percentiles, en la ilustración 5.14 se observa la distribución del mayor valor de probabilidad de cada predicción. Evidentemente, la gran mayoría de las predicciones se hace con una probabilidad cercana al 100 %. En estos casos donde hay una clara mayoría absoluta, la selección de la categoría no representa una mayor dificultad. Para el resto de los casos, a medida que la probabilidad máxima disminuye los errores de clasificación aumentan. En la ilustración 18 se observa como el desempeño de cada método de selección frente al conjunto de validación. Se concluye que no hay mayores diferencias de comportamientos en cuanto a la subestimación o sobreestimación del impacto del soiling o sombreamiento en el módulo.

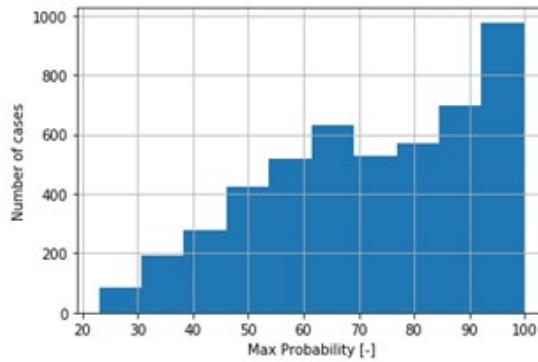


Figura 5.14: Probabilidad máxima de cada decisión sobre el conjunto de validación.

Para analizar el error del sistema, se mide la diferencia entre la categoría predicha por el modelo y la categoría real. Diferencias pequeñas indican que, si bien el modelo se equivoca, lo hace por pequeños márgenes, por lo que como herramienta cualitativa sigue siendo confiable. De los tres enfoques de selección descritos anteriormente, en la ilustración 5.15 se observa que, si bien la selección por valor esperado minimiza los errores de clasificación por una amplia diferencia de categorías, estos representan una pequeña parte porcentual de la clasificación, por lo que se concluye que sacrificar algunos puntos porcentuales de precisión no se ve compensado por la ganancia. Para el caso de selección basado la mediana, se logra el compromiso óptimo entre precisión y errores de amplia diferencia de categorías.

En la ilustración 5.16 se compara el desempeño de cada método de selección frente a la distribución de categorías del conjunto de validación. Se observa que en ningún caso hay una tendencia de subestimación o sobreestimación del soiling o sombreamiento en los paneles.

