

La investigación reportada en esta tesis es parte de los programas de investigación del CICESE (Centro de Investigación Científica y de Educación Superior de Ensenada, B.C.). La investigación fue financiada por el CONACYT (Consejo Nacional de Ciencia y Tecnología).

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México). El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos Autor.

CICESE © 2023, Todos los Derechos Reservados, CICESE

Centro de Investigación Científica y de Educación Superior de Ensenada



Maestría en Ciencias en Electrónica y Telecomunicaciones con orientación en Telecomunicaciones

Uso del efecto de electroluminiscencia infrarroja para la detección de defectos en paneles fotovoltaicos

Tesis

para cubrir parcialmente los requisitos necesarios para obtener el grado de
Maestro en Ciencias

Presenta:

Abner Calderón Velderrain

Ensenada, Baja California, México

2023

Tesis defendida por

Abner Calderón Velderrain

y aprobada por el siguiente Comité

Dr. Miguel Ángel Alonso Arévalo

Codirector de tesis

Dr. Daniel Saucedo Carvajal

Codirector de tesis

Dr. Jassiel Rolando Rodríguez Barreras

Dr. Rafael de Jesús Kelly Martínez

Dr. Luis Antonio Ríos Osuna

Dr. Ubaldo Ruiz López



Dra. María del Carmen Maya Sánchez

Coordinadora del Electrónica y Telecomunicaciones

Dr. Pedro Negrete Regagnon

Director de Estudios de Posgrado

Resumen de la tesis que presenta Abner Calderón Velderrain como requisito parcial para la obtención del grado de Maestro en Ciencias en Electrónica y Telecomunicaciones con orientación en Telecomunicaciones.

Uso del efecto de electroluminiscencia infrarroja para la detección de defectos en paneles fotovoltaicos

Resumen aprobado por:

Dr. Miguel Ángel Alonso Arévalo

Codirector de tesis

Dr. Daniel Saucedo Carvajal

Codirector de tesis

Las energías renovables contribuyen a la reducción de las emisiones de gases de efecto invernadero. Los paneles fotovoltaicos (PF) son una fuente de energía renovable que permite generar electricidad a partir de la luz solar. Por su ubicación geográfica, México se encuentra en una zona donde la radiación solar es alta. Para aprovechar al máximo la radiación solar es importante conocer el estado de funcionamiento de los PF y una forma de analizarlos es por medio de la electroluminiscencia. La electroluminiscencia es un fenómeno opto-eléctrico en el cuál un material emite luz en respuesta a una corriente eléctrica que fluye a través de él. La electroluminiscencia infrarroja nos permite adquirir imágenes de PF en el infrarrojo cercano (NIR). Es una técnica no invasiva y de bajo costo que provee información sobre el funcionamiento de las celdas fotovoltaicas. El rendimiento de un PF depende de su estado, y este se verá afectado o disminuido si el dispositivo presenta microgrietas, celdas desconectadas, zonas muertas, etc. Con la ayuda de herramientas de adquisición y tratamiento de imágenes se facilita el análisis de las imágenes de electroluminiscencia. En este trabajo, se construyó un banco de pruebas y se adquirieron imágenes mediante una cámara monocromática sensible en el NIR. Se creó una base de datos de 846 imágenes de electroluminiscencia que contiene celdas fotovoltaicas dañadas y en buen estado. Se propone una técnica de preprocesamiento para mejorar la calidad de las imágenes; además se propone el uso de algoritmos de aprendizaje profundo para clasificar las imágenes. Las celdas fotovoltaicas se clasifican como dañada o en buen estado, de esta manera se analiza el estado del PF. Se propone el uso de dos redes neuronales de alto desempeño: AlexNet y VGG16. Se agregó a la base propia de imágenes de electroluminiscencia los datos de una base de datos pública que consta de 2,540 muestras, en total se analizaron 3,386 imágenes. Se analizaron varios escenarios y el sistema propuesto logra un valor F1 de 90.5 % en la clase de celdas dañadas y 91.81 % en las celdas en buen estado.

Palabras clave: Panel fotovoltaico, Infrarrojo cercano, Electroluminiscencia

Abstract of the thesis presented by Abner Calderón Velderrain as a partial requirement to obtain the Master of Science degree in Electronic and Telecommunications with orientation in Telecommunications.

Use of the infrared electroluminescence effect for the detection of defects in photovoltaic panels

Abstract approved by:

Dr. Miguel Ángel Alonso Arévalo

Thesis Co-Director

Dr. Daniel Saucedo Carvajal

Thesis Co-Director

Renewable energies contribute to the reduction of greenhouse gas emissions. Photovoltaic (PV) panels are a renewable energy source that generates electricity from sunlight. Due to its geographical location, Mexico is located in an area where solar radiation is high. To make the most of solar radiation, it is important to know the operating state of the PVs and one way to analyze them is by means of electroluminescence. Electroluminescence is an opto-electrical phenomenon in which a material emits light in response to an electric current flowing through it. Infrared electroluminescence allows us to acquire FP images in the near infrared (NIR). It is a non-invasive and low-cost technique that provides information about the performance of photovoltaic cells. The performance of a PF depends on its condition, and this will be affected or diminished if the device presents micro-cracks, disconnected cells, dead zones, etc. With the help of image acquisition and processing tools, the analysis of electroluminescence images is facilitated. In this work, a test bench was built and images were acquired using a sensitive monochromatic camera in the NIR. A database of 846 electroluminescence images containing damaged and good photovoltaic cells was created. A preprocessing technique is proposed to improve the quality of the images; furthermore, the use of deep learning algorithms is proposed to classify the images. The photovoltaic cells are classified as damaged or in good condition, in this way the state of the PF is analyzed. The use of two high performance neural networks AlexNet and VGG16 is proposed. Data from a public database consisting of 2,540 samples were added to the in-house electroluminescence image database; a total of 3,386 images were analyzed. Several scenarios were analyzed and the proposed system achieves an F1 score of 90.5 % in the damaged cell class and 91.81 % in the good cell class.

Keywords: Photovoltaic panel, Near infrared, Electroluminescence

Dedicatoria

Este trabajo se lo dedico a toda mi familia y amigos, ya que me han apoyado en todas las etapas de mi formación académica.

Agradecimientos

Agradezco a mi familia que me ha apoyado incondicionalmente en los caminos y decisiones que he decidido tomar.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por brindarme el apoyo económico para realizar mis estudios de maestría (CVU: 1064224).

Agradezco a David Said Jiménez López y Miguel Angel Castro Pérez quienes me apoyaron durante mi grado de tesis y compartimos muchas horas de trabajo y buenos momentos.

Agradezco a Gustavo Enrique Ramos Alcaraz y Leonel Orozco Reyes por su apoyo incondicional durante este trabajo.

Agradezco al Dr. Miguel Ángel Alonso Arévalo y al Dr. Daniel Saucedo Carvajal por su guía y enseñanza a lo largo de este trabajo. A mis sinodales, Dr. Rafael de Jesús Kelly Martínez, Dr. Jassiel Rolando Rodríguez Barreras, Dr. Luis Antonio Ríos Osuna y al Dr. Ubaldo Ruiz López por su apoyo y enseñanza durante el proyecto.

Agradezco a Roberto Conte Galván, al taller de mecánica y a todos los profesores, investigadores y amigos del CICESE por toda la ayuda que me brindaron en distintos puntos de mi trabajo de tesis.

Agradezco a la Dra. Alma Georgina Navarrete Alcalá, Dra. Elena Tchaikina Kolesnikova y al Dr. Luis Antonio Ríos Osuna por la ayuda para realizar las mediciones de electroluminiscencia que se muestran en la figura 18.

Agradezco al Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California (CICESE) por brindar las herramientas para el desarrollo de este trabajo.

Tabla de contenido

Página

Resumen en español	ii
Resumen en inglés	iii
Dedicatoria	iv
Agradecimientos	v
Lista de figuras	viii
Lista de tablas	xi

Capítulo 1. Introducción

1.1. Radiación solar en el mundo	1
1.2. Los paneles fotovoltaicos y sus defectos	1
1.3. Antecedentes	2
1.4. Planteamiento del problema	3
1.5. Justificación	4
1.6. Hipótesis	4
1.7. Objetivos	4
1.7.1. Objetivo general	4
1.7.2. Objetivos específicos	4
1.8. Organización de la tesis	5

Capítulo 2. Estado del arte

2.1. Paneles fotovoltaicos	6
2.1.1. Producción de los bloques de silicio	8
2.1.2. Creación de las obleas de silicio	8
2.1.3. Creación del panel fotovoltaico	9
2.1.4. Tipos e instalación de los paneles fotovoltaicos	11
2.2. Estado del arte	12
2.2.1. Adquisición de la imagen	12
2.2.2. Base de datos y procesamiento de las imágenes	14
2.2.3. Entrenamiento del clasificador y clasificación de las imágenes	15
2.2.4. Toma de decisión de los algoritmos y resultados	17

Capítulo 3. Adquisición y procesamiento de imágenes de electroluminiscencia

3.1. Electroluminiscencia	19
3.1.1. Electroluminiscencia de los paneles fotovoltaicos	20
3.1.2. Equipo utilizado para las pruebas de electroluminiscencia	21
3.2. Procesamiento	27
3.2.1. Distorsión en imágenes	27
3.2.2. Distorsión de barril	27
3.2.3. Calibración de las imágenes adquiridas con la cámara ASI178MM monocromática ZWO	28
3.3. Adquisición de las imágenes de electroluminiscencia	34

3.3.1. Preprocesamiento de las imágenes EL	36
3.4. Pruebas de funcionamiento del panel fotovoltaico	41
3.4.1. Bases de datos	43

Capítulo 4. Clasificación de imágenes de electroluminiscencia

4.1. Fundamentos matemáticos de las redes neuronales	46
4.1.1. Perceptrón	46
4.1.2. Algoritmo de aprendizaje automático	47
4.2. Redes neuronales convolucionales (CNN)	49
4.3. Arquitectura de una CNN	51
4.4. Filtros, convoluciones y función de activación	52
4.5. Muestreo, capa densa y capa de salida	55
4.5.1. Comparación entre una red neuronal y una red neuronal con- volucional	57
4.6. <i>Transfer learning</i>	58
4.7. Validación cruzada	58
4.8. Matriz de confusión y las métricas de rendimiento del modelo para dos clases	60
4.8.1. Precisión	62
4.8.2. Sensitividad	62
4.8.3. Exactitud	62
4.8.4. Valor F1	62

Capítulo 5. Resultados del clasificador de imágenes de electrolu- miniscencia

5.1. Resultados obtenidos utilizando la arquitectura VGG16	65
5.1.1. Resultados del clasificador binario utilizando la base de datos original sin balanceo	65
5.1.2. Resultados del clasificador binario utilizando la base de datos original balanceada	67
5.1.3. Pruebas del clasificador de tres clases utilizando la base de datos extendida	69
5.2. Resultados obtenidos utilizando la arquitectura AlexNet	72
5.2.1. Resultados del clasificador binario utilizando la base de datos original sin balanceo	72
5.2.2. Resultados del clasificador binario utilizando la base de datos original balanceada	74
5.2.3. Pruebas del clasificador de tres clases utilizando la base de datos extendida	76
5.3. Resultados obtenidos utilizando la técnica de <i>transfer learning</i>	79
5.3.1. Pruebas del clasificador de tres clases utilizando la base de datos extendida	79

Capítulo 6. Conclusiones

6.1. Sobre los objetivos de la tesis	82
6.2. Trabajo futuro	83

Literatura citada	85
------------------------------------	----

Lista de figuras

Figura	Página
1. Mapa de la irradiación solar en México.	1
2. Electroluminiscencia aplicada en una celda fotovoltaica.	2
3. Proceso de generación de energía fotovoltaica en un panel fotovoltaico . .	6
4. Diferentes tipos de paneles fotovoltaicos existentes	7
5. Diagrama del proceso de creación de un panel fotovoltaico	8
6. Cambio de la superficie de una oblea de silicio	9
7. Proceso de análisis de calidad de las celdas fotovoltaicas	9
8. Enmarcado automático para PF	10
9. Representación gráfica del proceso de fabricación de una celda fotovoltaica	11
10. Principales tamaños de los paneles fotovoltaicos comerciales	11
11. Diferentes tipos de defectos en las celdas fotovoltaicas	12
12. Defectos en celdas fotovoltaicas	13
13. Imágenes de electroluminiscencia extraídas de una base de datos pública	15
14. Visualización del diagrama de un modelo de redes neuronales convolucio- nales	16
15. Precisión del modelo del clasificador CNN y su respuesta conforme las épocas de entrenamiento	18
16. Funcionamiento del panel solar al momento de polarizarse directamente .	19
17. Excitación de un panel fotovoltaico el cuál emite radiación infrarroja.	20
18. Espectro infrarrojo del panel fotovoltaico	21
19. Fuente de voltaje utilizada	22
20. Lente Cinegon con distancia focal de 7.2 mm	22
21. Panel fotovoltaico de la marca JA Solar.	23
22. Panel fotovoltaico de la marca Condumex.	23
23. Panel fotovoltaico de la marca SunTech.	24
24. Filtros ópticos pasa largo utilizados durante las pruebas de EL.	24
25. Gráfica de la respuesta de los filtros pasa largo utilizados.	25
26. Estructura de montaje de la cámara	25
27. Cámara de uso astronómico ASI178MM.	26
28. Curva de respuesta espectral de la cámara ASI178MM.	26
29. Tarjeta de video utilizada para el entrenamiento de la red neuronal.	27

30. Detección de los cuadrados del tablero de ajedrez.	29
31. Localización de las imágenes utilizadas.	29
32. Error medio en píxeles de las imágenes utilizadas para las pruebas de distorsión.	30
33. Comparación entre la imagen original y corregida.	30
34. Resta entre la imagen original y corregida.	31
35. Disminución de la distorsión.	31
36. Estructura ajustable para prueba de PF.	34
37. Ajuste de los parámetros a utilizar	35
38. Imagen con ruido y píxeles calientes.	36
39. Ruido obtenido del sensor para cada pixel.	37
40. Ruido obtenido por largos tiempos de exposición.	37
41. Diagrama de la compensación de la imagen y mejora de la calidad.	38
42. Comparación de la imagen EL original y la imagen EL compensada.	39
43. Comparación del histograma de la imagen de EL compensada y original.	40
44. Representación gráfica del proceso de compensación y recorte.	40
45. Recorte de las celdas fotovoltaicas automáticamente.	41
46. Diagrama de flujo del algoritmo de procesamiento y clasificación.	42
47. Celda fotovoltaica en buen estado.	43
48. Celda fotovoltaica dañada.	44
49. Forma gráfica del comportamiento de las neuronas en una red neuronal.	49
50. Representación de una imagen de 8 bits monocromática con sus valores matriciales normalizados.	51
51. Representación de una imagen de 8 bits con 3 canales con sus valores matriciales normalizados.	51
52. Arquitectura de una red neuronal convolucional.	52
53. Visualización del <i>kernel</i> que se convolucionará contra la imagen de entrada.	53
54. Ejemplo de la convolución entre la imagen y el <i>kernel</i>	53
55. Proceso de convolución en redes neuronales convolucionales	54
56. Matriz del filtro convolucionada.	54
57. Comportamiento de la función de activación ReLU.	55
58. Aplicación de ReLU en la matriz final.	55
59. Técnica de <i>Maxpooling</i> utilizada a partir del ejemplo anterior.	56

60. Arquitectura VGG16 de una red neuronal con 2 clases de salida.	57
61. Arquitectura AlexNet de una red neuronal con 2 clases de salida.	57
62. Ejemplo de como se efectúa una validación cruzada.	59
63. Ejemplo de una matriz de confusión.	61
64. Análisis del tipo de imágenes que se encuentran en el directorio.	64
65. Gráfica de precisión del modelo VGG16.	65
66. Gráfica de pérdida de la validación cruzada del modelo VGG16.	66
67. Matriz de confusión del modelo utilizando VGG16.	67
68. Gráfica de precisión de la validación cruzada 10 <i>fold</i> del modelo VGG16 utilizando la base de datos original balanceada.	68
69. Gráfica de pérdida de la validación cruzada 10 <i>fold</i> del modelo VGG16 utilizando la base de datos original balanceada.	68
70. Matriz de confusión utilizando la base de datos original.	69
71. Gráfica de precisión de la validación cruzada 10 <i>fold</i> del modelo utilizando VGG16 con la base de datos extendida.	70
72. Gráfica de pérdida de la validación cruzada 10 <i>fold</i> del modelo utilizando VGG16 la base de datos extendida.	70
73. Matriz de confusión utilizando la base de datos extendida.	71
74. Imágenes que fueron predichas incorrectamente.	72
75. Gráfica de precisión de la validación cruzada 10 <i>fold</i> del modelo AlexNet utilizando la base de datos original sin balanceo.	73
76. Gráfica de pérdida de la validación cruzada 10 <i>fold</i> del modelo AlexNet utilizando la base de datos original sin balanceo.	73
77. Matriz de confusión del modelo utilizando AlexNet.	74
78. Gráfica de precisión de la validación cruzada 10 <i>fold</i> del modelo AlexNet. .	75
79. Gráfica de pérdida de la validación cruzada 10 <i>fold</i> del modelo AlexNet. .	75
80. Matriz de confusión del modelo utilizando AlexNet.	76
81. Gráfica de precisión del modelo utilizando AlexNet con la base de datos extendida.	77
82. Gráfica de pérdida del modelo utilizando AlexNet con la base de datos extendida.	77
83. Matriz de confusión utilizando la base de datos extendida.	78
84. Gráfica de precisión utilizando la técnica de <i>transfer learning</i>	79
85. Gráfica de pérdida utilizando la técnica de <i>transfer learning</i>	80
86. Matriz de confusión del modelo utilizando la técnica de <i>transfer learning</i> . .	80

