



Clasificación Automática De Defectos De Paneles Solares
Aplicando Aprendizaje De Máquina.

Automatic Classification For Defects Of Photovoltaic Solar
Cells Using Machine Learning.

Robinson Castillo Méndez
Centro de Electricidad, Electrónica y Telecomunicaciones, SENA,
Regional Distrito Capital.
rcastillo48@misena.edu.co

Resumen

Este trabajo presenta el avance realizado en el desarrollo e implementación de una interfaz para la detección automática de defectos en paneles solares fotovoltaicos, aplicando aprendizaje de máquina, proyecto ejecutado en el Centro de Electricidad, Electrónica y Telecomunicaciones, con el objetivo de contribuir con el mejoramiento del proceso de verificación de defectos de los paneles solares a los que se les realiza el ensayo de Electroluminiscencia (EL) en el Laboratorio de Ensayos de Paneles Solares (LEPS). Se presentan definiciones y aspectos básicos de Machine Learning (ML), los principales defectos de los paneles solares que pueden identificarse en las imágenes EL, una descripción de alto nivel de la solución propuesta a nivel de diseño y principales resultados de validación en la inspección a partir de un dataset de entrenamiento y pruebas.

Palabras clave: *Aprendizaje de máquina; Aprendizaje supervisado; Clasificador; Defectos en paneles solares fotovoltaicos; Imágenes de Electroluminiscencia.*

Abstract

This document outlines the advancements achieved in the development and implementation of an interface for automated defect detection in photovoltaic solar panels. The project, conducted at the Electricity, Electronics, and Telecommunications Center, aims to enhance the defect verification process of solar panels undergoing the Electroluminescence (EL) test at the Solar Panel Testing Laboratory (LEPS). The text covers fundamental concepts and aspects of Machine Learning (ML), highlights key defects identifiable in EL images of solar panels, provides

a high-level description of the proposed design solution, and presents significant validation results obtained from training and testing datasets.

Key words: *Machine learning; Supervised learning; Classifier; Photovoltaic solar panel defects; Electroluminescence images.*

Introducción

El aprendizaje de máquina (Machine Learning) es una rama de la inteligencia artificial que funciona gracias a la acción de algoritmos que trabajan con los datos que una máquina recibe constantemente, mejorando su desempeño, adquiriendo nuevos conocimientos o habilidades, o reorganizando los conocimientos o habilidades existentes; pretende que los sistemas aprendan partiendo de los datos suministrados, identifiquen patrones y tomen decisiones sin necesidad de una participación humana. Entre las soluciones relacionadas con la Industria 4.0 con más futuro, se encuentra la combinación entre la Inteligencia Artificial y el Machine Learning (ML).

Los sistemas basados en paneles fotovoltaicos son cada vez más interesantes a medida que el desarrollo tecnológico ha logrado aumentar aún más su eficiencia de conversión. En comparación con otros sistemas utilizados para la generación de electricidad, los paneles solares están diseñados para operar en ambientes exteriores; en ocasiones presentan daños, o una eficiencia reducida (Haba, 2019).

El desarrollo de este trabajo pretende lograr la implementación de un sistema que detecte y clasifique automáticamente defectos de paneles solares, optimizando la velocidad y la fiabilidad de las inspecciones visuales que se realizan durante el ensayo de electroluminiscencia en el Laboratorio de Ensayos de Paneles Solares, eliminando factores humanos como la fatiga y los sesgos propios, así como dejar de identificar defectos que puedan ser imperceptibles por el ojo humano durante el análisis de las imágenes obtenidas en el ensayo aplicado. El alcance planteado en este

documento llega hasta la descripción del diseño de alto nivel y pruebas a partir de un dataset destinado a test de la solución propuesta.

Antecedente

El Laboratorio de Ensayos de Paneles Solares - LEPS, cuenta con un equipo de Electroluminiscencia (EL) para inspeccionar los paneles solares, durante el ensayo se realiza la captura de imágenes del panel que se ha inspeccionado, quedando almacenadas en disco duro para su posterior análisis; sin embargo, la verificación de defectos de los paneles solares debe realizarse de manera manual por el laboratorista encargado, haciéndolo un proceso ineficiente en términos de tiempo, y susceptible a errores debido a factores humanos como la fatiga y los sesgos propios, así como por la no observación de posibles defectos imperceptibles por el ojo humano durante el análisis.