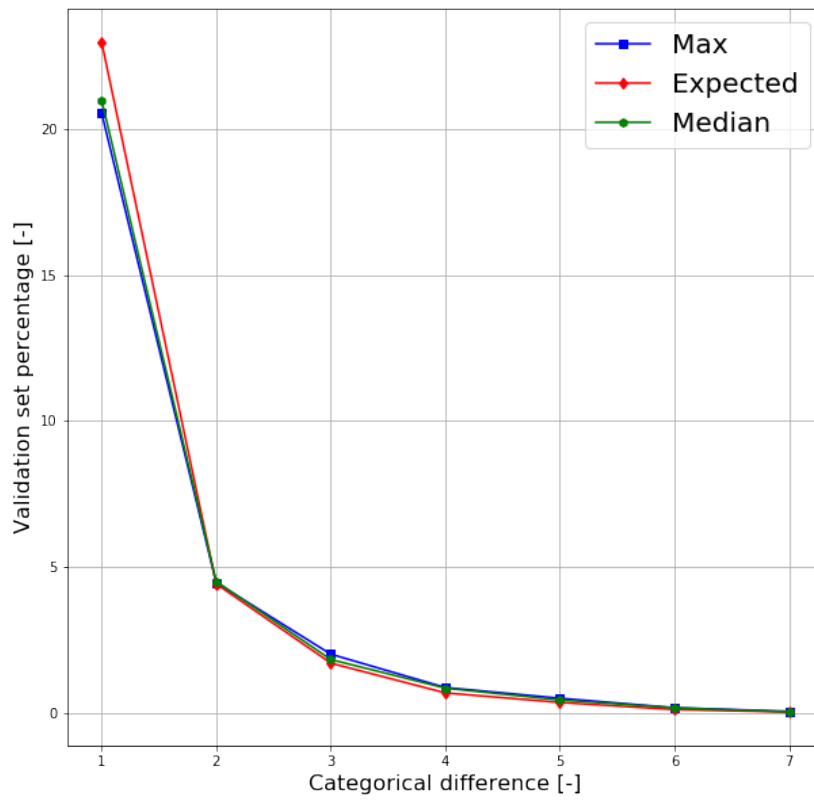


Figura 5.15: Distribución del error de selección para octiles

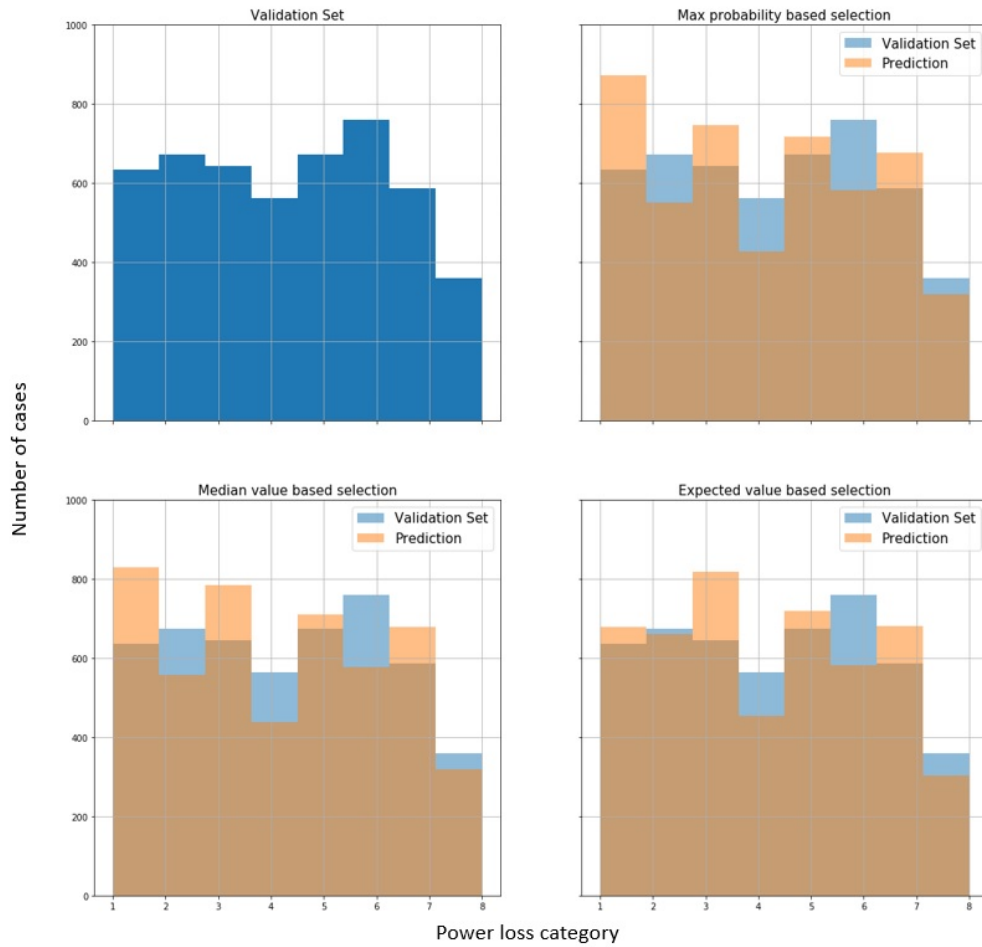


Figura 5.16: Predicciones sobre el conjunto de validación para cada método de selección.

5.6. Integración del Algoritmo

Con cada etapa resuelta individualmente, se procede a conectar las entradas y las salidas para concretar la herramienta de diagnóstico. El núcleo de la etapa de segmentación son los pesos obtenidos al entrenar el modelo Mask RCNN.. En caso de querer perfeccionar la detección de módulos, es posible entregar imágenes capturadas en distintas condiciones y con una cantidad de módulos variable. De la etapa de segmentación se reciben las máscaras de cada instancia detectada. Para cada instancia, se aplicará el algoritmo de normalización.