Lista de tablas

Tabla	Página
1. Propiedades de los algunos tipos de cámara utilizadas para la obtención de imágenes de EL.	14
2. Área del cuadrado del tablero del ajedrez con la imagen cruda.	32
3. Área del cuadrado del tablero del ajedrez con la imagen procesada.	32
4. Relación cuantificada entre la imagen sin corrección y la imagen corregida	33
5. Distorsión de la imagen original obtenida.	33
6. Comparación entre dos tipos de redes neuronales.	57
7. Resultados del clasificador VGG16 con la base de datos sin balanceo.	67
8. Resultados del clasificador VGG16 con la base de datos balanceada.	69
9. Resultados de desempeño del clasificador utilizando VGG16.	71
10. Algunas métricas de desempeño de los clasificadores entrenados con VGG16.	72
11. Resultados del clasificador AlexNet sin balanceo.	74
12. Resultados del clasificador AlexNet con la base de datos original balanceada.	76
13. Resultados del clasificador AlexNet con la base extendida.	78
14. Algunas métricas de desempeño de los clasificadores entrenados con AlexNet.	78
15. Resultados de las métricas de desempeño usando <i>transfer learning</i> con VGG16.	81

Capítulo 1. Introducción

1.1. Radiación solar en el mundo

El uso de las energías renovables como lo es la energía solar ha permitido que el petróleo deje de ser la fuente principal para generar electricidad, esto ha influido mucho en el mundo de las finanzas y la economía. Según la *Energy Transitions Commission* (2017), el consumo per cápita anual de energía para garantizar una buena calidad de vida es de 22.22 a 27.77 Megawatts-hora (MWh), cabe señalar que en México, en 2015, se consumieron 19.66 MWh. México se encuentra situado entre 15° y 35° de latitud norte, región que es considerada favorecida en recursos solares, donde se recibe diariamente en ciertas áreas una radiación solar mayor 5 kWh/m² (Vargas-Hernández and Espinosa, 2016). En la figura 1 se observa que el noroeste del país de México es la región con mayor potencial de radiación solar del país.




Figura 1. Mapa de la irradiación solar en México (Vargas-Hernández and Espinosa, 2016).

1.2. Los paneles fotovoltaicos y sus defectos

Los paneles fotovoltaicos (PF) suelen estar expuestos a tensiones termomecánicas durante su producción, montaje y operación a lo largo de su vida útil, lo cuál puede

provocar daños físicos como microgrietas, fracturas, desconexiones entre celdas, entre otros. El agrietamiento de las celdas fotovoltaicas es una causa de la pérdida de voltaje en los paneles fotovoltaicos (Parikh et al., 2020), por lo que es necesario de visualizar estos defectos, es posible observar estos defectos utilizando el fenómeno de la electroluminiscencia (EL), se produce cuando un material emite luz en respuesta a una corriente eléctrica que fluye a través de el, estas imágenes que se generan a través de la electroluminiscencia permiten identificar distintos tipos de defectos que se visualizan como zonas oscuras en la celda fotovoltaica, como se observa en la figura 2.




Figura 2. Desconexión eléctrica en la celda solar (Köntges et al., 2011).

1.3. Antecedentes

Existen diferentes tecnologías de celdas fotovoltaicas y la más utilizada es la de celdas de silicio policristalino gracias a su bajo costo comparada con la de silicio monocristalino, independientemente del tipo de tecnología, la detección oportuna de defectos es esencial para conocer el estado y asegurar la confiabilidad del panel fotovoltaico. Varios trabajos presentan el uso de celdas fotovoltaicas policristalinas, por ejemplo, el trabajo que presenta Lockridge et al. (2016), realiza una comparación de métodos de captura de imágenes de electroluminiscencia con el uso de distintas cámaras, las cuáles intentan detectar defectos en las celdas. A pesar del método de captura de imágenes es importante realizar una segmentación del objeto deseado, el método de Otsu citado por Spataru et al. (2015), se basa en detectar un cierto parámetro en los píxeles (nivel de intensidad) que conforman una imagen, se compara el valor de cada píxel contra un valor de referencia propuesto (umbral) y categoriza el píxel. Esta téc-

nica es utilizada en imágenes monocromáticas y puede ser combinada con algoritmos de segmentación automática, que podrían generar buenos resultados en las imágenes de una base de datos.

La cantidad de imágenes en una base de datos es muy importante a la hora del reconocimiento de defectos en celdas fotovoltaicas, debido a que brindan diferentes tipos de características de aprendizaje, en el estudio de Parikh et al. (2020), se reporta el uso de casi 46,000 imágenes de electroluminiscencia que contaban con diferentes tipos de defectos, de los cuáles se extrajeron parámetros estadísticos del histograma de estas imágenes, y se utilizaron como características de aprendizaje para el clasificador. La investigación se basa en un clasificador de tres categorías: grietas, microgrietas y celdas sin fallos, para detectar estos tipos de defectos se utilizaron tres técnicas de aprendizaje de máquina para entrenar la red y así comparar los resultados, los cuáles fueron los siguientes: Máquinas de soportes (SVM), Bosques Aleatorios (RF) y k-vecinos más cercanos (k-NN), los tres clasificadores obtuvieron buenos resultados y la precisión fue de: 96.7 % (SVM), 99.2 % (RF) y 98.4 % (k-NN).

A parte del aprendizaje de máquina ya mencionado, existen trabajos en el cuál se menciona el uso de redes neuronales convolucionales (CNN) para la clasificación de imágenes, por ejemplo, Akram et al. (2019) en su investigación, reporta que obtuvo un 93% de precisión a la hora de la detección de defectos en celdas fotovoltaicas utilizando una CNN. Esta red neuronal convolucional fue basada en la arquitectura VGG la cuál utilizó solo 4 capas de convoluciones, los cambios realizados en la red neuronal fueron debidos a que se contaba con una base de datos pequeña (2,624 imágenes) y querían evitar un sobreajuste. Al disminuir el tamaño de la red permitió reducir el tiempo de entrenamiento y el de predicción. El tiempo de predicción fue de 8.07 *ms*, gracias al bajo tiempo de respuesta y la optimización de la red neuronal mencionada, se pudieron realizar predicciones con una computadora de uso básico.

1.4. Planteamiento del problema

En el caso de los paneles fotovoltaicos y sus celdas fotovoltaicas es muy sencillo dañarlas indirectamente ya que algunos de estos dispositivos son sensibles al tacto, el simple hecho de hacer un mal manejo de las celdas puede llevar a dañar el dispositivo, por lo que es importante determinar si el panel fotovoltaico sigue considerándose

en buen estado para seguir funcionando. Es necesario crear un método de análisis enfocado a los paneles fotovoltaicos, teniendo en cuenta que los resultados obtenidos nos den a conocer el estado funcional de las celdas.

1.5. Justificación

México cuenta con un gran potencial para la recepción de la energía solar debido a su zona geográfica, en los últimos años la energía solar ha estado ocupando un espacio cada vez mayor dentro de la economía global, por lo que los países están cambiando sus políticas energéticas para el desarrollo de tecnologías que proporcionen crecimiento económico sustentable y amigable con el medio ambiente. Es necesario tener un método de inspección de paneles fotovoltaicos, para cuando llegue el momento en que en México, el uso de paneles fotovoltaicos sea algo común y sean utilizados por gran parte de la población del país.

1.6. Hipótesis

La base de datos creada con imágenes de electroluminiscencia infrarroja de celdas fotovoltaicas, permite entrenar una red neuronal convolucional para la detección temprana de defectos en paneles fotovoltaicos, la cuál cuenta con alta certidumbre y permite el diagnóstico del estado de las celdas de una manera no invasiva y rápida.

1.7. Objetivos

1.7.1. Objetivo general

Desarrollar un dispositivo que permita detectar de manera automática defectos en paneles fotovoltaicos mediante el efecto de electroluminiscencia infrarroja.

1.7.2. Objetivos específicos

- Construir una estructura que soporte la instalación de un panel fotovoltaico y una cámara digital con sensibilidad en el infrarrojo cercano.
- Crear una base de datos de imágenes de electroluminiscencia infrarroja utilizando algunos de los paneles fotovoltaicos actualmente instalados en el CICESE.

- Utilizar técnicas de procesamiento de imágenes que permitan mejorar la calidad de las imágenes de EL adquiridas.
- Desarrollar un algoritmo de aprendizaje automático que permita clasificar de manera automática la presencia de defectos en paneles fotovoltaicos.

1.8. Organización de la tesis

El capítulo 2 describe de manera general el estado del arte basado en trabajos donde se realizaron pruebas, clasificadores o algún tipo de manipulación de imágenes de electroluminiscencia, así como también algunos resultados de algoritmos de aprendizaje profundo encontrados en la literatura.

El capítulo 3 abordará el tema de la electroluminiscencia infrarroja y las pruebas realizadas con las imágenes, así como el funcionamiento, creación y algunos tipos de paneles fotovoltaicos que actualmente existen. También presenta de manera breve el principio de fabricación de las celdas fotovoltaicas a partir de un bloque de silicio y como son creados con estas celdas los paneles fotovoltaicos.

El capítulo 4 expone el tema de redes neuronales convolucionales de una manera práctica, así como algunas técnicas basadas en el aprendizaje de máquina y las métricas que suelen utilizarse con las matrices de confusión obtenidas de los clasificadores de imágenes.

En el capítulo 5 se exponen los resultados obtenidos después de varias pruebas hechas con el clasificador de imágenes de electroluminiscencia aplicado en paneles fotovoltaicos, también muestran las métricas principales que se toman en cuenta al momento de medir el rendimiento de un clasificador.

En el capítulo 6 se presentan los objetivos cumplidos del proyecto, así como también el trabajo futuro y las mejoras que se pueden realizar para obtener un producto comercial para la detección de defectos en paneles fotovoltaicos a un bajo costo.

Capítulo 2. Estado del arte

2.1. Paneles fotovoltaicos

Un panel fotovoltaico es un dispositivo que aprovecha la energía solar para generar electricidad, utilizando el efecto fotovoltaico que provoca un flujo de electrones entre dos semiconductores próximos de distinto tipo (P y N) y genera un campo eléctrico que producirá una corriente eléctrica, como se muestra en la figura 3. Una celda solar prácticamente es una unión PN con una gran superficie, la generación de corriente eléctrica ocurre dentro de la zona de agotamiento de la unión PN, donde la región de agotamiento es el área alrededor de la unión, los electrones del silicio de tipo N entran en los orificios del material de tipo P, cuando un fotón de luz es absorbido por uno de estos átomos en el silicio de tipo N, se desaloja un electrón, creando un electrón libre y un hueco. El electrón libre y el hueco tienen suficiente energía para saltar fuera de la zona de agotamiento, lo que hace que el electrón sea atraído por la carga positiva del material tipo P y viaje a través de la carga externa creando un flujo de corriente eléctrica, el agujero creado por el electrón desprendido es atraído por la carga negativa del material de tipo N y migra al contacto eléctrico trasero. A medida que el electrón entra en contacto con el silicio de tipo P desde el contacto eléctrico posterior, se combina con el orificio para restaurar la neutralidad eléctrica y se mantiene el flujo de electrones.




Figura 3. Proceso de generación de energía fotovoltaica (Cibse, 2010).

Las celdas fotovoltaicas de silicio son las más comunes y utilizadas, el rendimiento de éstas depende de la estructura interna que tengan las láminas de silicio. Según su estructura podemos clasificarlas del siguiente modo:

- **Celdas de silicio monocristalino:** constituido por un solo cristal de grandes dimensiones que es cortado en finas láminas, generalmente de azul uniforme. Son las más avanzadas, el coste de fabricación es alto y proporcionan un rendimiento superior bajo determinadas condiciones.
- **Celdas de silicio policristalino:** están constituidas por varios cristales, tienen un color azul no uniforme, presentan menor eficiencia que las celdas de silicio monocristalino.
- **Celdas de silicio amorfo:** el silicio que contiene se encuentra de forma amorfa por lo que no contiene cristales definidos, es la forma más barata pero también la que menor rendimiento ofrece, se utilizan, por ejemplo, en dispositivos como calculadoras o relojes y tienen la particularidad de que pueden producir electricidad (en poca cantidad) aunque no estén expuestas directamente a la radiación solar de manera perpendicular.



Figura 4. Diferentes tipos de paneles fotovoltaicos (El Hammoumi et al., 2022).

2.1.1. Producción de los bloques de silicio

El silicio es utilizado para crear celdas fotovoltaicas, son creadas a partir de lingotes de silicio que surgen a través de la fundición de semiconductores a base de silicio, al tener el lingote producido, se procede a segmentarlo, una vez estén cortados en forma de cubos, se pulimentan con cuidado y se procede a realizar otros cortes que generen obleas de silicio. Por lo general, estas celdas fotovoltaicas de silicio cristalino se dividen en dos tipos: oblea de alta calidad (monocristalina) o una oblea de silicio de menor calidad (policristalina), el grosor de las obleas esta en el intervalo de 350 a 450 μm , las obleas de silicio son revisadas, reparadas y/o pulimentadas, ya que estarán envueltas por conductores metalizados. Para esto se tienen que seguir los pasos mostrados en la figura 5, en la cuál nos expone todas las etapas que conlleva el crear celdas fotovoltaicas.




Figura 5. Diagrama del proceso de creación de un panel fotovoltaico (Efenarsolar, 2021).

2.1.2. Creación de las obleas de silicio

El corte de las obleas de silicio son de forma cuadrada, una vez realizado el corte del lingote, se usa un método de limpieza en la oblea de silicio el cuál se basa en una solución ácida o alcalina para limpiar la capa de daño del corte ocasionado en la superficie oblea de silicio. Esto permite que la estructura de la superficie del material tenga una mejora en su área superficial (ver figura 6), ya ayuda a minimizar los reflejos de luz no deseados, de esta manera las celdas podrán absorber mayor luz solar.

Después las celdas son colocadas en pares ocultando una cara de este y son ingresadas a un horno tubular, donde son calentadas a 800°C mientras se recubren con gas de fósforo de nitrógeno. El gas se condensa en la superficie expuesta y penetra

la oblea creando dos capas con diferentes características electrónicas, para difundir y producir la unión PN_+ para así generar una oblea de silicio conductora la cuál genere un flujo de electrones que genere el efecto fotovoltaico deseado. A la oblea se le añade una capa de difusión que se forma en la superficie de la oblea de silicio, ésta capa de difusión provoca un cortocircuito del electrón superior e inferior, de esta forma se logra aislar la carga positiva de la oblea de silicio de la parte negativa para poder continuar con el proceso de manufacturación.




Figura 6. Cambio de la superficie de una oblea de silicio (Akinyele et al., 2015)

2.1.3. Creación del panel fotovoltaico

Una vez terminado el proceso de añadir los electrodos se revisan nuevamente las celdas para evitar imperfecciones o posibles fracturas generadas por la cadena de procesos mientras que su eficiencia eléctrica es analizada con luz artificial de 1000 W y dependiendo de los resultados las celdas son clasificadas según su grado de calidad (grado A o B), así como se observa en la figura 7.




Figura 7. Análisis de calidad de las celdas fotovoltaicas (Akinyele et al., 2015).

Ya que las celdas de silicio se encuentran evaluadas y aprobadas, se montan en un laminado y son conectadas en serie, se recubren por un lado y del otro lado se monta un vidrio antirreflejante para la protección del módulo solar. Después se monta una nueva película que es sellada y crea un sistema fotovoltaico que resiste hasta 1000 W. Para terminar, se realizan pruebas eléctricas y de electroluminiscencia para así visualizar la calidad en general del panel fotovoltaico creado y los conectores son montados en la parte trasera del PF para ser puesto en una base de aluminio anodizado con un proceso de enmarcado de alta precisión (ver figura 8).




Figura 8. Proceso de enmarcado automático para PF (Akinyele et al., 2015).

Una vez realizado el montaje de las celdas solares en el encapsulado y los sockets de conexión ajustados, se procede a sellarlos y protegerlos con silicón industrial, para de esta forma realizar las últimas pruebas eléctricas del panel fotovoltaico.