Se ha planteado la ejecución de un proyecto, el cual propone el desarrollo e implementación de una interfaz de usuario, que permita realizar la detección automática de defectos en los paneles solares fotovoltaicos sometidos al ensayo de electroluminiscencia realizado en el Laboratorio LEPS, aplicando algoritmos de aprendizaje de máquina y aprendizaje supervisado.

Metodología

Para el alcance planteado en este documento, el cual llega hasta la descripción del diseño de alto nivel de la solución propuesta, se ha abordado la siguiente metodología:

Apropiación de fundamentos en Machine Learning, Electroluminiscencia y defectos de los paneles solares fotovoltaicos: mediante búsqueda en fuentes especializadas de información, determinar y comprender los componentes, aplicaciones y características fundamentales en

Machine Learning, Electroluminiscencia y defectos de los paneles solares fotovoltaicos.

Caracterización parámetros de calidad y defectos de paneles solares fotovoltaicos: mediante una búsqueda especializada, se establecen las características mínimas de calidad que debe presentar un panel solar fotovoltaico que se pretenda usar en aplicaciones prácticas a nivel industrial, y que deben ser necesarias para su certificación e ingreso al mercado y, los principales defectos que presentan dichos paneles.

Creación de base de imágenes: conociendo los parámetros de calidad que deben satisfacer los paneles solares fotovoltaicos, establecer una base de imágenes que contenga descripciones de paneles en buen estado y certificables, así como de paneles con los principales defectos, logrando así la creación de la base de aprendizaje y clasificación para la interfaz a desarrollar.

Especificación del sistema para identificación y clasificación de defectos de paneles solares: se caracteriza el sistema y se definen los requerimientos de diseño de este. En esta etapa se plantea también determinar la herramienta de desarrollo en la cual se creará y bajo la cual operará la interfaz que clasificará los paneles probados en el laboratorio LEPS en el ensayo de Electroluminiscencia.

Diseño y simulación del sistema: una vez especificado el sistema en función de los requerimientos de diseño y de los parámetros de calidad que deben satisfacer los paneles solares fotovoltaicos, se realiza el diseño y simulación de la aplicación propuesta.

Generalidades Machine Learning

De forma muy general, puede definirse Machine Learning como un tipo de Inteligencia Artificial que desarrolla técnicas que permiten a máquinas tomar decisiones. Machine Learning (también

llamado Aprendizaje Automático) se define como un proceso automatizado que extrae patrones de los datos. Para construir los modelos utilizados en las aplicaciones de análisis predictivo de datos, se utiliza el aprendizaje automático supervisado (Kelleher et al., 2015).

Figura 1

Funcionamiento general Machine Learning.



Fuente. (SAP Insights, 2022).

Los algoritmos de Machine Learning funcionan buscando a través de un conjunto de posibles modelos de predicción el modelo que captura mejor la relación entre las características descriptivas y la característica de destino en un conjunto de datos. (**Figura 1**).

El aprendizaje automático no es un conjunto concreto de algoritmos utilizados en todos los ámbitos. Dependiendo de lo que intente lograr, se pueden usar diferentes tecnologías y diferentes algoritmos. A medida que los algoritmos incorporan datos de entrenamiento, es posible producir modelos más precisos basados en esos datos. En general, en ML e Inteligencia Artificial cuando se encuentra en un entorno controlado, en esta fase se introducen una gran cantidad de datos y sus respectivos resultados con los que se podrá crear relaciones entre ideas (Aprendizaje Supervisado). El aprendizaje supervisado generalmente comienza con un conjunto establecido de datos y una cierta comprensión de cómo se clasifican esos datos. El aprendizaje supervisado está destinado a encontrar patrones en los datos que se pueden aplicar a un proceso de análisis. Estos datos tienen características etiquetadas que definen el significado de los datos (Hurwitz & Kirsch, 2018).

El aprendizaje supervisado usa datos etiquetados por humanos y se usa comúnmente cuando los datos pueden predecir eventos probables. En otras palabras, es una entrada cuando se conoce la salida deseada. El algoritmo aprende un conjunto de entradas junto con las salidas correctas correspondientes y aprende comparando su salida real con las salidas correctas para encontrar errores. Una vez que encuentra los errores, puede modificar el modelo en consecuencia.