Con la faz del módulo separada de la imagen, se procesará la región extraída dentro de la red neuronal, se categorizará la imagen y se entregará un diagnóstico. Para expresar la clasificación dentro de la misma imagen, se aprovecharán las máscaras de segmentación obtenidas en la primera etapa. Se crea una función de mapa de colores que traduce la categoría entregada por la red neuronal en valores RGB que se asignan a la máscara del panel analizado, y, mediante operaciones matriciales, se colorea el módulo según la etiqueta recibida. También se entrega un eje que representa la pérdida del panel en función del color asignado.

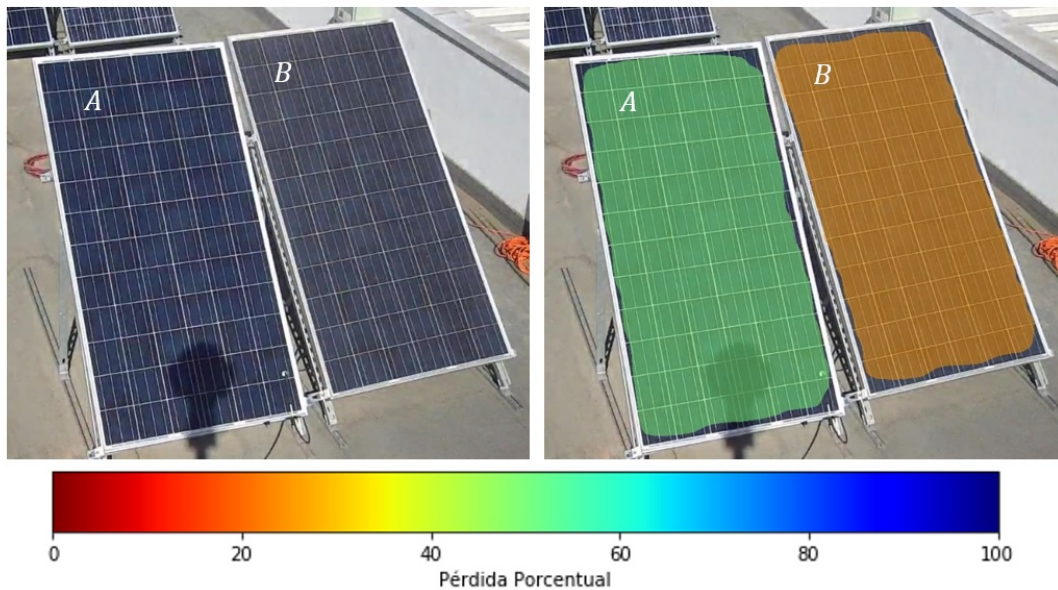


Figura 5.17: Validación del modelo integrado.

En la ilustración 5.17 se observa el algoritmo completo en acción, se entrega una imagen ajena a los conjuntos de entrenamiento y validación. La escena presenta un

Módulo	Pérdida Real	Pérdida Calculada
<i>A</i>	0,43 [-]	0,375 – 0,50 [-]
<i>B</i>	0,14 [-]	0,125 – 0,25 [-]

Tabla 5.4: Valores calculados y reales de la ilustración 5.17.

módulo experimentando soiling y otro con una sombra proyectada en su superficie. El algoritmo identifica correctamente ambas regiones de interés, las analiza y emite el diagnóstico basado en la pérdida de potencia relativa (tabla 5.4). En este caso, predice correctamente que el módulo sombreado sufre una mayor pérdida que el módulo sucio. Las predicciones son representadas sobre las máscaras obtenidas de la etapa de segmentación, asignándoles un color para facilitar la interpretación de los resultados en caso de que haya una gran cantidad de módulos. Finalmente, se entrega una leyenda que traduce el color sobre el módulo en el valor porcentual de pérdida de producción de energía.

Capítulo 6

Conclusiones y recomendaciones

En este trabajo se demostró que es posible evaluar el rendimiento de un módulo expuesto a sombreado o ensuciamiento basándose en una imagen capturada por una cámara digital.