El proceso de fabricación de las celdas fotovoltaicas de silicio cristalino se puede representar con el diagrama de la figura 9.




Figura 9. Representación gráfica del proceso de fabricación de una celda fotovoltaica.

2.1.4. Tipos e instalación de los paneles fotovoltaicos

Los paneles fotovoltaicos mas utilizados están conformados de 60 y 72 celdas(ver figura 10), suelen instalarse en lugares altos y abiertos (azoteas, techos, zonas abiertas, etc.), para evitar que excedan la temperatura de operación. A los paneles se les instala una película de vidrio que actúa como una protección para las celdas, una vez unido el vidrio con el panel se emplea cemento conductivo térmico (Serrano, 2017), el cuál reduce la probabilidad de que los paneles fotovoltaicos se sobrecalienten.



Figura 10. Principales tamaños de los paneles fotovoltaicos comerciales (Serrano, 2017).

2.2. Estado del arte

Existen distintas formas de supervisar si los paneles fotovoltaicos cuentan con defectos, por ejemplo: las imágenes de electroluminiscencia, la termografía de flujo térmico y por medio de tecnología ultrasónica (Fuyuki et al., 2005). Aunque se puedan detectar a tiempo los defectos, no se pueden rechazar todas las celdas fotovoltaicas y cada uno de los módulos fotovoltaicos contruidos, el daño ocasionado por las microgrietas es mínimo siempre y cuando las secciones de la celda sigan conectadas eléctricamente. Sin embargo, a medida que pasa el tiempo de vida útil del panel, el movimiento relativo repetitivo de las secciones rotas de la celda pueden resultar en una separación eléctrica total, dejando partes de la celda inactivas (Pingel et al., 2009) (Gabor et al., 2006), es necesario realizar un análisis rutinario del estado de los paneles fotovoltaicos para evitar un daño total.

2.2.1. Adquisición de la imagen

En Köntges et al. (2011) se menciona una prueba para observar la relevancia de las microgrietas en las celdas fotovoltaicas, se realizaron pruebas con doce módulos fotovoltaicos de 60 celdas fotovoltaicas policristalinas libres de fisuras de $15.6 \times 15.6 \text{ cm}^2$ del mismo tipo. Se utilizó el método de EL mediante una cámara óptica Sensicam qe de 1.42 Mpixeles que usa corrección de campo oscuro (una mejora de contraste) para la detección de microgrietas. El número de celdas fotovoltaicas rotas fue visualizado debido a que había regiones inactivas en la imagen de la celda (Ver figura 11).




Figura 11. Defectos en las celdas, A) Microgrietas, B) Zonas muertas y C) Desconexiones (Köntges et al., 2011).

Parikh et al. (2020) presenta el uso de una cámara de superior calidad a las ya mencionadas. Las imágenes EL se adquirieron utilizando una cámara Nikon D750 que consta de un sensor CMOS de 24.3 Mpixeles, que fue modificado reemplazando el filtro que elimina el infrarrojo integrado en la cámara por uno que permite el paso de longitudes de onda en el intervalo de 850–1700 *nm*. Las imágenes se adquirieron al aire libre una hora antes de la puesta del sol, aproximadamente a las 17:00 horas con una base trípode que sujeta la cámara perpendicular al módulo a una distancia de 2-3 m con un tiempo de exposición entre cinco y diez segundos. En la imagen mostrada en la figura 12, se puede apreciar una imagen obtenida en el trabajo, la cámara utilizada cuenta con una mayor resolución, lo que permite obtener una imagen de mayor calidad.

Hablando del uso de distintos tipos de cámaras para la obtención de imágenes de EL, Frazão et al. (2017) en su artículo científico, menciona haber utilizado un equipo de bajo costo para la obtención de imágenes de electroluminiscencia, el cuál incluye el uso de una cámara de uso cotidiano, sin embargo, el uso de una cámara de alta gama puede proporcionar imágenes más nítidas y de mejor calidad para la detección de defectos.




Figura 12. Defectos en imágenes de EL: (A) sin fallas; (B) falla por presión; (C) Modo A de microgrietas (negro); (D) grietas Modo B (verde) y Modo C (blanco) (Parikh et al., 2020).

En la tabla 1, se presenta la comparación de las especificaciones de algunas cámaras que se han utilizado según la literatura en la detección de defectos en paneles fotovoltaicos.

Tabla 1. Propiedades de los algunos tipos de cámara utilizadas para la obtención de imágenes de EL.

Cámaras	Nikon D40	Nikon D750	Sensicam qe
Eficiencia cuántica	50-60%	0.53	0.62
Sensor utilizado	23.7 x 15.6 mm	35.9x24 mm	10.2x8.33 mm
	Sony ICX-453-AQ	Sony IMX128 CMOS sensor	CCD Sensor
Tamaño de la imagen	6.24 Mpix	24.3 Mpix	1.42168 Mpix
Formato de las imágenes	12 Bits RAW	14 Bits RAW	12 Bits
Rango espectral	-	-	290-1200 nm
Tiempo de exposición	5 ms-30 s	2.5 ms-30 s	500 ns-3600 s

2.2.2. Base de datos y procesamiento de las imágenes

Las bases de datos tienen una gran relevancia a nivel profesional, empresarial y científico, son muy necesarias actualmente y es importante saber gestionar la información proveída por la base, una parte muy importante es eliminar la redundancia para de esta manera tener una base de datos mas confiable. Una manera sencilla de trabaja es utilizando una base de datos pública, aunque puede tener repercusiones. En el trabajo de Akram et al. (2019) utilizaron una base de datos de celdas fotovoltaicas pública (ver figura 13), donde al realizar un experimento de esta manera es más difícil conocer las condiciones en las que se obtuvieron las imágenes y esto podría llevar a comprometer los resultados esperados (si es que se piensan añadir imágenes de dos bases de datos totalmente diferentes), si la cantidad de imágenes que se tiene es pequeña, es necesario unir dos bases de datos, ya que se recomienda tener un gran número de imágenes, esto se debe a que en la creación y aprendizaje de un algoritmo clasificador de imágenes se requiere tener como referencia, la mayor cantidad de tipos e imágenes posibles para que el clasificador logre aprender y poder predecir distintos tipos imágenes con mayor precisión.




Figura 13. Imágenes de EL extraídas de una base de datos pública (Akram et al., 2019).

Otra manera de obtener una base de datos es crearla, los autores en Rahman and Chen (2020) diseñaron una base de datos con 828 imágenes EL de celdas fotovoltaicas, cuenta con 406 fotografías con defectos de grietas, 359 imágenes de defectos de interrupción de los dedos y 63 imágenes sin defectos. Todas las imágenes fueron adquiridas en un entorno industrial real, el contraste, el brillo y los patrones de cada imagen son únicos y esto mejora la calidad de la base de datos, ya que se centra en situaciones reales del día a día. Las imágenes de la base de datos fueron procesadas en escala de grises y tuvieron una reducción en la resolución de las imágenes de entrada la cuál fue a una resolución de 224x224x1 pixeles (Tang et al., 2020).

2.2.3. Entrenamiento del clasificador y clasificación de las imágenes

Conocer las ideas y metodologías básicas de la categorización de imágenes, así como destacar el potencial y la utilidad de las técnicas de aprendizaje profundo por encima de las técnicas de aprendizaje automático tradicionales es muy importante para el entrenamiento y clasificación de las imágenes. Uno de los enfoques más modernos citado en el estado del arte conlleva el implementar redes neuronales, Chaganti et al. (2020) mencionan que SVM sería un mejor punto de partida, esto debido a que es un algoritmo tradicional que ha sido utilizado para clasificar imágenes y se han obtenido resultados con alta precisión. También existen métodos que utilizan redes neuronales,

las cuáles pueden llegar superar en precisión, a cualquier algoritmo de aprendizaje automático e incluso otros algoritmos de aprendizaje profundo (Chaganti et al., 2020). Esto sucede dado que el rendimiento de los algoritmos tradicionales de aprendizaje automático tiene un punto de saturación, y el aumento de cantidad de datos más allá de este punto no dará como resultado un mayor rendimiento. En cambio, el aprendizaje profundo y su variante, las redes neuronales convolucionales aprenden ajustando las fortalezas de sus conexiones neuronales para transmitir mejor las señales de entrada a través de múltiples capas de las neuronas asociadas, mientras mas datos sean ingresados en la red, es posible lograr un mejor aprendizaje del modelo (Chaganti et al., 2020).

Las redes neuronales convolucionales son entrenadas por medio de aprendizaje supervisado que a través de sus capas intentan aprender ciertas características que hacen posible identificar objetos. Éstas redes, contienen varias capas ocultas (ver figura 14) que cuentan con una jerarquía: las primeras capas reconocen líneas curvas (Chaganti et al., 2020) y conforme mas se adentra a la red hasta llegar a capas más profundas, se llega a reconocer formas complejas como una cara o la silueta de un animal o en este caso los posibles defectos en un PF. Se cree que hacen lo mencionado anteriormente, pero, no existe una prueba formal que lo compruebe. Este proceso es realizado con imágenes de un tamaño pequeño debido a que las CNN requieren un alto nivel de procesamiento del sistema empleado para entrenar al clasificador. Por lo que, mientras mayor sea la base de datos (se puede aumentar el tamaño de la base de datos con técnicas de *Data Augmentation*) y la cantidad de capas de la red neuronal convolucional aumentará el tiempo de entrenamiento del modelo.




Figura 14. Diagrama de un modelo CNN (Mouha et al., 2021).

Un sistema de clasificación sencillo se basa en cuatro etapas:

- Base de datos: son el conjunto de imágenes obtenidas sobre un objeto específico el cuál será el objetivo a reconocer por medio del entrenamiento supervisado utilizado.
- Preprocesamiento: se refiere al procesado de las imágenes tratando de manipularlas segmentándolas, minimizando el ruido en las imágenes o aplicando filtros para obtener una mejor calidad de las imágenes en la base de datos.
- Decisión y clasificación de las imágenes: en esta etapa se propone la forma en la que se realizará el aprendizaje del algoritmo, ya sea si es un aprendizaje supervisado, no supervisado o semi supervisado. Además se define que tipo de algoritmo de aprendizaje que será utilizado.
- Evaluación de los resultados: en esta etapa se realizan pruebas con el sistema de clasificación entrenado, al usar imágenes de prueba y así obtener la precisión del proceso de clasificación del tipo de imágenes que se quieren identificar.

2.2.4. Toma de decisión de los algoritmos y resultados

Para tener una buena toma de decisiones en un clasificador de imágenes, el sistema entrenado depende la diversidad de imágenes que tiene la base de datos, así como los parámetros de la red de aprendizaje. En Chaganti et al. (2020) reportan una gráfica de la precisión del modelo de clasificación CNN, se puede observar en la figura 15 que se presenta una buena respuesta al realizar pruebas con el clasificador entrenado. En el eje Y de la tabla se muestra la precisión, que es la métrica de fidelidad del modelo, mientras que en el eje X tenemos las épocas, que se refieren al número de iteraciones de entrenamiento realizado con la base de datos. El uso de un sistema basado en redes neuronales convolucionales puede permitirnos obtener resultados sobresalientes, en la figura 15 podemos observar que el sistema entrenado mejora su respuesta conforme pasan las épocas, ya que su curva de aprendizaje tiene un comportamiento ascendente. Dependiendo de la complejidad del sistema, la cantidad de épocas de entrenamiento puede ser mayor o menor, si no se elige un número apropiado de épocas este puede afectar el entrenamiento o simplemente la red neuronal llegará a un punto en el cual no mejorará.




Figura 15. Respuesta del entrenamiento de la CNN (Chaganti et al., 2020).

- Existen dos posibles problemas que se pueden encontrar durante el entrenamiento de una red neuronal, los cuáles son:
 - *Underfitting*: Sucede cuando la red neuronal entrenada falla en reconocer una nueva variación del tipo de imágenes para la cuál se entrenó la red, esto se debe la falta de muestras diferentes para que la red aprenda (Dietterich, 1995).
 - *Overfitting*: Sucede cuando la red neuronal es entrenada con una cierta cantidad de tipos de imágenes, pero si se agrega un nuevo tipo falla en reconocer la imagen. Esto se debe a que la red neuronal solamente fue entrenada para reconocer una cantidad de tipos de imágenes (Dietterich, 1995).

Capítulo 3. Adquisición y procesamiento de imágenes de electroluminiscencia

3.1. Electroluminiscencia

Para conocer como funciona el efecto de electroluminiscencia, es necesario conocer el funcionamiento de un panel fotovoltaico. En la figura 16 se muestra una conexión de polarización directa de la celda fotovoltaica, la luz solar es recibida por el panel fotovoltaico y éste actúa como un diodo PN que consta de una unión de dos semiconductores uno con carga positiva y el otro con carga negativa (Hantula, 2009). Los fotones de la luz solar polarizan directamente la celda para generar una corriente eléctrica la cuál es suministrada hacia un dispositivo eléctrico.




Figura 16. Polarización directa del panel fotovoltaico (Hantula, 2009).

¿Qué sucede si se suministra una corriente eléctrica a un panel fotovoltaico?

Cuando una celda solar está polarizada directamente por una fuente de voltaje, los electrones excitados emiten energía en forma de radiación infrarroja, los rayos infrarrojos electroluminiscentes son invisibles para el ojo humano (ver figura 17). Sin

embargo, es posible obtener información sobre el estado del panel fotovoltaico con la ayuda de una cámara sensible al infrarrojo cercano, utilizando filtros de distinta longitud de onda para la visualización de los rayos infrarrojos generados mediante la excitación de la celda solar.




Figura 17. Excitación de un panel fotovoltaico el cuál emite radiación infrarroja.

3.1.1. Electroluminiscencia de los paneles fotovoltaicos

Una manera de observar el efecto de la electroluminiscencia implica visualizar su espectro con un espectrómetro para infrarrojo cercano, el modo de empleo es parecido al mostrado en la figura 18, pero en vez de la cámara se utilizan lentes ópticas que concentran la radiación infrarroja emitida por el panel fotovoltaico y la redirige hacia el espectrómetro. Las pruebas se realizaron en un laboratorio a puerta cerrada con las luces apagadas, donde la cantidad de luz era mínima (para minimizar la influencia de la luz exterior). Al panel fotovoltaico se le suministró energía con una fuente de voltaje de 30 V@3 A. Como respuesta, se esperaba un espectro cuyo pico de emisión de radiación del panel estuviera cerca de 1200 nm (emisión máxima de radiación del silicio).




Figura 18. Espectro infrarrojo del PF.

Las pruebas se realizaron a un tiempo de exposición de 15 segundos y se promediaron 10 muestras del espectro obtenido. En la figura 18 se presenta el espectro infrarrojo obtenido del panel solar durante las pruebas señaladas, pudimos notar que la emisión de radiación del panel fotovoltaico no era nula y se obtuvo la curva del espectro infrarrojo, por lo que se pudo determinar que se estaba generando el efecto de electroluminiscencia. El analizador de espectros utilizado en las pruebas es un EPP2000-NIR-InGaAs que trabaja en el intervalo de longitud de onda 900-1,700 nm, cuenta con un enfriador termoeléctrico y un ADC de 14 a 16 bits.

3.1.2. Equipo utilizado para las pruebas de electroluminiscencia

- Fuente de voltaje variable Keithley 2231A-30-3 con 2 canales de 0-20 V que soporte hasta 3 A.



Figura 19. Fuente de voltaje utilizada.

- Lente Cinegon 2.1/6": Cuenta con una distancia focal 7.2 mm y tiene un recubrimiento antireflectivo en el ancho de banda de 400 a 1000 nm.



Figura 20. Lente Cinegon con distancia focal de 7.2 mm

- Paneles fotovoltaicos.
 - 2 Paneles fotovoltaicos marca JA Solar.
 - voltaje de circuito abierto (V_{oc}) 38.17 V,
 - Corriente de corto circuito (I_{sc}) 9.18 A,
 - Potencia máxima 270 W,
 - Dimensiones: 165.2 x 91 cm.



Figura 21. Panel fotovoltaico de la marca JA Solar.

- 2 Paneles fotovoltaicos marca Condumex
 - Voltaje de circuito abierto (v_{oc}) 21 V,
 - Corriente de corto-circuito (I_{sc}) 5.07 A,
 - Potencia máxima 75 W,
 - Dimensiones: 108 x 67 cm.



Figura 22. Panel fotovoltaico de la marca Condumex.

- 8 Paneles fotovoltaicos marca SunTech.
 - Voltaje de circuito abierto (v_{oc}) 44.2 V,
 - Corriente de corto-circuito (I_{sc}) 5.2 A,
 - Potencia máxima 175 W,
 - Dimensiones: 158 x 80 cm.



Figura 23. Panel fotovoltaico de la marca SunTech.

- Filtro pasa largo *Midwest Optical System dark red LP 645 nm.*
- Filtro pasa largo *Midwest Optical System dark red LP 665 nm.*
- Filtro pasa largo *Midwest Optical System NI LP 830 nm.*



Figura 24. Filtros ópticos pasa largo utilizados durante las pruebas de EL.