Existen dos tipos principales de aprendizaje supervisado; clasificación y regresión. La clasificación es el lugar donde se entrena a un algoritmo para clasificar los datos de entrada en variables discretas. Durante el entrenamiento, los algoritmos reciben datos de entrada de entrenamiento con una etiqueta de clasificación. La regresión es un método de aprendizaje supervisado en el que se entrena a un algoritmo para predecir una salida a partir de un rango continuo de valores posibles.

Clasificadores.

La clasificación es un enfoque de aprendizaje supervisado, que puede interpretarse como un medio de categorización (o clasificación) de algunos elementos desconocidos en un conjunto discreto de clases. Un clasificador es un algoritmo que recibiendo como entrada cierta información de un objeto, es capaz indicar la categoría o clase a la que pertenece de entre un número acotado de clases posibles (Gavilan, 2017). Antes de aplicar un método de clasificación, debe realizarse una partición del conjunto de datos en dos conjuntos de datos más pequeños que serán utilizadas con entrenamiento y test. El subconjunto de datos de entrenamiento es utilizado para estimar los parámetros del modelo y el subconjunto de datos de test se emplea para comprobar el comportamiento del modelo estimado.


Un clasificador basado en Machine Learning funciona en dos fases: primero es entrenado, recibe una gran cantidad de datos de ejemplo y

su clasificación correcta, de forma que se pueden ajustar los parámetros del algoritmo para un funcionamiento óptimo. Cuando ya está entrenado recibe unos datos de entrada y da la clasificación

correspondiente como salida (Gavilan, 2017). Algunos de los principales clasificadores usados en Machine Learning se muestran a continuación:

Tabla 1
Principales clasificadores en ML.

CLASIFICADOR	DESCRIPCIÓN	IMAGEN TOPOLOGÍA
Árbol de decisión	Corresponde a una estructura donde en cada nodo se hace una pregunta y, en función de la respuesta, se sigue hacia un nodo u otro. La respuesta final es la categoría buscada.	
Bosques Aleatorios	Corresponde a una colección de árboles de decisión entrenados cada uno con un subconjunto de los datos disponibles y que se ocupan sólo de un subconjunto de las características. La decisión final se toma como una media de las decisiones individuales de los árboles.	
Grupo de Clasificadores	Se toman varios clasificadores (árboles de decisión o no), se entrenan bajo condiciones diferentes, y sus resultados se agregan de alguna forma. La idea subyacente es que cada clasificador es muy bueno en algo y los diferentes clasificadores son bastante independientes, de forma que se espera que la agregación sea una buena clasificación.	
Máquinas de Vectores de Soporte	Asumen que se puede establecer fronteras lineales en el espacio total de valores posibles de forma que, dependiendo de dónde se encuentre un conjunto de datos concreto, estará a alguno de los lados de la frontera, lo que lleva a su clasificación según el lado en que se encuentre. Asumen una separabilidad lineal (las fronteras vienen dadas por ecuaciones lineales).	
Naive Bayes	Corresponde a una aplicación simplificada de la estadística bayesiana en que, se parte de unos valores iniciales de confianza en una clasificación y, durante el entrenamiento se van ajustando.	

CLASIFICADOR	DESCRIPCIÓN	IMAGEN TOPOLOGÍA
Redes Neuronales	A partir de un conjunto de nodos estructurados en capas, se obtiene una salida en función de sus entradas y la aplicación de unos pesos. Estos pesos se ajustan durante el entrenamiento, y es la forma en que aprenden. Las redes neuronales son en general buenas cuando se trata de clasificar con base en muchas características.	

Fuente. (Gavilan, 2017).

Principales Defectos De Los Paneles Solares Fotovoltaicos.

Las celdas solares pueden presentar defectos característicos, tales como microgrietas, dedos rotos, contactos defectuosos entre celdas, celdas con fisuras o celdas rotas, los cuales no son perceptibles a simple vista. En este caso, la prueba de electroluminiscencia proporciona información de los defectos que se encuentran en las celdas solares bajo análisis, las cuales conforman el panel solar fotovoltaico (Salazar-Peralta et al., 2018).

Las celdas solares están sujetas a procesos de fabricación muy duros, que incluyen el corte de obleas, los procesos incrustación, y los procedimientos de soldadura y laminación. Las celdas solares fotovoltaicas son más susceptibles a las grietas y microgrietas, generalmente no visibles a simple vista, cuya propagación puede quitar más del 10% del área de esa celda del circuito eléctrico del módulo. Las grietas en las celdas se pueden clasificar en las siguientes clases, según su efecto sobre el rendimiento del generador fotovoltaico (Ahmad et al., 2019):

Las grietas de modo A no conducen a partes de celda inactivas. Sin embargo, el envejecimiento y la exposición a las tensiones ambientales en el campo pueden causar la separación eléctrica completa de las partes de la celda.