La configuración implementada en el laboratorio permite obtener una gran cantidad de datos de módulos en operación, y es posible incluir nuevos modos de falla para evaluar en el espectro visible e incluso en el infrarrojo.

En cuanto al análisis estadístico de imágenes, se observa que es posible relacionar características extraídas de una imagen directamente con el rendimiento del módulo expuesto a ensuciamiento, logrando un error cuadrático medio de $4,87 \cdot 10^{-5}$ en un clasificador a base de redes neuronales artificiales, siempre y cuando sea de acumulación natural. Al aplicar las mismas metodologías sobre módulos sucios artificialmente, las características que describían el ensuciamiento dejan de ser efectivas.

Finalmente, el uso de redes neuronales resultó una alternativa eficaz a la hora de implementar técnicas de análisis de imágenes. El método propuesto recibe como entrada una imagen en el espectro visible de uno o múltiples módulos fotovoltaicos junto con la radiación en plano en el instante de captura, y es capaz de detectar, segmentar y evaluar sombreados o soiling para cada módulo presente en la imagen, con una precisión sobre un 73% para predicciones en ocho percentiles, concentrando la mayor parte de los errores en percentiles aledaños. La naturaleza del algoritmo permite mejorar individualmente cada etapa sin alterar drásticamente el funcionamiento del algoritmo, siempre y cuando se mantengan las entradas y salidas de cada etapa.

En un futuro se mejorará la segmentación expandiendo el entrenamiento a imágenes capturadas en unidades de vuelo no tripuladas, la etapa de normalización será capaz de detectar y descartar módulos incompletos de la imagen, y finalmente, la etapa de análisis se expandirá con nuevos modos de falla y una mayor variedad de imágenes.

Bibliografía

- [1] M. Gaetan, O. Sinead, and R. Manoel, “Global market outlook,” EPIA - European Photovoltaic Industry Association., p. 60, 2018. [Online]. Available: www.africa-eu-renewables.org
- [2] “Capacidad instalada – Energía Abierta — Comisión Nacional de Energía.” [Online]. Available: <http://energiaabierta.cl/visualizaciones/capacidad-instalada/>
- [3] Ministerio de Energía, “Energía 2050,” pp. 1–154, 2014. [Online]. Available: http://eae.mma.gob.cl/uploads/D03_Politica_Energetica_de_Chile_2050_Anteproyecto2.pdf
- [4] Andru Rothenberg, “How long do solar panel last,” 2018.
- [5] M. Köntges, S. Kurtz, C. Packard, U. Jahn, K. Berger, K. Kato, T. Friesen, H. Liu, and M. Van Iseghem, “Review of Failures of Photovoltaic Modules,” Tech. Rep., 2014.
- [6] J. Huang, R. Wai, and W. Gao, “Newly-Designed Fault Diagnostic Method for Solar Photovoltaic Generation System Based on IV-Curve Measurement,” *IEEE Access*, vol. 7, pp. 70 919–70 932, 2019.
- [7] P. Jain, J. Poon, J. P. Singh, C. Spanos, S. R. Sanders, and S. K. Panda, “A digital twin approach for fault diagnosis in distributed photovoltaic systems,” *IEEE Transactions on Power Electronics*, vol. 35, no. 1, pp. 940–956, jan 2020.
- [8] Y. F. Li, P. J. Lin, H. F. Zhou, Z. C. Chen, L. J. Wu, S. Y. Cheng, and F. P. Su, “On-line monitoring system of PV array based on internet of things technology,” *IOP Conference Series: Earth and Environmental Science*, vol. 93, no. 1, p. 12078, nov 2017.