Un filtro pasa largo es un filtro que mediante interferencia óptica o de vidrio coloreado atenúa longitudes de onda más cortas y transmite (deja pasar) las longitudes de onda más largas sobre el rango activo del espectro objetivo (ultravioleta, visible o infrarrojo).




Figura 25. Gráfica de la respuesta de los filtros pasa largo utilizados.

■ Estructura de montaje de la Cámara




Figura 26. Estructura de aluminio utilizada durante el desarrollo del proyecto.

■ Cámara ASI178MM Monocromática ZWO.

Algunas de sus principales características son las siguientes:

- Sensor de 1/1.8" sensible al NIR,

- Resolución: 3096x2080 pixeles,
- 30 fps con ADC de 14 bit o 60 fps con ADC de 10 bit usando la resolución total,
- Posibilidad de larga exposición de hasta 1000 segundos.



Figura 27. Cámara de uso astronómico ASI178MM.




Figura 28. Curva de respuesta espectral de la cámara ASI178MM.

■ Tarjeta de video NVIDIA Gigabyte GeForce GTX1660

- *Base Clock*: 1530 MHz.
- *Memory Clock*: 2001 MHz.
- *Memory size*: 6 GB.
- *Memory type*: GDDR5 con soporte CUDA core.

- *Memory bus*: 192 bit.
- *Bandwidth*: 191.1 GB/s.



Figura 29. Tarjeta de video utilizada para el entrenamiento de la red neuronal.

3.2. Procesamiento

3.2.1. Distorsión en imágenes

La distorsión en fotografía, son aquellas deformaciones ópticas de la imagen causadas por el objetivo empleado, y que diferencian la imagen capturada de lo que realmente había delante de la cámara en el momento de generar la imagen. La distorsión es algo que se busca evitar, sin embargo cualquier sistema de tratamiento de señales o imágenes va a introducir en menor o mayor medida cierta porción de distorsión. En el caso de las imágenes estas distorsiones son más evidentes, cuanto más nos acerquemos a los bordes de la imagen, y en la parte central, por lo general, se encuentra libre de estos defectos ópticos.

3.2.2. Distorsión de barril

La distorsión de barril es la más común y suele darse por lo general en distancias focales cortas, como sucede con la lente Cinegon de la figura 20. Como su propio nombre indica, se trata del abombamiento de la imagen de tal modo que las líneas situadas en los extremos del encuadre aparentarán una curvatura. Puesto que este defecto óptico se suele dar sobre todo en objetivos angulares; al ser éstos empleados

habitualmente para paisajes, es probable notar la distorsión de barril de una manera sencilla. También se suele dar habitualmente en la posición de gran angular de las cámaras compactas como en la cámara utilizada en la adquisición de las imágenes de electroluminiscencia.

3.2.3. Calibración de las imágenes adquiridas con la cámara ASI178MM monocromática ZWO

La calibración una cámara es una técnica utilizada para mejorar la calidad de las imágenes capturadas haciendo una corrección de la distorsión. Por lo que el uso de una cámara calibrada es un componente esencial en aplicaciones como la visión artificial, puesto que permite medir el tamaño real de los objetos. La calibración de una cámara implica determinar sus características que se dividen en: parámetros intrínsecos y extrínsecos. Los parámetros intrínsecos definen las características internas de la cámara, como la distancia focal del objetivo, el centro óptico y los coeficientes de distorsión del objetivo. El hecho de conocer estos parámetros nos permite mejorar la calidad de la imagen corrigiendo la distorsión de la lente. Por otra parte, los parámetros extrínsecos definen la ubicación de la cámara en el espacio con referencia a un objeto fijo.

Para disminuir la distorsión en las imágenes, se utilizó un algoritmo desarrollado en MATLAB. En primer lugar el algoritmo pide de entrada imágenes de un tablero de ajedrez, esto se realiza para que el algoritmo detecte un cierto patrón y de esta manera el patrón de reconocimiento sea más sencillo de visualizar. Es necesario conocer el tamaño en milímetros de los cuadrados que conforman el tablero de ajedrez, ya que se requiere para encontrar la correspondencia entre las unidades y los píxeles de la imagen. En la figura 30, se muestra una forma de obtenerlo por medio del algoritmo desarrollado, la detección del patrón de calibración del tablero de ajedrez es automática y el reconocimiento de los puntos detectados es por medio de los vértices de los cuadrados.




Figura 30. Detección de los cuadrados del tablero de ajedrez.

Una vez realizada la calibración por medio de la localización de los vértices y la extracción de los parámetros intrínsecos y extrínsecos de las imágenes, se pueden evaluar los resultados que son almacenados. Estos parámetros extraídos son la diferencia entre los puntos detectados en la imagen y los puntos reproyectados. Se realiza por medio de una interpolación lineal que se basa en los parámetros de la base de datos generada con las imágenes introducidas al sistema. Los datos obtenidos anteriormente, se visualizan en la figura 31, en la cuál se muestran en un plano tridimensional la superposición de las imágenes utilizadas.

Visualización de los parámetros extrínsecos de las imágenes de calibración




Figura 31. Localización de las imágenes utilizadas.

La función de calibración que fue utilizada, realiza una interpolación lineal que se puede representar con el polinomio de interpolación de Newton que logra aproximar un valor de la función $f(x)$ (imagen) en un valor desconocido de x (píxeles del cuadrado) entre los puntos más cercanos de la imagen. El algoritmo se encarga de ir aproximando los cuadrados detectados en cada imagen de acuerdo con los puntos detectados en cada imagen, en la figura 32, se puede observar el error medio de píxeles en cada imagen.




Figura 32. Error medio en píxeles de las imágenes utilizadas para las pruebas de distorsión.

Ya obtenidos los parámetros intrínsecos, extrínsecos y los resultados anteriores, fue necesario aplicarlos en el algoritmo para visualizar la distorsión que presentaba la imagen, a continuación se muestra la mejora que se obtuvo con el procesamiento de las imágenes.



Figura 33. Comparación entre la imagen original y corregida.




Figura 34. Resta entre la imagen original y corregida.

El algoritmo creado ayudó a minimizar en gran parte el efecto de la distorsión de barril generada al usar la lente Cinegon 2.1/6, en algunos casos la distorsión de barril no es tan evidente, por lo que dependerá también de las condiciones en la que sean adquiridas las imágenes. En la figura 34, se muestra la diferencia entre los pixeles de la imagen original contra los de la imagen corregida, mostrándonos una imagen en la cuál entre más blanco sea el color del pixel nos indica una mayor error. Cabe señalar que la parte en la que se presentó menor distorsión fue en el centro de la imagen, y la parte con mayor distorsión se presentó en los extremos de las imágenes.




Figura 35. Disminución de la distorsión.

Se realizó una prueba poniendo el tablero de ajedrez en la parte central de la imagen y se obtuvo el resultado presentado en la figura 35. Podemos notar que la imagen esta casi completamente negra, esto significa que al calcular la diferencia de los pi-

xeles entre la imagen original y la corregida es casi cero, por lo que podemos deducir que las imágenes capturadas en el centro con la cámara ASI178MM Monocromática ZWO presentarán una distorsión mínima. La prueba se realizó para cada una de las 5 imágenes, el número que se muestra en la columna Imagen en la tabla 2, indica el número de imagen en la base de datos actual para la prueba de la distorsión de barril.

- Imagen 1: Tablero de ajedrez en la esquina superior izquierda de la imagen.
- Imagen 2: Tablero de ajedrez en el centro de la imagen.
- Imagen 3: Tablero de ajedrez en la esquina superior derecha de la imagen
- Imagen 4: Tablero de ajedrez en la esquina inferior derecha de la imagen.
- Imagen 5: Tablero de ajedrez en la esquina inferior izquierda de la imagen.

Tabla 2. Área del cuadrado del tablero del ajedrez con la imagen cruda.

Imagen	Area (pixeles)	Centroide [x,y]	Dimensión [x,y,ancho,altura]
1	1352	[362.74,246.98]	[343.5,228.5,39,37]
	1205	[241.99,361.64]	[222.5,343.5,37,36]
2	1529	[801.81,543.1]	[781.5,523.5,40,40]
	1554	[925.122,663.54]	[903.5,643.5,43,40]
3	1368	[1148.79,285.07]	[1129.5,265.5,38,39]
	1353	[1260.79,410.78]	[1241.5,390.5,38,40]
4	1379	[1161.80,662.51]	[1142.5,642.5,38,39]
	1209	[1271.67,787.76]	[1254.5,768.5,34,38]
5	1491	[354.286,621.63]	[334.5,601.5,40,41]
	1367	[232.85,734.31]	[212.5,714.5,39,40]

Tabla 3. Área del cuadrado del tablero del ajedrez con la imagen procesada.

Imagen	Área (pixeles)	Centroide [x,y]	Dimensión [x,y,ancho,altura]
1	1372	[357.36,242.51]	[338.5,223.5,38,38]
	1257	[233.24,358.58]	[213.5, 340.5,38,36]
2	1530	[801.82,543.13]	[781.5, 523.5,40,40]
	1559	[681.91,667.33]	[661.5, 646.5,41,41]
3	1435	[1154.23,281.39]	[1134.5, 261.5,39,40]
	1430	[1269.40,408.49]	[1249.5, 388.5,39,40]
4	1508	[1166.40,663.58]	[1146.5, 643.5,40,40]
	1470	[1282.22,792.00]	[1262.5, 771.50,39,41]
5	1536	[350.63,622.26]	[330.5, 601.50,41,41]
	1464	[271.29,618.06]	[251.5, 598.5,40,40]

Los valores presentados en la tabla 2 y 3 se extrajeron del cuadrado central del tablero de ajedrez y el cuadrado más lejano del centro de cada imagen, es por esto que se cuenta con 2 valores de área, centroide y dimensión del cuadrado procesado. Podemos notar que el área del cuadrado procesado es mayor y sus dimensiones son más parecidas a las de un cuadrado. Comparando los valores de cada imagen podemos observar que la imagen 2 presentó una menor distorsión, ya que la adquisición de la imagen fue justo debajo de la cámara y la distorsión era prácticamente nula. En cambio, la mayor distorsión fue en la imagen 4, la cuál contaba con una cantidad menor de pixeles, la tabla 5 muestra el porcentaje de distorsión de cada imagen.

Tabla 4. Relación cuantificada entre la imagen sin corrección y la imagen corregida por medio de la proporción del tamaño de sus cuadrados.

Imagen	Posición	Razón sin corrección	Razón con corrección
1	1	0.9782	0.9032
	2	0.958	0.8062
2	1	0.9993	1
	2	0.9967	1
3	1	0.9533	0.9379
	2	0.9461	0.9172
4	1	0.9144	0.9856
	2	0.8224	0.9429
5	1	0.9770	0.9973
	2	0.9337	0.9390

Tabla 5. Distorsión de la imagen original obtenida.

Imagen	Distorsión [%]
1	1.45
2	0.06
3	4.66
4	8.55
5	2.92

La ecuación utilizada para calcular la distorsión de las imágenes es la siguiente:

$$Distorsion_{img(i)}[\%] = 100 \times \frac{img_{corregida(i)} - img_{cruda(i)}}{img_{corregida(i)}} \quad (1)$$

Al haber realizado estas pruebas, se pudo demostrar que las imágenes adquiridas no afectarían el procesamiento de las imágenes de EL.

3.3. Adquisición de las imágenes de electroluminiscencia

Para la adquisición de las imágenes de EL se montó la cámara ASI178MM en una estructura de pruebas de bajo costo para paneles fotovoltaicos, como se puede observar en la figura 36, la estructura cuenta con rieles que se ajustan al tamaño del panel fotovoltaico en estudio, y también permite un movimiento en el vertical y horizontal para modificar la posición de la cámara.




Figura 36. Estructura ajustable para prueba de PF.

A continuación, se enlistan los pasos realizados para la adquisición de imágenes:

1. Identificar las fuentes de luz en el laboratorio y minimizarlas. Las pruebas fueron realizadas en la noche con la menor cantidad de luz externa posible y cubriendo las ventanas, limitando las fuentes de luz dentro del laboratorio de pruebas.
2. Montar la cámara en la estructura en una posición estable y adecuada para la toma de imágenes.

3. Instalar sobre la base de la estructura el PF para mantenerlo fijo y adecuadamente situado.
4. Conectar los cables MC4 al panel fotovoltaico y a una fuente de 30 V @3 A, además ajustar los parámetros de adquisición de la imagen en la aplicación de la computadora.




Figura 37. Ajuste de los parámetros a utilizar

5. Realizar la toma de las imágenes de EL con las luces apagadas y con el tiempo de exposición deseado, el cuál varía dependiendo de la calidad y tipo del panel fotovoltaico.
6. Deslizar el panel fotovoltaico a las diferentes posiciones después del tiempo de exposición definido para la captura de cada imagen y cada una de las celdas del PF.

Las pruebas se realizaron con diferentes tiempos de exposición que van desde los 70 hasta los 120 segundos por cada imagen de electroluminiscencia. El motivo de esta prueba fue conocer el comportamiento de las unidades arbitrarias que conforman el histograma de la foto, ya que se tiene que escoger un tiempo de exposición óptimo en el cuál se aprovechara la mayor cantidad del intervalo dinámico de la imagen sin que llegara a saturarse.

3.3.1. Preprocesamiento de las imágenes EL

La adquisición de cada imagen de EL tuvo una duración estimada de 120 a 240 segundos. Una vez que se adquirieron las imágenes de todos los PF se procedió a realizar un preprocesamiento de las mismas. Cuando se trabaja con tiempos de exposición altos pueden aparecer ciertas perturbaciones en algunos pixeles de la imagen: ruido y pixeles calientes, los cuáles son pixeles blancos que se generan por un sobrecalentamiento del sensor de la cámara. De tal forma que resulta necesario realizar un tratamiento a la imagen con el objetivo de mejorar la calidad de la imagen y disminuir el ruido y los pixeles calientes.




Figura 38. Imagen con ruido y pixeles calientes.

En el presente proyecto se mejoró la calidad de la imagen eliminando cierto ruido ya mencionado, el cuál puede ser generado por la cámara, ya sea por las condiciones ambientales y/o debido al calentamiento del sensor por tiempos largos de exposición. Para ello, fue necesario adquirir un tipo de imágenes que se utilizan en la astronomía, estas son llamadas *bias* y *dark*. Luego se procedió a realizar un tratamiento a la imagen *light* (imagen del panel fotovoltaico) el cuál se basa en una restarle a la imagen original las imágenes *bias* y *dark*.




Figura 39. Ruido obtenido del sensor para cada pixel.

- Imagen *bias*: muestra el ruido de lectura del sensor para cada pixel. Sus características son:
 - Para la obtención de la imagen, primero el sensor de la cámara se debe exponer a temperatura ambiente.
 - Las imágenes deben ser tomadas en un lugar sin luz con la cámara cubierta.
 - El tiempo de exposición se debe configurar al mínimo de la cámara en uso, para este trabajo se tuvo un tiempo de exposición de $32\mu s$.
 - Se deben tomar de 50 a 100 imágenes para obtener un promedio del ruido del sensor para cada pixel.




Figura 40. Ruido obtenido por largos tiempos de exposición.

- Imagen *dark*: se refiere al ruido obtenido por largos tiempos de exposición, el cuál produce errores por la temperatura del sensor. Sus características son:
 - Para la obtención de la imagen, el sensor de la cámara se debe exponer a temperatura ambiente.
 - Las imágenes deben ser tomadas en un lugar sin luz con la cámara cubierta.
 - Se usan los mismos parámetros y tiempo de exposición que se utilizan en la adquisición de fotos.
 - Se deben tomar de 20 a 50 imágenes para obtener un promedio del ruido obtenido por los largos tiempos de exposición.

El procedimiento mostrado en la figura 41 fue utilizado en todos los elementos que conforman la base de datos de imágenes de electroluminiscencia, para mejorar la calidad de imagen y la base de datos en general.




Figura 41. Diagrama de la compensación de la imagen y mejora de la calidad.

La expresión matemática utilizada para la compensación en las imágenes de EL es la siguiente:

$$Img_{comp} = Img_{org} - \left(\frac{\sum_{i=0}^N Darks(i)}{N} + \frac{\sum_{i=0}^M Bias(i)}{M} \right), \quad (2)$$

donde Img_{comp} es la imagen compensada, Img_{org} es la imagen original, M es la cantidad total de imágenes *bias* y N es la cantidad total de imágenes *dark*.

Una vez preprocesadas las imágenes de EL se realizó una prueba para comparar la imagen original y la imagen compensada.




Imagen original

Imagen compensada

Figura 42. Comparación de la imagen EL original y la imagen EL compensada.