Las grietas de modo B representan grietas que producen un efecto mínimo en la eficiencia eléctrica del módulo.

En las grietas de modo C, las grietas conducen a partes de celda inactivas. Estos tienen un efecto severo en el sistema eléctrico y propiedades del módulo, lo que lleva a la formación de puntos críticos.

En las primeras etapas de su desarrollo, estas grietas no se pueden ver con inspección visual (grietas de modo A). Con el paso del tiempo, estas grietas se ensanchan y se vuelven visibles. Sin embargo, la mejor manera de ver la existencia de la grieta o microgrieta y el desarrollo de partes inactivas de la celda es a través de pruebas EL que resaltan el contraste entre las grietas (áreas oscuras) y el fondo circundante (Ver **Figura 2**).

Figura 2

Principales defectos paneles solares; grietas y microgrietas.



Fuente. (Köntges et al., 2014).

Dislocaciones de cristal, manchas, dedos cortados (interrupciones de los dedos) son otros de los defectos más comunes identificables mediante las imágenes EL.

Resultados Y Discusión


A continuación, se presenta el avance en el desarrollo e implementación de la interfaz para la detección automática de defectos en paneles solares fotovoltaicos, el cual, corresponde al diseño general del sistema, software de la interfaz y pruebas de validación del modelo entrenado.

Diseño General Del Sistema.

El sistema contempla los cuatro bloques fundamentales de un clasificador que incorpora aprendizaje de máquina mostrados en la siguiente figura:

Figura 3

Bloques generales del sistema.



Fuente. Elaboración propia.

El sistema se realiza a partir de imágenes de electroluminiscencia (EL) de las obleas individuales de paneles solares monocristalinos y policristalinos, clasifica los siguientes defectos más comunes identificables a partir de una imagen EL:

- Fractura (Crack)
- Microfisura (Microcrack)
- Manchas
- Dedos cortados
- Dislocación del cristal (Policristalinos)


Así mismo, está en capacidad de identificar si se encuentra en buen estado para ambos casos: monocristalino y policristalino.

La extracción de características se realiza a partir de árbol de decisiones en primera instancia, se evaluarán y simularán otros métodos seleccionando finalmente el que mejores resultados presente en las simulaciones. La clasificación se realiza implementando una red neuronal.

El diseño y desarrollo del sistema consta de dos grandes etapas: entrenamiento basado en iteraciones hasta identificar el modelo ML de mejor desempeño; y la clasificación, la cual integra el modelo determinado en la solución, como lo muestra la siguiente figura:

Figura 4

Determinación del modelo ML.



Fuente. Elaboración propia basado en MathWorks®.

A un alto nivel, el diseño del sistema consta de ocho bloques básicos. El primer bloque del sistema se encarga de acceder a la información (esto es imagen EL capturada) y acondicionarla. A continuación, se realiza la extracción de características y una vez conformado el vector de entrada, durante la etapa de desarrollo, esta información se usará para el entrenamiento mediante aprendizaje supervisado, eso permitirá determinar las capas y pesos requeridos para la red neuronal convolucional, la cual clasifica la imagen si corresponde con alguna de los defectos comunes entrenados. Desde el punto de vista de interfaz de usuario, se despliega la información

correspondiente a la salida del sistema, lo cual equivale a indicar si se trata de un panel defectuosos o no, y el tipo de defecto identificado (ver Figura 5).

Figura 5

Interfaz de usuario.





Fuente. Elaboración propia.

Las pruebas de validación del sistema a partir de la base de aprendizaje y de pruebas del dataset mostraron los siguientes niveles de efectividad en la inspección y clasificación de defectos:

Figura 6

Resultados obtenidos en etapa de validación del sistema.



Fuente. Elaboración propia.

La **Figura 6** muestra algunos resultados de una validación aleatoria de imágenes de un dataset destinado a pruebas, estos porcentajes de precisión guardan coherencia con los resultados de precisión de validación obtenidos durante el proceso de entrenamiento de la red neuronal en la cual se basa el clasificador y el sistema desarrollado, cuyo valor fue del 90%. De estas pruebas, se encuentra que la identificación del defecto “Manchas” es el que puede llegar a tener un menor nivel de precisión al momento de realizar la inspección.