[Online]. Available: <https://iopscience.iop.org/article/10.1088/1755-1315/93/1/012078><https://iopscience.iop.org/article/10.1088/1755-1315/93/1/012078/meta>

- [9] J. M. Kala P., Joshi P., Agrawal S., Yadav L.K., “Introduction to Condition Monitoring of PV System.” in *Soft Computing in Condition Monitoring and Diagnostics of Electrical and Mechanical Systems*, Springer, Ed., Singapore, 2020. [Online]. Available: <https://doi.org/10.1007/978-981-15-1532-3{-}7>
- [10] A. Y. Al-hasan and A. A. Ghoneim, “A new correlation between photovoltaic panel’s efficiency and amount of sand dust accumulated on their surface,” *International Journal of Sustainable Energy*, vol. 24, no. 4, pp. 187–197, 2005.
- [11] J. J. John, S. Warade, G. Tamizhmani, and A. Kottantharayil, “Study of soiling loss on photovoltaic modules with artificially deposited dust of different gravimetric densities and compositions collected from different locations in India,” *IEEE Journal of Photovoltaics*, vol. 6, no. 1, pp. 236–243, 2016.
- [12] P. D. Burton, A. Hendrickson, S. S. Ulibarri, D. Riley, W. E. Boyson, and B. H. King, “Pattern Effects of Soil on Photovoltaic Surfaces,” *IEEE Journal of Photovoltaics*, vol. 6, no. 4, pp. 976–980, 2016.
- [13] W. Javed, B. Guo, Y. Wubulikasimu, and B. W. Figgis, “Photovoltaic Performance Degradation Due to Soiling and Characterization of the Accumulated Dust,” 2016 IEEE International Conference on Power and Renewable Energy Photovoltaic, pp. 580–584, 2016.
- [14] M. Gostein, J. R. Caron, and B. Littmann, “Measuring soiling losses at utility-scale PV power plants,” 2014 IEEE 40th Photovoltaic Specialist Conference, PVSC 2014, pp. 885–890, 2014.
- [15] M. Gostein, T. Duster, and C. Thuman, “Accurately measuring PV soiling losses with soiling station employing module power measurements,” 2015 IEEE 42nd Photovoltaic Specialist Conference, PVSC 2015, 2015.
- [16] “Using Topological Data Analysis to Understand the Behavior of Convolutional Neural Networks.” [Online]. Available: <https://www.kdnuggets.com/2018/06/topological-data-analysis-convolutional-neural-networks.html>

- [17] “Using Topological Data Analysis to Understand the Behavior of Convolutional Neural Networks.” [Online]. Available: <https://www.kdnuggets.com/2018/06/topological-data-analysis-convolutional-neural-networks.html>
- [18] M. Alsafasfeh, I. Abdel-Qader, B. Bazuin, Q. Alsafasfeh, and W. Su, “Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision,” *Energies*, vol. 11, no. 9, pp. 1–18, 2018.
- [19] J. A. Tsanakas, L. Ha, and C. Buerhop, “Faults and infrared thermographic diagnosis in operating c-Si photovoltaic modules: A review of research and future challenges,” *Renewable and Sustainable Energy Reviews*, vol. 62, pp. 695–709, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1364032116301629>
- [20] M. Alt, S. Fischer, S. Schenk, S. Zimmermann, K. Ramspeck, and M. Meixner, “Electroluminescence imaging and automatic cell classification in mass production of silicon solar cells,” in *2018 IEEE 7th World Conference on Photovoltaic Energy Conversion, WCPEC 2018 - A Joint Conference of 45th IEEE PVSC, 28th PVSEC and 34th EU PVSEC*. Institute of Electrical and Electronics Engineers Inc., nov 2018, pp. 3298–3304.
- [21] J. A. Tsanakas, D. Chrysostomou, P. N. Botsaris, and A. Gasteratos, “Fault diagnosis of photovoltaic modules through image processing and Canny edge detection on field thermographic measurements,” *International Journal of Sustainable Energy*, vol. 34, no. 6, pp. 351–372, jul 2015.
- [22] K. Niazi, W. Akhtar, H. A. Khan, S. Sohaib, and A. K. Nasir, “Binary Classification of Defective Solar PV Modules Using Thermography,” in *2018 IEEE 7th World Conference on Photovoltaic Energy Conversion, WCPEC 2018 - A Joint Conference of 45th IEEE PVSC, 28th PVSEC and 34th EU PVSEC, 2018*, pp. 753–757.
- [23] T. Pivem, F. de Oliveira de Araujo, L. de Oliveira de Araujo, and G. S. de Oliveira, “Application of A Computer Vision Method for Soiling Recognition in Photovoltaic Modules for Autonomous Cleaning Robots,” *Signal & Image Processing : An International Journal*, vol. 10, no. 03, pp. 43–59, 2019.