En la figura 42, se muestra la comparación entre la imagen original contra la compensada. En ella se puede observar notablemente una mejora en el contraste de la imagen que se debe al tratamiento realizado de las imágenes de EL. También podemos notar una disminución de píxeles calientes en la imagen y el ruido producido por los largos tiempos de exposición. En el histograma mostrado en la figura 43, nos muestra una de forma gráfica la distribución de los píxeles de la imagen compensada, en la que el rango dinámico de los valores de intensidad de las imagen esta mejor distribuido, comparado con la imagen original. También el corrimiento del histograma hacia la izquierda es observable, y nos ayuda a tener más tonalidades de los píxeles en escala de grises que será de gran ayuda al momento del entrenamiento del clasificador de imágenes de EL.




Figura 43. Comparación del histograma de la imagen de EL compensada y original.

Es necesario recortar las imágenes de los paneles fotovoltaicos ya que la clasificación en este trabajo se realiza a nivel de las celdas. En este caso se desarrolló un algoritmo para realizar el recorte automático de las celdas en todas las imágenes de paneles fotovoltaicos.




Figura 44. Representación gráfica del proceso de compensación y recorte.

En la figura 44, podemos observar un diagrama que nos muestra los pasos principales para recortar las celdas fotovoltaicas.

Una vez las imágenes son procesadas se realizan los siguientes pasos para el re-

corte de las celdas fotovoltaicas (los parámetros para la extracción de las imágenes varían dependiendo del tipo de panel fotovoltaico).

1. Se ubica la celda fotovoltaica objetivo por medio de coordenadas dadas en pixeles, las coordenadas varían dependiendo de la resolución de la imagen.
2. Se procede a conocer el tamaño de la celda por medio del ancho y largo, así como el tamaño de la zona que aísla cada celda, estos parámetros son clave para conocer el desplazamiento del recorte de las celdas que tendrá en su eje horizontal y vertical.
3. Una vez conocidos todos los parámetros se procede a realizar el recorte automático, en la salida del algoritmo se obtienen las celdas recortadas y redimensionadas a un tamaño de 224x224x1 pixeles.




Figura 45. Recorte de las celdas fotovoltaicas automáticamente.

3.4. Pruebas de funcionamiento del panel fotovoltaico

Es necesario estar consciente del método y de las partes más importantes que se necesitan para realizar un proyecto de una forma correcta y estructurada, es por esto que recurrimos a representar de una forma gráfica las etapas del proyecto. Un diagrama de flujo es una herramienta que nos ayuda a describir los pasos de un proyecto y visualizar fácilmente las actividades a realizar, a continuación se muestra una descripción del diagrama de este trabajo:




Figura 46. Diagrama de flujo del algoritmo de procesamiento y clasificación.

- **Adquisición de la imagen:** se presenta el tipo de cámara utilizada y las herramientas que facilitaron la adquisición de las imágenes EL.
- **Procesamiento de las imágenes:** se mencionan las manipulaciones hechas en la imagen original y los resultados obtenidos al procesar la base de datos.

- **Entrenamiento del clasificador:** se despliega el modelo de inteligencia artificial desarrollado, así como la estructura del modelo y su respuesta.
- **Clasificación de las imágenes EL y toma de decisiones:** se presentan los resultados del entrenamiento del sistema, tomando en cuenta su precisión y su pérdida de entrenamiento.

3.4.1. Bases de datos

En el presente trabajo se utilizaron 846 imágenes adquiridas, con las que se realizaron las pruebas para conformar la base de datos. Se decidió crear en primer instancia un clasificador binario, el cuál identificaría si la celda fotovoltaica estaba en dañado o en buen estado. Todas las celdas de la base de datos fueron analizadas y divididas entre los dos tipos de clases, por lo que la base de datos cuenta con las siguientes clases:

- 630 (74.47 %) imágenes de las celdas fotovoltaicas están en buen estado.
- 216 (25.53 %) imágenes de las celdas fotovoltaicas presentan daños.




Figura 47. Celda fotovoltaica en buen estado.

Las celdas fotovoltaicas en buen estado están definidas de la siguiente forma:

- Celda sin defectos: al momento de aplicar el efecto de electroluminiscencia, la celda responde de una manera en la cuál la luz infrarroja hace que toda la celda sea visible y ninguna zona tenga partes oscuras (como se puede observar en la figura 47).
- Defectos mínimos: engloba los daños por manejo y microgrietas en la celda fotovoltaica.




Figura 48. Celda fotovoltaica dañada.

Las celdas fotovoltaicas dañadas se diferencian por:

- Daños parciales: Defectos que conlleven a desconexiones, fracturas y celdas completamente oscuras (como se puede visualizar en la figura 48).

Ya que se separaron las imágenes en las dos clases mencionadas, se pudo apreciar que había una cantidad de imágenes en buen estado casi tres veces mayor en comparación de las celdas dañadas. Se propuso realizar un balanceo en la base de datos, se basa en reducir la cantidad de imágenes de cada tipo que conforman nuestra base de datos hasta tener la misma proporción de imágenes para cada clase. El realizar el balanceo nos ayuda a disminuir la posibilidad de que la red neuronal funcione favoreciendo la predicción hacía una sola clase, lo que podría llegar a ocasionar resultados dudosos.

Se realizaron tres bases de datos a partir de la base de datos original:

■ **Base de datos balanceada:**

- Cuenta con 216 imágenes de celdas en buen estado.
- Cuenta con 216 imágenes de celdas dañadas.
- Tamaño del conjunto de entrenamiento y validación: se utiliza el 90 % de los datos para entrenar la red y 10 % para la validación.
- Resolución de la imagen de entrada: la imagen de entrada es de 224x224 píxeles.

■ **Base de datos sin balanceo:**

- Cuenta con 630 imágenes de celdas en buen estado.
- Cuenta con 216 imágenes de celdas dañadas.

■ **Base de datos extendida**

- Cuenta con 1580 imágenes de celdas en buen estado.
- Cuenta con 528 imágenes de celdas dañadas.
- Cuenta con 1278 imágenes de celdas en estado aceptable.

La base de datos pública utilizada para crear la base de datos extendida consta 2,624 imágenes de electroluminiscencia, cuenta con celdas fotovoltaicas en buen estado, aceptables y dañadas, esta base de datos se encuentra en internet y puede ser utilizada libremente en estudios científicos sin fines de lucro (Buerhop-Lutz et al., 2018; Deitsch et al., 2019, 2021).

Capítulo 4. Clasificación de imágenes de electroluminiscencia

4.1. Fundamentos matemáticos de las redes neuronales

4.1.1. Perceptrón

La red neuronal más sencilla es un perceptrón, desarrollado por primera vez por Frank Rosenblatt en 1958 (Bishop and Nasrabadi, 2006).

Un perceptrón tiene una neurona y una salida, para cada entrada se multiplica el valor de entrada x_i con los coeficientes ponderados (pesos) w_i y se realiza una suma de todos los productos. Por lo que los pesos representan la fuerza de la conexión entre las neuronas y determina la influencia que tendrá la entrada dada en la salida de la neurona. Los vectores de las entradas y los coeficientes ponderados son $\mathbf{x} = [x_1, x_2, \dots, x_n]$ y $\mathbf{w} = [w_1, w_2, \dots, w_n]$ respectivamente, su producto punto se expresa con la siguiente ecuación:

$$\mathbf{x} \cdot \mathbf{w} = (x_1 w_1) + (x_2 w_2) + \dots + (x_n w_n) \quad (3)$$

Después se le añade un sesgo (b) a la suma de los valores multiplicados anteriormente, donde llamaremos a la nueva variable z . El sesgo también conocido como *offset* o *bias*, es necesario para el ajuste de la función de activación, ya que se encarga de transmitir los datos generados por la combinación lineal de los pesos y las entradas de la red, generando así, una salida.

$$z = \mathbf{x} \cdot \mathbf{w} + b \quad (4)$$

El valor de z se agrega a una función de activación escogida para la red neuronal.

$$\hat{y} = \sigma(z) = \frac{1}{1 + e^{-z}}, \quad (5)$$

donde σ es la función de activación y la salida que se obtiene de la propagación hacia adelante es decir, el valor predicho $\hat{y}$.

4.1.2. Algoritmo de aprendizaje automático

Un algoritmo de aprendizaje automático consta de dos partes; retropropagación y el optimizador (en este proyecto se utilizó Adadelata), según lo reportan Lydia and Francis (2019). La retropropagación (en inglés conocida como *backpropagation*) se refiere al algoritmo utilizado para calcular el gradiente de la función de pérdida con respecto a los coeficientes ponderados (Hart et al., 2000). Para conocer una estimación de lo lejos que estamos de nuestra solución deseada se utiliza una función de pérdida, generalmente, se suele usar el error medio cuadrático para los problemas de regresión, y la entropía cruzada para los problemas de clasificación.

Si tomamos un problema de regresión cuya función de pérdida sea el error medio cuadrático, que corresponde al cuadrado de la diferencia entre el valor real (y_i) y el predicho ($\hat{y}_i$).

$$MSE_i = (y_i - \hat{y}_i)^2 \quad (6)$$

Para el cálculo de la función de pérdida se toma toda la base de datos de entrenamiento que usualmente es conocida como la función de coste C .

$$C = MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

Para conocer los mejores valores de nuestros coeficientes ponderados y sesgos para el perceptrón es necesario conocer el comportamiento de la función de coste en relación a $\mathbf{x}$ y $\mathbf{w}$, es necesario conocer gradiente descendiente, ya que nos ayuda a conocer el comportamiento ya mencionado. El gradiente de la función de coste se calcula utilizando la regla de la cadena.

$$\frac{\partial C}{\partial w_i} = \left(\frac{\partial C}{\partial \hat{y}} \right) \left(\frac{\partial \hat{y}}{\partial z} \right) \left(\frac{\partial z}{\partial w_i} \right) \quad (8)$$

Ahora se necesitan conocer los tres gradientes de la función.

$$\frac{\partial C}{\partial w_i} = ? \quad \frac{\partial \hat{y}}{\partial z} = ? \quad \frac{\partial z}{\partial w_1} = ? \quad (9)$$

Para obtener el gradiente de la función de coste respecto al valor predicho se evalúa la siguiente ecuación:

$$\frac{\partial C}{\partial \hat{y}} = \frac{\partial}{\partial \hat{y}} \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 2x \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (10)$$

Por lo que tenemos de forma simplificada lo siguiente:

$$\frac{\partial C}{\partial \hat{y}} = \frac{2}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (11)$$

Una vez encontrado el primer gradiente, procedemos a obtener el gradiente del valor predicho respecto a z .

$$\frac{\partial \hat{y}}{\partial z} = \frac{\partial}{\partial z} \sigma(z) = \frac{\partial}{\partial z} \frac{1}{1 + e^{-z}} = \frac{e^{-z}}{(1 + e^{-z})^2} = \frac{1}{1 + e^{-z}} \frac{e^{-z}}{(1 + e^{-z})} \quad (12)$$

$$\frac{\partial \hat{y}}{\partial z} = \frac{\partial}{\partial z} \sigma(z) = \frac{1}{1 + e^{-z}} \left(1 - \frac{1}{(1 + e^{-z})} \right) = \sigma(z)(1 - \sigma(z)) \quad (13)$$

Ahora solo falta obtener el gradiente z respecto al coeficiente ponderado w_i .

$$\frac{\partial z}{\partial w_i} = \frac{\partial}{\partial w_i} (z) = \frac{\partial}{\partial w_i} \sum_{i=1}^n (x_i \cdot w_i + b) = x_i \quad (14)$$

Entonces obtenemos:

$$\frac{\partial C}{\partial w_i} = \frac{2}{n} \sum_{i=1}^n (y_i - \hat{y}_i)(\sigma(z))(1 - \sigma(z))(x_i) \quad (15)$$

Una vez que se conocen los tres gradientes podemos optimizar nuestro modelo, se basa en elegir el mejor elemento dentro de un conjunto de datos, en nuestro caso

serían los coeficientes ponderados y los sesgos del perceptrón, el método mas comúnmente utilizado es el del gradiente descendiente que funciona como algoritmo para optimizar la red.

$$w_i = w_i - \left(\alpha \frac{\partial C}{\partial w_i} \right) \quad (16)$$

$$b = b - \left(\alpha \frac{\partial C}{\partial b} \right) \quad (17)$$

Para más información sobre los fundamentos matemáticos en redes neuronales revisar las siguientes referencias (Bishop and Nasrabadi, 2006) y (Hart et al., 2000).

4.2. Redes neuronales convolucionales (CNN)

Son un tipo de redes neuronales artificiales donde las neuronas corresponden a campos receptivos de una manera muy similar a las conexiones neuronales de un cerebro, su aplicación es realizada a través de matrices bidimensionales, las cuáles permiten manipular la información de las conexiones neuronales, son muy efectivas para tareas de visión artificial, como en la clasificación y segmentación de imágenes, entre otras. El sistema puede contar con una o más entradas (ver figura 49), dependiendo de su aplicación y complejidad, estas redes consisten en múltiples capas de filtros convolucionales de una o más dimensiones. Después de cada capa, por lo general se añade una función para realizar un mapeo causal no-lineal (O'Shea and Nash, 2015).




Figura 49. Comportamiento de las neuronas en la red (O'Shea and Nash, 2015).

Como cualquier red empleada para clasificación, al principio estas redes tienen una fase de extracción de características, compuesta de neuronas convolucionales, luego hay una reducción por muestreo y al final tendremos neuronas de perceptrón más sencillas para realizar la clasificación final sobre las características extraídas. La fase de extracción de características se compone de capas alternas de neuronas convolucionales y neuronas de reducción de muestreo. Según progresan los datos a lo largo de esta fase, se disminuye su dimensión, siendo que las neuronas localizadas en capas lejanas resultan mucho menos sensibles a perturbaciones en los datos de entrada, pero al mismo tiempo estas son activadas por características cada vez más complejas, para ello necesitan entrenarse previamente con una cantidad importante de muestras. De esta forma, las neuronas de la red van a poder captar las características únicas de cada objeto y a su vez, poder generalizarlo, esto es lo que se conoce como el proceso de aprendizaje del algoritmo.

La red va a poder reconocer un cierto patrón porque ya había sido visualizado anteriormente, pero no solo buscará estos patrones en neuronas semejantes, sino que podrá inferir en imágenes que no conozca y que relaciona en donde podrían existir similitudes. Todo comienza con el análisis de la imagen, se puede representar una imagen como una matriz de píxeles y dependiendo la cantidad de bits de profundidad de la imagen dependerá el valor de cada píxel en la imagen, estos valores son normalizados para la red neuronal en una escala de 0 a 1 (ver la figura 50). La red toma como entrada los píxeles de una imagen. Si tenemos una imagen con apenas 224×224 píxeles de alto y ancho, esto equivale a utilizar 50,176 neuronas (cada píxel es una neurona de la red), considerando si sólo tenemos 1 color (escala de grises), como se puede observar en la figura 50. Si se tiene una imagen a color como se muestra en la figura 51, se requieren 3 canales RGB (*Red, Green, Blue*) y entonces se usan $224 \times 224 \times 3 = 150,528$ neuronas que constituyen la capa de entrada. En este caso para el preprocesamiento de la red neuronal se necesitaría normalizar los valores de los píxeles de cada canal, para una imagen de 8 bits, el valor de intensidad de los píxeles debería ser dividido entre 255.




Figura 50. Representación de una imagen de 8 bits monocromática con sus valores matriciales normalizados (Barrios, 2022).




Figura 51. Representación de una imagen de 8 bits con 3 canales con sus valores matriciales normalizados (Barrios, 2022).

4.3. Arquitectura de una CNN

- **Capa de entrada:** toma en cuenta la resolución en píxeles de la imagen, considerando el ancho, largo y los canales de color de la imagen a procesar (Barrios, 2022).
- **Capa de convolución:** Procesará la salida de neuronas que están conectadas en la capa de entrada, calculando el producto escalar entre sus pesos y una pequeña región a la que están conectados las neuronas (Barrios, 2022).

- **Capa de filtros:** En esta parte se definen los filtros que submuestrearán la imagen de entrada (Barrios, 2022).
- **Función de activación:** transmite la información de las neuronas por la combinación lineal de los pesos y las entradas como una salida de información (He et al., 2018).
- **Muestreo:** Hará una reducción en las dimensiones alto y ancho, pero se mantiene la profundidad, manteniendo ciertas características de la imagen de entrada (Barrios, 2022).
- **Capa de salida:** en esta capa se conectan todas las neuronas durante el aprendizaje de la red neuronal convolucional, se entregan los resultados en un vector unidimensional y se procede a generar el modelo de predicción de la red en base a los resultados anteriores. (Barrios, 2022).

En la figura 52 se presenta una representación gráfica de una red neuronal convolucional.




Figura 52. Arquitectura de una red neuronal convolucional.

4.4. Filtros, convoluciones y función de activación

El *kernel* en las redes neuronales convolucionales se considera como el filtro que se aplica a una imagen para extraer ciertas características importantes o patrones de la imagen a convolucionar, consisten en ir muestreando una imagen y realizar un producto escalar entre la imagen de entrada y una matriz propuesta. Supongamos que un *kernel* tiene un tamaño de 3×3 píxeles (ver figura 53) y se calcula su producto

escalar con todas las neuronas generadas con la imagen de entrada, este proceso sigue una secuencia (de izquierda-derecha, de arriba-abajo), ya que se muestrea toda la imagen, se obtiene una nueva matriz de salida.