Se trata de un primer ciclo de diseño, desarrollo y entrenamiento, se han obtenido resultados importantes en cuanto a precisión de identificación del tipo de defecto en entorno controlado. Dentro de los pasos a seguir, será validar el funcionamiento y precisión del sistema en ambiente real y, a partir de los resultados obtenidos, generar las mejoras que se identifiquen a nivel de clasificación, rendimiento de la red neuronal y de interfaz gráfica para una implementación final y totalmente funcional.

Conclusiones

El aprendizaje de máquina (Machine Learning) tiene amplia aplicación en diferentes procesos y

en diferentes áreas, se define como un proceso automatizado que extrae patrones de los datos; es un subcampo importante de la Inteligencia Artificial, tecnología de gran importancia dentro de la Industria 4.0, por esto, es relevante para el Centro de Formación y el Grupo de Investigación GICS generar capacidades internas que le permitan cerrar brechas de conocimiento en estas tecnologías.

En Machine Learning existen varios tipos de aprendizaje, para el caso del trabajo presentado, se ha empleado el aprendizaje supervisado, el cual, generalmente comienza con un conjunto establecido de datos y una cierta comprensión de cómo se clasifican esos datos. El aprendizaje supervisado está destinado a encontrar patrones en los datos que se pueden aplicar a un proceso de análisis. Existen dos tipos principales de aprendizaje supervisado; clasificación y regresión. La clasificación es el lugar donde se entrena a un algoritmo para clasificar los datos de entrada en variables discretas.

La clasificación es un enfoque de aprendizaje supervisado, que puede interpretarse como un medio de categorización (o clasificación) de algunos elementos desconocidos en un conjunto discreto de clases. Un clasificador es un algoritmo que recibiendo como entrada cierta información de un objeto, es capaz indicar la categoría o clase a la que pertenece de entre un número acotado de clases posibles. El desarrollo de este trabajo está orientado al diseño de un clasificador de defectos de paneles solares fotovoltaicos a partir de imágenes de electroluminiscencia.

Las grietas y microgrietas (fisuras y microfisuras) son los defectos más comunes de los paneles solares fotovoltaicos, sin embargo, existen otro tipo de defectos como dislocaciones de cristal, manchas, dedos cortados (interrupciones de los dedos), que sin ser todos los posibles defectos que pueden llegar a tener los paneles solares, son los contemplados dentro del alcance del diseño presentado.

Referencias Bibliográficas

- Ahmad, J., Ciocia, A., Fichera, S., Murtaza, A. F., & Spertino, F. (2019). *Detection of typical defects in silicon photovoltaic modules and application for plants with distributed MPPT configuration*. *Energies*, 12, 1–26. <https://doi.org/10.3390/en12234547>
- Gavilan, I. (2017). *Clasificadores: el encuentro entre Data Science, Machine Learning y Redes Neuronales*. *Clasificadores: El Encuentro Entre Data Science, Machine Learning y Redes Neuronales*. <http://bluechip.ignaciogavilan.com/2017/06/clasificadores-el-encuentro-entre-data.html#.YZ0Pe9DMLIU>
- Haba, C. G. (2019). *Monitoring Solar Panels using Machine Learning Techniques*. *Proceedings of 2019 8th International Conference on Modern Power Systems, MPS 2019*. <https://doi.org/10.1109/MPS.2019.8759651>
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning*. In *Journal of the American Society for Information Science* (Vol. 35, Issue 5). John Wiley & Sons, Inc.
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics* (T. M. Press, Ed.). The MIT Press.
- Köntges, M., Kurtz, S., Packard, C. E., Jahn, U., Berger, K., Kato, K., Friesen, T., Liu, H., & Van Iseghem, M. (2014). *Review of failures of photovoltaic modules*. In *IEA-Photovoltaic Power Systems Programme*. International Energy Agency.
- Salazar-Peralta, A., Pichardo-Salazar, A., Pichardo-Salazar, U., & Chavez, R. H. (2018). *Estudio para detección de defectos en Paneles Solares por medio de la Técnica de Electroluminiscencia*. *Revista de Ingeniería Eléctrica*, 2(5), 1–9.

SAP Insights. (2022). ¿Qué es machine learning? ¿Qué Es Machine Learning? - Definición, Tipos y Ejemplos. <https://www.sap.com/latinamerica/insights/what-is-machine-learning.html>