- [24] A. M. Karimi, J. S. Fada, J. Liu, J. L. Braid, M. Koyuturk, and R. H. French, "Feature Extraction, Supervised and Unsupervised Machine Learning Classification of PV Cell Electroluminescence Images," 2018 IEEE 7th World Conference on Photovoltaic Energy Conversion, WCPEC 2018 - A Joint Conference of 45th IEEE PVSC, 28th PVSEC and 34th EU PVSEC, pp. 418–424, 2018.
- [25] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng, "TensorFlow: Large-scale machine learning on heterogeneous systems," 2015, software available from tensorflow.org. [Online]. Available: <https://www.tensorflow.org/>
- [26] S. Mehta, A. P. Azad, S. A. Chemmengath, V. Raykar, and S. Kalyanaraman, "DeepSolarEye: Power Loss Prediction and Weakly Supervised Soiling Localization via Fully Convolutional Networks for Solar Panels," in Proceedings - 2018 IEEE Winter Conference on Applications of Computer Vision, WACV 2018, vol. 2018-Janua, 2018, pp. 333–342.
- [27] W. Zelada, "DISEÑO E IMPLEMENTACIÓN DE UN LABORATORIO PARA ESTUDIO DE FALLAS EN PANELES FOTOVOLTAICO," 2019.
- [28] D. Mery, "BALU: A Matlab toolbox for computer vision, pattern recognition and image processing (<http://dmery.ing.puc.cl/index.php/balu>)," 2011.
- [29] F.-f. Li, J. Johnson, and S. Yeung, "Lecture 11 : Detection and Segmentation," 2017.
- [30] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), vol. 11211 LNCS, pp. 833–851, feb 2018.

- [31] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, You only look once: Unified, real-time object detection. IEEE Computer Society, jun 2016, vol. 2016-Decem.
- [32] K. He, G. Gkioxari, P. Dollar, and R. Girshick, “Mask R-CNN,” Proceedings of the IEEE International Conference on Computer Vision, vol. 2017-Octob, pp. 2980–2988, mar 2017. [Online]. Available: <http://arxiv.org/abs/1703.06870>
- [33] R. Girshick, “Fast R-CNN,” Tech. Rep. [Online]. Available: <https://github.com/rbgirshick/>
- [34] F. Schroff, D. Kalenichenko, and J. Philbin, “FaceNet: A unified embedding for face recognition and clustering,” in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol. 07-12-June, 2015, pp. 815–823.
- [35] W. Zhang, C. Witharana, A. K. Liljedahl, and M. Kanevskiy, “Deep convolutional neural networks for automated characterization of arctic ice-wedge polygons in very high spatial resolution aerial imagery,” Remote Sensing, vol. 10, no. 9, sep 2018.
- [36] S. Galib, F. Islam, M. Abir, and H. K. Lee, “Computer aided detection of oral lesions on CT images,” Tech. Rep. 12, 2015.
- [37] M. Bojarski, D. Del Testa, D. Dworakowski, B. Firner, B. Flepp, P. Goyal, L. D. Jackel, M. Monfort, U. Muller, J. Zhang, X. Zhang, J. Zhao, and K. Zieba, “End to End Learning for Self-Driving Cars,” Tech. Rep., 2016. [Online]. Available: <http://arxiv.org/abs/1604.07316>
- [38] W. Abdulla, “Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow,” GitHub repository, 2017.
- [39] T. Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick, “Microsoft COCO: Common objects in context,” Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), vol. 8693 LNCS, no. PART 5, pp. 740–755, 2014.

- [40] A. Dutta and A. Zisserman, “The VIA annotation software for images, audio and video,” MM 2019 - Proceedings of the 27th ACM International Conference on Multimedia, pp. 2276–2279, 2019.
- [41] R. Adrian, Deep Learning for Computer Vision with Python, 2017.
- [42] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol. 2016-Decem, pp. 770–778, 2016.
- [43] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol. 2016-Decem, pp. 2818–2826, 2016.