Figura 53. Visualización del *kernel* y la imagen (Barrios, 2022).

Un *kernel* puede ser usado para detectar bordes y enfocarse en regiones o patrones específicos. Esto se logra al realizar la convolución entre la imagen y el kernel (que generalmente tiene un tamaño menor), ésto se realiza solo con una porción de la imagen escogida, se realiza la multiplicación tal como indica la figura 54 y luego el *kernel* se va desplazando de forma iterativa. Si la dimensión del kernel no cumple con las de la imagen suele aplicarse un relleno de la matriz llamado *padding*, consiste en rellenar la dimensión de la matriz con ceros. En la figura 54 se muestra un ejemplo de convolución usando un *kernel*, las ilustraciones están en Barrios (2022).




Figura 54. Ejemplo de la convolución entre la imagen y el *kernel*.

Posteriormente se desplaza el *kernel* sobre la imagen y se realiza el mismo producto escalar con cada uno de los elementos de la matriz de la misma forma (ver figura 55).


3	0	1	2	7	4
1	5	8	9	3	1
2	7	2	5	1	3
0	1	3	1	7	8
4	2	1	6	2	8
2	4	5	2	3	9

$*$

-1	0	1
-1	0	1
-1	0	1

$=$

5	4		



IMAGEN

KERNEL

MATRIZ RESULTANTE

Figura 55. Segunda iteración de la convolución.

Este proceso se realiza sucesivamente hasta completar toda la matriz que conforma el filtro, como se puede apreciar en la figura 56. Se puede tener una gran cantidad de filtros, que dependerán del tamaño de la imagen y *kernel* a utilizar.


3	0	1	2	7	4
1	5	8	9	3	1
2	7	2	5	1	3
0	1	3	1	7	8
4	2	1	6	2	8
2	4	5	2	3	9

$*$

-1	0	1
-1	0	1
-1	0	1

$=$

5	4	0	-8
10	2	-2	-3
0	2	4	7
3	2	3	16



IMAGEN

KERNEL

MATRIZ RESULTANTE

Figura 56. Matriz del filtro convolucionada.

Una vez que ya se realizó la convolución del *kernel* con la imagen se procede a usar una función de activación como se muestra en la figura 57. Por lo general se emplea la función de unidad lineal rectificadora (ReLU) donde $R(z) = \max(0, z)$.




Figura 57. Comportamiento de la función de activación ReLU (He et al., 2018).

Al aplicar la función ReLU sobre el filtro resultante se obtienen los siguientes cambios de valores de la matriz:




Figura 58. Aplicación de ReLU en la matriz final.

4.5. Muestreo, capa densa y capa de salida

En esta sección se describirá de forma general los componentes de las redes neuronales basadas en las arquitecturas AlexNet y VGG16.

Cuando la cantidad de neuronas es muy grande y se necesitan seguir realizando convoluciones, se procede a llevar a cabo un muestreo como estrategia de cálculo, donde se escogen las neuronas más representativas antes de hacer una nueva convolución, se toma el valor mayor del pixel del muestreo como una referencia, a esta técnica se le conoce como *Max-pooling2D* (Barrios, 2022). Existen diversos tipos de

muestreo, el más usado es el mencionado anteriormente, cuenta con un tamaño de 2x2 (tomando 2 pixeles de alto por 2 de ancho), esto quiere decir que mientras se va muestreando la imagen se va preservando el valor más alto entre los 4 pixeles (ver figura 59).




Figura 59. Técnica de *Maxpooling* utilizada a partir del ejemplo anterior.

La imagen resultante es reducida a la mitad y la cantidad de las neuronas es reducida a una cuarta parte, son bastantes menos neuronas y pero almacenan las características más importantes. Una vez terminados todos los cálculos numéricos y el submuestreo de *Max-Pooling* se procede a guardar la información en un vector unidimensional el cuál se conecta a distintas capas densas, que se encargan de conectar cada neurona en una capa con todas las salidas de la capa anterior. Al pasar por esta capa se pueden involucrar distintos procesos del tratamiento de las características obtenidas (como lo son el *dropout*, más capas densas, etc.), se debe tomar en cuenta que la salida del clasificador tiene que coincidir con la cantidad de clases del clasificador (Srivastava, 2013). En las figuras 60 y 61 se muestran la arquitecturas de redes neuronales de forma gráfica, en este caso se trata de las arquitecturas AlexNet y VGG16 las cuáles fueron usadas en este proyecto.

Se escogieron estos dos tipos de arquitecturas debido a que ya han sido utilizados en la tarea de visión por computadora y reconocimiento de imágenes con inteligencia artificial (Qassim et al., 2018). Cabe mencionar que éstas arquitecturas, han sido utilizadas con *ImageNet* que es una enorme base de datos con más de 14 millones de imágenes etiquetadas en más de 1000 clases y se han obtenido buenos resultados en el reconocimiento de diferentes tipos de imágenes usando redes neuronales convolucionales (Krizhevsky et al., 2017). Por lo que son las redes mas prácticas para realizar pruebas sobre la identificación de patrones y formas en un cierto tipo de imagen.




Figura 60. Arquitectura VGG16 de una red neuronal con 2 clases de salida.




Figura 61. Arquitectura AlexNet de una red neuronal con 2 clases de salida.

4.5.1. Comparación entre una red neuronal y una red neuronal convolucional

A continuación se presenta una pequeña comparación entre las características de dos tipos de redes neuronales, una tradicional frente a una convolucional.

Tabla 6. Comparación entre dos tipos de redes neuronales.

Características	Red neuronal tradicional	Red neuronal convolucional
Datos de entrada	Ancho, largo y canales.	Ancho, largo y canales.
Capas ocultas	Se define una cantidad de neuronas.	- Convoluciones. - Submuestreo.
Capa de salida	Se definen las clases de salida.	Se manipula la última capa de neuronas y se trata con funciones matemáticas.
Aprendizaje	Supervisado.	Supervisado.
Interconexiones	Entre cada capa.	Disminución de conexiones.
Backpropagation	Ajusta los pesos de todas las interconexiones de las capas.	Ajusta los pesos de los <i>kernels</i> .

4.6. *Transfer learning*

Es un método de aprendizaje automático en el que un modelo desarrollado para una tarea concreta, se puede usar como punto de partida para el desarrollo de otro modelo usado en otra tarea distinta de la primera (Tammina, 2019). Se trata de un enfoque popular dentro del aprendizaje profundo, se emplea como punto de partida en distintas tareas como la visión artificial. Permite ahorrar tiempo en tareas que necesitan muchos recursos informáticos y tiempo de desarrollo.

Existen dos enfoques comunes en el desarrollo de modelos con *transfer learning*:

- **Approach model:**

1. se crea un modelo de predicción para resolver un problema,
2. se construye el modelo fuente, a partir del cuál se desarrolla el modelo de reutilización, que aprovecha lo aprendido por el primer modelo para resolver otra tarea (Tammina, 2019),
3. se optimiza y corrigen posibles fallos que pueda contener el modelo desarrollado.

- **Pre-trained approach:** selecciona un modelo previamente entrenado. A partir de ahí, se desarrolla todo como el caso anterior (Tammina, 2019). Este tipo de *transfer learning* fue el que se utilizó en el proyecto.

4.7. Validación cruzada

La validación cruzada es una de las técnicas de muestreo de datos más populares para evaluar la calidad y el funcionamiento de un modelo predictivo y evitar el sobreajuste debido a una base de datos pequeña (Refaeilzadeh et al., 2009), es necesario realizarla durante el entrenamiento de la red, ya que, no hay forma de efectuar la técnica una vez se tiene el modelo final, es por esto que la validación cruzada se utiliza a lo largo de la fase de construcción del modelo, es decir, para estimar el funcionamiento del modelo cuando se introducen datos externos. La elección de características y datos suele ser un paso crucial en el proceso de creación del modelo, las características predictivas deben elegirse utilizando solo el conjunto de entrenamiento y no el conjunto de aprendizaje completo; de lo contrario, la estimación del error de pre-

dicción puede estar significativamente sesgada hacia una cierta clase del modelo de clasificación que se quiere predecir.

Considere que el conjunto de aprendizaje se divide en el conjunto de validación y de entrenamiento después de elegir las características predictivas en función del conjunto de aprendizaje completo como se muestra en la figura 62, se observa una validación cruzada de 10 iteraciones (*10-fold cross validation*, en inglés).




Figura 62. Ejemplo de una validación cruzada (Petkov et al., 2018).

Las 10 iteraciones de aprendizaje, se realizan variando el conjunto de datos de entrenamiento y validación y ayudan a trabajar con el 90 % de los datos en el conjunto de entrenamiento y el 10 % restante con el de validación, en cada iteración los conjuntos varían y cuentan con imágenes diferentes. Al realizar las 10 pruebas los resultados se promedian, en el caso del ejemplo y del proyecto se realizaron 10 iteraciones, la ecuación matemática utilizada es la siguiente:

$$E = \frac{1}{10} \sum_{i=1}^{10} E_i \quad (18)$$

4.8. Matriz de confusión y las métricas de rendimiento del modelo para dos clases

En el campo de la inteligencia artificial y en especial en el problema de la clasificación estadística, una matriz de confusión es una herramienta que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. Uno de los beneficios de las matrices de confusión es que permiten identificar fácilmente si el sistema está confundiendo dos clases. Si en los datos de entrada el número de muestras de clases diferentes varía mucho, la tasa de error del clasificador no será representativa de lo bien que el clasificador realiza la tarea. Por ejemplo, hay 900 muestras de la clase 0 (celdas dañadas) y sólo 100 de la clase 1 (celdas en buen estado), el clasificador puede tener fácilmente un sesgo hacia la clase 0. Si el clasificador clasifica todas las muestras como clase 0 su precisión será del 90 %. Sin embargo, esto no significa que sea un buen clasificador, debido a que tuvo un 100 % de error en la clasificación de las muestras de la clase 1. Por esto que se busca tener un valor equilibrado entre cada una de las clases.

Para el clasificador binario desarrollado en este proyecto, se propusieron solo dos tipos de clases que son las siguientes:

- Clase 0: Celdas fotovoltaicas dañadas.
- Clase 1: Celdas fotovoltaicas en buen estado.

Al usar la base de datos extendida ya mencionada anteriormente, nuestra cantidad de clases aumentó a tres y tuvo que realizarse un reetiquetado. De esta manera las clases quedaron de la siguiente forma:

- Clase 0: Celdas fotovoltaicas en estado aceptable.
- Clase 1: Celdas fotovoltaicas dañadas.
- Clase 2: Celdas fotovoltaicas en buen estado.

Existen cuatro métricas que se usan principalmente para evaluar el rendimiento del clasificador, las cuáles son las siguientes:

- Precisión.
- Sensitividad (*Recall*).
- Exactitud (*Accuracy*).
- Valor F1.

Estas métricas se calculan a partir de la matriz de confusión obtenida por el clasificador, al momento de evaluar un conjunto de imágenes. La figura 63 se presenta el ejemplo de una matriz de confusión.

Etiqueta verdadera	TN Dañado	164	52	FP
	Buen estado	3	213	TP
		Dañado	Buen estado	
		Etiqueta asignada		

Figura 63. Ejemplo de una matriz de confusión.

A continuación se muestra el significado sus siglas:

- **TN:** son las predicciones correctas negativas al momento de la predicción del clasificador
- **TP:** son las predicciones correctas positivas al momento de la predicción del clasificador.
- **FP:** son los falsos positivos al momento de la predicción del clasificador.
- **FN:** son los falsos negativos al momento de la predicción del clasificador.

4.8.1. Precisión

Mide la calidad y la dispersión del modelo en tareas de clasificación y se calcula a partir de la matriz de confusión mostrada en la figura 63, por lo cuál la ecuación utilizada es la siguiente:

$$Precision = \frac{TP}{TP + FP} \quad (19)$$

4.8.2. Sensitividad

Nos informa sobre la cantidad de imágenes que el modelo es capaz de identificar de manera correcta en los casos negativos, y se calcula de la siguiente manera:

$$Recall = \frac{TP}{TP + FN} \quad (20)$$

4.8.3. Exactitud

Mide el porcentaje de casos que el modelo ha acertado durante la prueba de rendimiento de clasificación, se representa como la relación entre el número de predicciones correctas y el número total de la base de datos.

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (21)$$

4.8.4. Valor F1

Combina las métricas de precisión y sensibilidad en un sólo valor, hace más fácil el poder comparar el rendimiento combinado de la precisión y la sensibilidad.

$$ValorF1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (22)$$

Las métricas mencionadas anteriormente son importante para medir el rendimiento del clasificador y son utilizadas durante este proyecto.

Capítulo 5. Resultados del clasificador de imágenes de electroluminiscencia

En un primer momento se optó por realizar un clasificador binario utilizando una red neuronal convolucional, esto fue debido a que la cantidad de muestras de nuestro banco de datos es de 846 imágenes. Además, las imágenes adquiridas eran muy distintas entre sí y el algoritmo podría no funcionar de una manera correcta. Pues si se intentaba realizar un clasificador con tres clases con esa cantidad limitada de imágenes probablemente los resultados obtenidos no fueran buenos y/o confiables, esto se debe a que la cantidad de imágenes, tomando en cuenta la variedad de diferentes tipos de imágenes era escasa. Por lo que las clases del clasificador binario son las siguientes:

- Celdas dañadas.
- Celdas en buen estado.

Para realizar pruebas con tres clases distintas, se decidió etiquetar la base de datos de imágenes de electroluminiscencia descargada de internet de Buerhop-Lutz et al. (2018); Deitsch et al. (2019, 2021), se obtuvieron un total de 3,386 imágenes de electroluminiscencia para entrenar la red, se añadió la tercera clase quedando las siguientes clases:

- Celdas en estado aceptable.
- Celdas dañadas.
- Celdas en buen estado.

Se realizaron tres pruebas con la base de datos extendida y con la base de datos original, las arquitecturas utilizadas fueron: VGG16, AlexNet y *transfer learning* utilizando VGG16 (solamente utilizando la base de datos extendida) .

El algoritmo creado recibe como entrada los siguientes parámetros:

- **Tamaño del conjunto de prueba:** cantidad de imágenes que se utilizarán durante la validación y el entrenamiento de la red (3,386 imágenes de la base de datos extendida y 846 imágenes de la base de datos original).

- **Resolución de la imagen de entrada:** la imagen de entrada es de 224x224 píxeles.
- **Número de clases:** como es un clasificador binario el número de clases es dos y en el clasificador utilizando la base extendida se tienen tres clases.
- **Épocas:** instante de tiempo considerado como punto de partida para un periodo o evento en particular.
- **Batch Size:** es la cantidad de muestras que se propagaran a través de la red durante cada época, además de que nos ayuda a trabajar requiriendo menos memoria y menor poder computacional, en este caso fueron 32 muestras.
- **Límite de VRAM:** cantidad máxima de uso de la memoria de la tarjeta gráfica NVIDIA Gigabyte GeForce GTX 1660 (6GB).
- **Fold:** dependiendo de la cantidad de "folds", el conjunto de entrenamiento y validación será dividido para entrenar a la red neuronal.

Una vez que tenemos definidos los parámetros anteriores se crean las etiquetas de cada una de las imágenes que se utilizarán en nuestro modelo CNN, como se muestra en la figura 64.

```
leyendo imagenes EL c:\Users\PC\Desktop\Tesis\Imágenes EL8b\
Directorios leídos: 2
Imágenes en cada directorio: [268, 578]
Total de imágenes en subdirectorio: 846
Cantidad etiquetas creadas: 846
0 Damaged
1 Good
Total de outputs : 2
Output classes : [0 1]
```

Figura 64. Análisis del tipo de imágenes que se encuentran en el directorio.

Las imágenes son divididas en 90% para el entrenamiento y 10% para la validación, cada conjunto de datos es colocado en su respectiva carpeta, la cuál cuenta a

su vez con subcarpetas en la cuál se encuentran los distintos tipos de clases del clasificador. Una vez separadas y preparadas las imágenes de electroluminiscencia se procede a entrenar la red neuronal convolucional, la cuál consta de un aprendizaje de 100 épocas. Se eligió la cantidad de 100 épocas debido a que se hicieron varias pruebas y en la mayoría de los casos se obtuvieron buenos resultados y el aprendizaje para un número mayor a 100 épocas en varios casos se mantenía sin mejora alguna. Debemos tener en cuenta que los parámetros que se mencionaron anteriormente y la forma de la división del conjunto de imágenes para el entrenamiento y validación de la red neuronal son los mismos en todas las pruebas, lo que cambia, es la arquitectura de la red neuronal convolucional y la semilla aleatoria que nos permite garantizar la aleatoriedad de los subconjuntos de imágenes de electroluminiscencia que se utilizan para entrenar a la red.

5.1. Resultados obtenidos utilizando la arquitectura VGG16

El entrenamiento de la red neuronal fue realizado con 100 épocas, aplicando una validación cruzada 10 *fold* donde el tiempo de entrenamiento tomó aproximadamente 4.5 h.

5.1.1. Resultados del clasificador binario utilizando la base de datos original sin balanceo




Figura 65. Gráfica de precisión del modelo VGG16.

El comportamiento del modelo tuvo un comportamiento ascendente de aprendizaje conforme avanzaban las épocas, no hay una gran diferencia entre la curva de validación que llega hasta un 95 % y la de entrenamiento que llega hasta un 93 %, lo cuál se puede ver en la figura 65. La diferencia entre la precisión de entrenamiento y la de validación indica el grado de sobreajuste que puede tener nuestra red neuronal convolucional, en la figura 65 la curva azul de precisión muestra una precisión mayor a la de entrenamiento, por lo que el modelo podría contar con un ligero sobreajuste. Para evitar algún tipo de sobreajuste se puede probar con el aumento de épocas de entrenamiento, aumentar el tamaño de la base de datos o modificar los diferentes parámetros de la red (*dropout*, optimizador, robustez, etc.).




Figura 66. Gráfica de pérdida de la validación cruzada del modelo VGG16.

Las pérdidas del entrenamiento y ambas alcanzan un valor cercano a 0.2, lo cuál se puede ver en la figura 66, también se generó una matriz de confusión que se muestra en la figura 67, contiene los resultados de la predicción del clasificador con un total de 846 imágenes, de las cuáles:

- En la clase 0 (celdas dañadas), 159 fueron predichas correctamente y 57 incorrectamente.
- En la clase 1, 630 imágenes fueron predichas correctamente y 0 predichas incorrectamente.




Figura 67. Matriz de confusión del modelo utilizando VGG16.

A partir de los resultados que se obtuvieron en la matriz de confusión de la figura 67 se generó la tabla 7. Estos resultados fueron obtenidos utilizando la base de datos original sin balanceo y usando la arquitectura de VGG16 la cuál tuvo un 84.8% de precisión.

Tabla 7. Resultados del clasificador VGG16 con la base de datos sin balanceo.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
VGG16 _{c0}	1	0.7528	0.922	0.859
VGG16 _{c1}	0.8977	1	0.922	0.9461

5.1.2. Resultados del clasificador binario utilizando la base de datos original balanceada

En este apartado se presentan los resultados que corresponden al aprendizaje de la red neuronal convolucional donde se utilizó la base de datos balanceada la cuál esta conformada por 432 imágenes de EL (216 imágenes de cada clase). Se graficaron los valores de precisión para obtener las curvas de validación y entrenamiento por 100 épocas de la figura 68. Se observa que ambas curvas se superponen teniendo la

misma tendencia ascendente de principio a fin. Siendo notorio su avance de precisión dado que pasa de alrededor del 50 % en la primer época hasta un 95 % y 97 % para la curva de validación y entrenamiento, respectivamente, al final de las épocas. Tener una base de datos con la misma cantidad de imágenes de cada clase nos ayuda a tener una visión más correcta de los resultados obtenidos, debido a que nos aseguramos que los resultados no favorezcan a una cierta clase. En la figura 69 se muestran las pérdidas del entrenamiento y validación, donde las curvas tienen un comportamiento descendente, esto significa que las pérdidas van disminuyendo durante el avance de las épocas de aprendizaje, hasta llegar a un valor mínimo de aproximadamente 0.2.




Figura 68. Gráfica de precisión de la validación cruzada 10 *fold* del modelo VGG16 utilizando la base de datos original balanceada.




Figura 69. Gráfica de pérdida de la validación cruzada 10 *fold* del modelo VGG16 utilizando la base de datos original balanceada.




Figura 70. Matriz de confusión utilizando la base de datos original.

A partir de los resultados que se obtuvieron en la matriz de confusión de la figura 70 se generó la tabla 8. Se observa que se obtuvo una precisión del 87.27 %.

Tabla 8. Resultados del clasificador VGG16 con la base de datos balanceada.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
VGG16 _{c0}	0.982	0.7593	0.8727	0.8564
VGG16 _{c1}	0.8038	0.9861	0.8727	0.8857

5.1.3. Pruebas del clasificador de tres clases utilizando la base de datos extendida

El entrenamiento de la red neuronal fue realizado con 100 épocas, aplicando una validación cruzada 10-*fold*, el entrenamiento duró aproximadamente 9.5 h. Se observa en la figura 71 que ambas curvas tienen la misma tendencia. Además, al final del proceso ambas alcanzaron una precisión del 94 %, el cual es un valor aceptable para los fines de este trabajo. En la figura 72, se muestran las pérdidas del entrenamiento, analizando las curvas, disminuyen con el paso de las épocas del aprendizaje, hasta llegar aproximadamente a 0.28 como valor mínimo al final de las 100 épocas.




Figura 71. Gráfica de precisión de la validación cruzada 10 *fold* del modelo utilizando VGG16 con la base de datos extendida.




Figura 72. Gráfica de pérdida de la validación cruzada 10 *fold* del modelo utilizando VGG16 la base de datos extendida.

Etiqueta verdadera	Aceptable 0	1188	0	90
	Dañado 1	96	336	96
	Buen estado 2	229	0	1351
		0 Aceptable	1 Dañado Etiqueta asignada	2 Buen estado


Figura 73. Matriz de confusión utilizando la base de datos extendida.

A partir de los resultados que se obtuvieron en la matriz de confusión de la figura 73 se generó la tabla 9.

Tabla 9. Resultados de desempeño del clasificador utilizando VGG16.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
VGG16 _{c0}	0.7852	0.9296	0.8491	0.8513
VGG16 _{c1}	1	0.6364	0.8491	0.7778
VGG16 _{c2}	0.8790	0.8551	0.8491	0.8669

El clasificador con la base de datos extendida obtuvo 0.8491 en la métrica de precisión (valor máximo 1). En la figura 74 se presentan algunas de las imágenes de las celdas que fueron predichas incorrectamente. En estas se aprecia que existen ciertas similitudes entre las celdas fotovoltaicas. La figura 74(a) y 74(b) son bastante parecidas, mientras que en la figura 74(c) es más fácil de diferenciar el estado de la celda fotovoltaica.



(a) Imagen de EL en estado aceptable. (b) Imagen de EL con daños. (c) Imagen de EL en buen estado.

Figura 74. Imágenes que fueron predichas incorrectamente.

El incremento de predicciones incorrectas se atribuye a que la base de datos aumentó aproximadamente cuatro veces su tamaño, al haber aumentado una clase más para categorizar las imágenes de forma manual, posiblemente haya generado confusión entre algunos tipos de imágenes que tenían ciertas similitudes pero que eran de diferente clase a la hora del entrenamiento de la red neuronal. En la tabla 10 se muestran las métricas de desempeño de los tres clasificadores con arquitectura VGG16 para las distintas bases de datos.

Tabla 10. Algunas métricas de desempeño de los clasificadores entrenados con VGG16.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
VGG16 con la base de datos sin balanceo	0.9170	1	0.8480	0.9567
VGG16 con la base de datos balanceada	0.9820	0.7593	0.8727	0.8564
VGG16 con la base de datos extendida	0.8790	0.8551	0.8491	0.8669

5.2. Resultados obtenidos utilizando la arquitectura Alex-Net

5.2.1. Resultados del clasificador binario utilizando la base de datos original sin balanceo

El aprendizaje del modelo entrenado tuvo un comportamiento de incremento gradual conforme avanzaban las épocas. Se puede ver en la figura 75 en la curva de color

azul que no hay ningún indicio de un sobreajuste. También, se observa que al finalizar el proceso de aprendizaje, la curva de validación que llega hasta un 100 % y la curva de entrenamiento llega hasta un 95 % de precisión, y son considerados valores aceptables. En la figura 76 se observa que las pérdidas del entrenamiento y validación tienen un comportamiento descendente, la curva de validación llega prácticamente hasta cero y la de entrenamiento disminuye hasta 0.16. Aquí podemos visualizar un ejemplo de sobreajuste, ya que la diferencia entre las dos curvas de pérdidas es muy grande. Para disminuir el sobreajuste se podrían realizar nuevas pruebas con diferentes parámetros y/o técnicas.




Figura 75. Gráfica de precisión de la validación cruzada 10 *fold* del modelo AlexNet utilizando la base de datos original sin balanceo.




Figura 76. Gráfica de pérdida de la validación cruzada 10 *fold* del modelo AlexNet utilizando la base de datos original sin balanceo.




Figura 77. Matriz de confusión del modelo utilizando AlexNet.

A partir de la matriz de confusión de la figura 77 se generó la tabla 11.

Tabla 11. Resultados del clasificador AlexNet sin balanceo.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
AlexNet _{c0}	0.9679	0.8380	0.9515	0.8983
AlexNet _{c1}	0.9469	0.9905	0.9515	0.9682

5.2.2. Resultados del clasificador binario utilizando la base de datos original balanceada

El comportamiento del modelo entrenado tuvo un aumento de aprendizaje de acuerdo a lo esperado. Observando la gráfica de la figura 78, notamos que tanto la curva de validación como la curva de entrenamiento tuvieron muy buenos valores de precisión, 99 % y 96 %, respectivamente.

En la figura 79 se muestran las pérdidas del entrenamiento y validación, las cuáles tienen un comportamiento descendente, es decir, las pérdidas van disminuyendo con el paso de las épocas hasta llegar aproximadamente a los valores de 0.05 en las pérdidas de validación y 0.15 en las pérdidas del entrenamiento.




Figura 78. Gráfica de precisión de la validación cruzada 10 *fold* del modelo AlexNet.




Figura 79. Gráfica de pérdida de la validación cruzada 10 *fold* del modelo AlexNet.




Figura 80. Matriz de confusión del modelo utilizando AlexNet.

La tabla 12 nos muestra los resultados de las cuatro métricas que utilizamos para medir el rendimiento del clasificador el cuál obtuvo un 91.2% de precisión, estos resultados fueron calculados a partir de la matriz de confusión de la figura 80.

Tabla 12. Resultados del clasificador AlexNet con la base de datos original balanceada.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
AlexNet _{c0}	0.9837	0.8380	0.912	0.9050
AlexNet _{c1}	0.8589	0.9861	0.912	0.9181

5.2.3. Pruebas del clasificador de tres clases utilizando la base de datos extendida

En la figura 81, se presentan las curvas de validación y entrenamiento correspondientes al clasificador de 3 clases con la base de datos extendida. Se observa que ambas curvas llegaron hasta un 95% de precisión al final del aprendizaje. En la figura 82 se muestran las curvas de pérdida respecto a las épocas. Las pérdidas del entrenamiento y validación tienen un comportamiento descendente, disminuyendo

gradualmente hasta un valor de 0.18 en ambas curvas.




Figura 81. Gráfica de precisión del modelo utilizando AlexNet con la base de datos extendida.




Figura 82. Gráfica de pérdida del modelo utilizando AlexNet con la base de datos extendida.

También se generó una matriz de confusión del modelo utilizando AlexNet, la cuál se ilustra en la figura 83. La matriz se caracteriza por calcularse con una base de datos extendida. Sus resultados se exhiben en la tabla 13, en la cuál se presentan los valores de precisión, sensibilidad, valor F1 y exactitud. Es importante resaltar que se tuvo una

exactitud de 85.82 % en las pruebas de clasificación utilizando 3 diferentes clases.

Etiqueta verdadera	Aceptable 0	1041	27	210
	Dañado 1	32	416	80
	Buen estado 2	115	16	1449
		0 Aceptable	1 Dañado	2 Buen estado
		Etiqueta asignada		

Figura 83. Matriz de confusión utilizando la base de datos extendida.

A partir de la matriz de confusión de la figura 83 se generó la tabla 13.

Tabla 13. Resultados del clasificador AlexNet con la base extendida.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
AlexNet _{c0}	0.8763	0.8146	0.8582	0.8443
AlexNet _{c1}	0.9063	0.7879	0.8582	0.8430
AlexNet _{c2}	0.8332	0.9171	0.8582	0.8732

En la tabla 14 se muestran las métricas de desempeño de los tres clasificadores con arquitectura AlexNet utilizados en cada base de datos.

Tabla 14. Algunas métricas de desempeño de los clasificadores entrenados con AlexNet.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
AlexNet con la base de datos sin balanceo	0.9469	0.9905	0.9515	0.9682
AlexNet con la base de datos balanceada	0.9837	0.8380	0.9120	0.9050
AlexNet con la base de datos extendida	0.8332	0.9171	0.8582	0.8731

5.3. Resultados obtenidos utilizando la técnica de *transfer learning*

5.3.1. Pruebas del clasificador de tres clases utilizando la base de datos extendida

En esta sección se encuentran los resultados obtenidos al utilizar *transfer learning* con VGG16, se espera obtener una mejor respuesta a los modelos anteriores ya que esta metodología cuenta con conocimientos predecesores que en algunos casos ha aumentado el desempeño de la red, en nuestra red, los valores de precisión se muestran en la figura 84. Se observa que tanto la curva de validación como la de entrenamiento siguen un mismo camino superponiéndose una sobre otra desde el inicio hasta el fin de las épocas, que en este caso el entrenamiento llega hasta las 100 épocas, de tal forma ambas curvas llegan hasta un 96 %. Podemos decir que la red neuronal convolucional entrenada no cuenta con sobreajuste. Con estos resultados obtenidos, podemos decir que el uso de *transfer learning* combinado con la arquitectura VGG16, obtuvo buenos resultados al momento del aprendizaje utilizando nuestra base de datos extendida.




Figura 84. Gráfica de precisión utilizando la técnica de *transfer learning*.

En la figura 85 se muestran las pérdidas del entrenamiento y validación tienen un comportamiento descendente, en la cuál van disminuyendo con el paso del aprendizaje hasta llegar a 0.16.




Figura 85. Gráfica de pérdida utilizando la técnica de *transfer learning*.

Etiqueta verdadera	Aceptable 0	1168	5	105
	Dañado 1	0	432	96
	Buen estado 2	161	0	1419
		0 Aceptable	1 Dañado	2 Buen estado
		Etiqueta asignada		

Figura 86. Matriz de confusión del modelo utilizando la técnica de *transfer learning*.

A partir de la matriz de confusión de la figura 86 se generó la tabla 15. De acuerdo a lo esperado, los resultados mostraron un mejor desempeño del método de entrenamiento, ya que el entrenamiento mediante *transfer learning* permite generar un modelo más robusto. Se obtuvo un 89.16 % de precisión. Los resultados fueron superiores a los obtenidos con las arquitecturas de AlexNet y VGG16, esto, tomando en cuenta

que la complejidad del clasificador aumentó al momento de incrementar el tamaño de la base de datos y la cantidad de clases.

Tabla 15. Resultados de las métricas de desempeño usando *transfer learning* con VGG16.

Clasificador	Precisión	Sensitividad	Exactitud	Valor F1
VGG16 _{c0}	0.8789	0.9139	0.8916	0.8960
VGG16 _{c1}	0.9886	0.8182	0.8916	0.8953
VGG16 _{c2}	0.8759	0.8981	0.8916	0.8869

Las pruebas con *transfer learning* se realizaron solo con VGG16. De acuerdo a lo encontrado hasta el momento se podrían predecir resultados superiores respecto a los otros métodos. Por lo que es prometedor continuar realizando pruebas con diferentes arquitecturas, parámetros y/o optimizadores.

Capítulo 6. Conclusiones

En esta sección se presentan las conclusiones generadas durante el desarrollo de la tesis, además se proponen aspectos a considerar para trabajos futuros, los cuáles pueden ser abordados y mejorados de distintas maneras.

6.1. Sobre los objetivos de la tesis

Se realizó una investigación sobre los dispositivos necesarios para llevar a cabo la adquisición de imágenes de EL. Se construyó una estructura sobre la cual se instalaron dichos dispositivos y que además soporta la colocación de PF para ser analizados.

Basándonos en técnicas de preprocesamiento como lo fue la calibración de la cámara para disminuir el efecto de distorsión de barril y mediante el uso de las imágenes de tipo *dark* y *bias* se creó una base de datos de imágenes de EL de alta calidad.

Se aplicaron algoritmos de aprendizaje automático para clasificar las imágenes de EL. Por lo que se logró comparar los resultados obtenidos de las diferentes arquitecturas vistas a lo largo de este trabajo (*transfer learning* con VGG16, Alexnet y VGG16). Esto permitió probar distintos parámetros para cada red neuronal e ir ajustando las características de la red para nuestro propósito.

Basándonos en los resultados anteriores se puede decir que se cumplieron todos los objetivos de la tesis, cabe resaltar que con más trabajo, es posible desarrollar un sistema comercial basado en este trabajo de investigación, también se podría mejorar el rendimiento del clasificador, cabe mencionar que no se tiene el conocimiento de que alguien más haya desarrollado un sistema similar al propuesto en la tesis de manera comercial.

Los resultados de este trabajo fueron obtenidos a partir de varias horas de entrenamiento de las redes neuronales anteriormente mencionadas. Para el uso de VGG16 se obtuvieron los siguientes resultados: 98.2 % de precisión, 75.93 % de sensibilidad, 87.27 % de exactitud y 85.64 % en el valor F1. En la red neuronal en la cual se utilizó la arquitectura AlexNet, se obtuvieron los siguientes resultados para sus cuatro métricas de desempeño: 98.37 % de precisión, 83.8 % de sensibilidad, 91.2 % de exactitud y

90.5 % en el valor F1, los resultados presentan una mejora considerable en comparación a las pruebas realizadas con VGG16, a futuro es posible mejorar estos resultados agregando mas tipos de celdas fotovoltaicas a cada clase del clasificador, y de esta manera obtener una mejor fiabilidad.

La base de datos utilizada en este trabajo de investigación tiene dos limitaciones importantes. La primera es que está mal balanceada, es decir contiene más imágenes correspondientes a celdas fotovoltaicas en buen estado que de celdas dañadas. La segunda limitación es con respecto al tamaño de la base, ya que 846 muestras es poco para poder obtener resultados que puedan ser considerados como generalizables. Esto afecta particularmente la capacidad del sistema propuesto para identificar paneles dañados en una situación real.

6.2. Trabajo futuro

Al terminar este trabajo se considera que se podrían realizar trabajos complementarios que podrían dar buenos resultados. Para lo cual se propone:

- Ampliar la base de datos, ya que incrementar la cantidad de imágenes, permitiría abarcar mayor cantidad de tipos de paneles fotovoltaicos y posibles defectos que existen. Es particularmente importante aumentar la cantidad de imágenes de paneles fotovoltaicos defectuosos para mejorar la precisión de la clase.
- Una mejora significativa al trabajo desarrollado sería contar con muchos más ejemplos de celdas dañadas y realizar más estudios en esta dirección. Las arquitecturas de CNN utilizadas tienen un gran número de parámetros que deben ajustarse para poder tener una buena generalización.
- Construir una estructura de montaje tipo campana sobre el PF, esta estructura estaría colocada encima del panel fotovoltaico cubriéndolo de manera que pueda bloquear toda luz externa para que las imágenes de EL puedan ser adquiridas en completa oscuridad.
- Utilizar cámaras enfriadas que tengan una mejor sensibilidad, para evitar el calentamiento del sensor, con el fin de disminuir considerablemente los pixeles calientes y el ruido en las mediciones durante la toma de la imagen de EL.

- Combinar imágenes térmicas e imágenes de electroluminiscencia en el clasificador, para evaluar la mejoría de los resultados.
- Utilizar otras arquitecturas de redes neuronales más recientes que tienen mejor desempeño, así se podría realizar una comparación más profunda del aprendizaje del clasificador.
- Optimizar el desarrollo del modelo de clasificación así como la estructura con el objetivos de alcanzar el nivel comercial, ya que es un hecho que el uso de los paneles fotovoltaicos aumentará con el paso de los años y dispositivos como el propuesto en este trabajo serán indispensables.

Literatura citada

- Akinyele, D., Rayudu, R., and Nair, N.-K. C. (2015). Global progress in photovoltaic technologies and the scenario of development of solar panel plant and module performance estimation- application in nigeria. *Renewable and Sustainable Energy Reviews*, 48:112–139.
- Akram, M. W., Li, G., Jin, Y., Chen, X., Zhu, C., Zhao, X., Khaliq, A., Faheem, M., and Ahmad, A. (2019). Cnn based automatic detection of photovoltaic cell defects in electroluminescence images. *Energy*, 189:116319.
- Alves, R. H. F., de Deus Junior, G. A., Marra, E. G., and Lemos, R. P. (2021). Automatic fault classification in photovoltaic modules using convolutional neural networks. *Renewable Energy*, 179:502–516.
- Andrychowicz, M., Denil, M., Gomez, S., Hoffman, M. W., Pfau, D., Schaul, T., Shillingford, B., and De Freitas, N. (2016). Learning to learn by gradient descent by gradient descent. *Advances in neural information processing systems*, 29.
- Azab, M. (2008). A new maximum power point tracking for photovoltaic systems. *Waset. Org*, 34:571–574.
- Barrios, J. (2022). Las redes neuronales convolucionales son un tipo de redes neuronales. Consultado el 28 de febrero de 2022 de: <https://www.juanbarrios.com/redes-neurales-convolucionales>.
- Bishop, C. M. and Nasrabadi, N. M. (2006). *Pattern recognition and machine learning*, volume 4. Springer.
- Buerhop-Lutz, C., Deitsch, S., Maier, A., Gallwitz, F., Berger, S., Doll, B., Hauch, J., Camus, C., and Brabec, C. J. (2018). A benchmark for visual identification of defective solar cells in electroluminescence imagery. In *35th European PV Solar Energy Conference and Exhibition*, volume 12871289, pages 1287–1289.
- Carlsson, T. and Brinkman, A. (2006). Identification of degradation mechanisms in field-tested cdte modules. *Progress in photovoltaics: research and applications*, 14(3):213–224.
- Chaganti, S. Y., Nanda, I., Pandi, K. R., Prudhvith, T. G., and Kumar, N. (2020). Image classification using svm and cnn. In *2020 International conference on computer science, engineering and applications (ICCSEA)*, pages 1–5. IEEE.
- Chao, K.-H. and Li, C.-J. (2010). An intelligent maximum power point tracking method based on extension theory for pv systems. *Expert Systems with Applications*, 37(2):1050–1055.
- Cibse (2010). Photovoltaics for buildings. Consultado el 27 de abril de 2022 de: <https://www.cibsejournal.com/cpd/modules/2010-01/>.
- Dallas, W., Polupan, O., and Ostapenko, S. (2007). Resonance ultrasonic vibrations for crack detection in photovoltaic silicon wafers. *Measurement Science and Technology*, 18(3):852.
- Deceglie, M. G. and Silverman, T. J. (2020). Illuminated outdoor luminescence imaging of photovoltaic modules. US Patent 10,554,172.

- Deitsch, S., Buerhop-Lutz, C., Sovetkin, E., Steland, A., Maier, A., Gallwitz, F., and Riess, C. (2021). Segmentation of photovoltaic module cells in uncalibrated electroluminescence images. *Machine vision and applications*, 32(4):84.
- Deitsch, S., Christlein, V., Berger, S., Buerhop-Lutz, C., Maier, A., Gallwitz, F., and Riess, C. (2019). Automatic classification of defective photovoltaic module cells in electroluminescence images. *Solar Energy*, 185:455–468.
- Demirci, M. Y., Bešli, N., and Gümüşçü, A. (2021). Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in electroluminescence images. *Expert Systems with Applications*, 175:114810.
- Dietterich, T. (1995). Overfitting and undercomputing in machine learning. *ACM computing surveys (CSUR)*, 27(3):326–327.
- Du, B., Yang, R., He, Y., Wang, F., and Huang, S. (2017). Nondestructive inspection, testing and evaluation for si-based, thin film and multi-junction solar cells: An overview. *Renewable and sustainable energy reviews*, 78:1117–1151.
- Ebner, R., Kubicek, B., and Újvári, G. (2013). Non-destructive techniques for quality control of pv modules: Infrared thermography, electro-and photoluminescence imaging. In *IECON 2013-39th Annual Conference of the IEEE Industrial Electronics Society*, pages 8104–8109. IEEE.
- Efenarsolar (2021). Centro de producción – fábrica. Consultado el 25 de julio de 2022 de: <http://www.efenarsolar.com/index.php/es/efenar-solar/fabrica>.
- El Hammoumi, A., Chtita, S., Motahhir, S., and El Ghzizal, A. (2022). Solar pv energy: From material to use, and the most commonly used techniques to maximize the power output of pv systems: A focus on solar trackers and floating solar panels. *Energy Reports*, 8:11992–12010.
- Fluga, S. and Eigenbrod, H. (2009). Inline-thermografie-system prüft solarzellen—den mikrorissen auf der spur. *QZ*, 54:9.
- Frazão, M., Silva, J., Lobato, K., and Serra, J. (2017). Electroluminescence of silicon solar cells using a consumer grade digital camera. *Measurement*, 99:7–12.
- Fuyuki, T., Kondo, H., Yamazaki, T., Takahashi, Y., and Uraoka, Y. (2005). Photographic surveying of minority carrier diffusion length in polycrystalline silicon solar cells by electroluminescence. *Applied Physics Letters*, 86(26):262108.
- Gabor, A. M., Ralli, M., Montminy, S., Alegria, L., Bordonaro, C., Woods, J., Felton, L., Davis, M., Atchley, B., and Williams, T. (2006). Soldering induced damage to thin si solar cells and detection of cracked cells in modules. In *21st European Photovoltaic Solar Energy Conference*, pages 4–8.
- Hantula, R. (2009). *How Do Solar Panels Work?* Infobase Publishing.
- Hart, P. E., Stork, D. G., and Duda, R. O. (2000). *Pattern classification*. Wiley Hoboken.
- He, J., Li, L., Xu, J., and Zheng, C. (2018). Relu deep neural networks and linear finite elements. *arXiv preprint arXiv:1807.03973*.

- Hobbs, W. B., Hamzavy, B., Jones, C. B., Libby, C., and Lavrova, O. (2018). In-field electroluminescence imaging: Methods, comparison with indoor imaging, and observed changes in modules over one year. In *2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC)(A Joint Conference of 45th IEEE PVSC, 28th PVSEC & 34th EU PVSEC)*, pages 3257–3260. IEEE.
- Jayas, D., Paliwal, J., and Visen, N. (2000). Review paper (ae—automation and emerging technologies): multi-layer neural networks for image analysis of agricultural products. *Journal of Agricultural Engineering Research*, 77(2):119–128.
- Johnston, S. (2015). Contactless electroluminescence imaging for cell and module characterization. In *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)*, pages 1–6. IEEE.
- Johnston, S. (2017). Luminescence imaging systems and methods for evaluating photovoltaic devices. US Patent 9,641,125.
- Kabir, E., Kumar, P., Kumar, S., Adelodun, A. A., and Kim, K.-H. (2018). Solar energy: Potential and future prospects. *Renewable and Sustainable Energy Reviews*, 82:894–900.
- Karimi, A. M., Fada, J. S., Hossain, M. A., Yang, S., Peshek, T. J., Braid, J. L., and French, R. H. (2019). Automated pipeline for photovoltaic module electroluminescence image processing and degradation feature classification. *IEEE Journal of Photovoltaics*, 9(5):1324–1335.
- Kim, J.-H., Kim, J.-H., Jung, S.-W., Noh, C.-K., and Ko, S.-J. (2011). Novel contrast enhancement scheme for infrared image using detail-preserving stretching. *Optical Engineering*, 50(7):077002–077002.
- Köntges, M., Kunze, I., Kajari-Schröder, S., Breitenmoser, X., and Bjørneklett, B. (2011). The risk of power loss in crystalline silicon based photovoltaic modules due to micro-cracks. *Solar energy materials and solar cells*, 95(4):1131–1137.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90.
- Kubat, M. (1999). Neural networks: a comprehensive foundation by simon haykin, macmillan. *The Knowledge Engineering Review*, 13(4):409–412.
- Liu, J., Melnikov, A., and Mandelis, A. (2015). Non-contact determination of local efficiency of mc-si solar cells using quantitative lock-in thermographic and carriero-graphic (photoluminescence) imaging. *International Journal of Thermophysics*, 36(5-6):987–996.
- Lockridge, B. P., Lavrova, O., and Hobbs, W. B. (2016). Comparison of electroluminescence image capture methods. In *2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)*, pages 0876–0879. IEEE.
- Lydia, A. and Francis, S. (2019). Adagrad-an optimizer for stochastic gradient descent. *Int. J. Inf. Comput. Sci*, 6(5):566–568.
- Mathias, N., Shaikh, F., Thakur, C., Shetty, S., Dumane, P., Chavan, D., et al. (2020). Detection of micro-cracks in electroluminescence images of photovoltaic modules. In *Proceedings of the 3rd International Conference on Advances in Science & Technology (ICAST)*.

- Mellit, A. and Kalogirou, S. (2021). Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions. *Renewable and Sustainable Energy Reviews*, 143:110889.
- Mouha, R. A. et al. (2021). Deep learning for robotics. *Journal of Data Analysis and Information Processing*, 9(02):63.
- Nema, R., Nema, S., and Agnihotri, G. (2009). Computer simulation based study of photovoltaic cells/modules and their experimental verification. *International journal of recent trends in Engineering*, 1(3):151–156.
- Nuotio, M. and Kernahan, K. (2012). Method for determining the operating condition of a photovoltaic panel. US Patent 8,239,149.
- O'Shea, K. and Nash, R. (2015). An introduction to convolutional neural networks. *arXiv:1511.08458*.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1):62–66.
- Parikh, H. R., Buratti, Y., Spataru, S., Villebro, F., Reis Benatto, G. A. D., Poulsen, P. B., Wendlandt, S., Kerekes, T., Sera, D., and Hameiri, Z. (2020). Solar cell cracks and finger failure detection using statistical parameters of electroluminescence images and machine learning. *Applied Sciences*, 10(24):8834.
- Petkov, N. et al. (2018). Automatic segmentation of indoor and outdoor scenes from visual lifelogging. In *Applications of Intelligent Systems: Proceedings of the 1st International APPIS Conference*, page 194.
- Pierdicca, R., Malinverni, E., Piccinini, F., Paolanti, M., Felicetti, A., and Zingaretti, P. (2018). Deep convolutional neural network for automatic detection of damaged photovoltaic cells. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42(2).
- Pingel, S., Koshnicharov, D., Frank, O., Geipel, T., Zemen, Y., Striner, B., and Berghold, J. (2010). Initial degradation of industrial silicon solar cells in solar panels. In *Proceedings of the 25th European Photovoltaic Solar Energy Conference. Valencia, Spain*, pages 4027–4032. Citeseer.
- Pingel, S., Zemen, Y., Frank, O., Geipel, T., and Berghold, J. (2009). Mechanical stability of solar cells within solar panels. *Proc. of 24th EUPVSEC*, pages 3459–3464.
- Qassim, H., Verma, A., and Feinzimer, D. (2018). Compressed residual-vgg16 cnn model for big data places image recognition. In *2018 IEEE 8th annual computing and communication workshop and conference (CCWC)*, pages 169–175. IEEE.
- Rahman, M. R. U. and Chen, H. (2020). Defects inspection in polycrystalline solar cells electroluminescence images using deep learning. *IEEE Access*, 8:40547–40558.
- Refaeilzadeh, P., Tang, L., and Liu, H. (2009). Cross-validation. *Encyclopedia of database systems*, 5:532–538.
- Ren, S., He, K., Girshick, R., and Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28:91–99.

- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv:1609.04747*.
- Rupnowski, P. and Sopori, B. (2009). Strength of silicon wafers: fracture mechanics approach. *International journal of fracture*, 155:67–74.
- Sampaio, P. G. V. and González, M. O. A. (2017). Photovoltaic solar energy: Conceptual framework. *Renewable and Sustainable Energy Reviews*, 74:590–601.
- Serrano (2017). Tipos de paneles fotovoltaicos. Consultado el 28 de julio de 2022 de: <https://tritec-intervento.cl/tipos-de-paneles-fotovoltaicos>.
- Shin, W., Han, J., and Rhee, W. (2021). Ai-assistance for predictive maintenance of renewable energy systems. *Energy*, 221:119775.
- Sinton, R. (2008). Contactless electroluminescence for shunt-value measurement in solar cells. In *23rd European Photovoltaic Solar Energy Conference*, pages 1157–1159.
- Sopori, B., Basnyat, P., Devayajanam, S., Shet, S., Mehta, V., Binns, J., and Appel, J. (2012). Understanding light-induced degradation of c-si solar cells. In *2012 38th IEEE Photovoltaic Specialists Conference*, pages 001115–001120. IEEE.
- Spataru, S., Hacke, P., Sera, D., Glick, S., Kerekes, T., and Teodorescu, R. (2015). Quantifying solar cell cracks in photovoltaic modules by electroluminescence imaging. In *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)*, pages 1–6. IEEE.
- Srivastava, N. (2013). Improving neural networks with dropout. *University of Toronto*, 182(566):7.
- Sulas, D. B., Johnston, S., and Jordan, D. C. (2019). Comparison of photovoltaic module luminescence imaging techniques: Assessing the influence of lateral currents in high-efficiency device structures. *Solar Energy Materials and Solar Cells*, 192:81–87.
- Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications*, 9(10):143–150.
- Tang, W., Yang, Q., Xiong, K., and Yan, W. (2020). Deep learning based automatic defect identification of photovoltaic module using electroluminescence images. *Solar Energy*, 201:453–460.
- Vargas-Hernández, J. G. and Espinosa, E. R. A. (2016). Solar panel and renewable energy in mexico development and outlook for photovoltaic. *International Journal of Environment and Sustainability*, 5(2).