

**Desarrollo de un Modelo para la Detección Automática de Fallas en Sistemas Solares
Fotovoltaicos a Gran Escala Asociados a la Empresa Ingeniería Creativa – ICREA S.A.S.**

Trabajo presentado como requisito para optar por el título de Ingeniero Electricista

César Augusto Sierra Torres

Director: PhD. Oscar Arnulfo Quiroga Quiroga
Codirector: MBA. Rolando Andrés Rincón Saravia

Universidad Industrial de Santander
Facultad de Ingenierías Fisicomecánicas
Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones
Bucaramanga, Santander, Colombia
2024

Dedicatoria

A mis padres, Carmenza y Danilo, hermano, Manuel y sobrina, Lauren, por su amor incondicional y apoyo constante en cada paso de mi vida. Su fe en mis capacidades ha sido la chispa que me ha impulsado a alcanzar mis metas. Gracias por estar siempre allí para ofrecermme aliento y por sacrificar tanto para brindarme las oportunidades que tengo hoy. A mis profesores, quienes con su pasión por la ingeniería y su dedicación en la enseñanza han sido una fuente constante de inspiración. Cada consejo y cada lección han sido fundamentales para mi desarrollo académico y profesional.

A mis compañeros de estudio y amigos, por los momentos compartidos, la colaboración y el apoyo mutuo que han hecho de este proceso una experiencia memorable.

A la empresa Ingeniería Creativa ICREA S.A.S. por abrirme las puertas y confiar en mis capacidades brindándome la oportunidad de desarrollar mi practica y colaborar en proyectos que fueron esenciales para mi desarrollo profesional.

Y, finalmente, a mí mismo, por la perseverancia y el esfuerzo dedicados a lo largo de estos años. Este trabajo es testimonio de la pasión y el compromiso con los que he abordado cada desafío y cada oportunidad.

Tabla de Contenidos

Introducción	7
1. Objetivos.....	9
1.1. Objetivo General	9
1.2. Objetivos Específicos.....	9
2. Identificación de Estrategias y Modelos Desarrollados	10
3. Modelo de Machine Learning Propuesto.....	13
3.1. Primera Parte: Exploración de la planta donde se va a implementar el modelo.	13
3.2. Segunda Parte: Análisis de datos meteorológicos y eléctricos.....	14
3.3. Tercera Parte: Construcción del modelo.	15
4. Validación de Desempeño del Modelo Propuesto	19
4.1. Primera etapa: Comparación de resultados	19
4.2. Segunda etapa: Análisis de desempeño	19
4.3. Tercera etapa: Validación Cruzada	19
4.4. Resultados Obtenidos	20
4.5. Limitaciones en inversores:	20
4.6. Inversores apagados:	23
4.7. Conjunto de inversores anómalos:	24
5. Conclusiones y Recomendaciones	26
Referencias	28

Tabla de Imágenes

Figura 1. Configuración de la planta.....	13
Figura 2: Datos meteorológicos proporcionados	14
Figura 3: Datos eléctricos proporcionados.	15
Figura 4: Días y horas a las cuales se presentaron Outliers.....	16
Figura 5: Documento generado por el modelo.	17
Figura 6: Diagrama de flujo del modelo propuesto.	18
Figura 7: Comportamiento anormal de los inversores.	20
Figura 8: Comportamiento de limitación de energía en los inversores.	21
Figura 9: Comportamiento de limitación de energía en los inversores a largo plazo.	22
Figura 10: Comportamiento de la potencia del inversor vs Comportamiento de la planta.....	22
Figura 11: Comportamiento anormal de inversores apagados.	24
Figura 12: Comportamientos anormales de la planta.	25

Resumen

Título: Desarrollo de un Modelo para la Detección Automática de Fallas en Sistemas Solares Fotovoltaicos a Gran Escala Asociados a la Empresa Ingeniería Creativa – ICREA S.A.S.

Autor: César Augusto Sierra Torres

Palabras Clave: Transición energética, Energías renovables, Sostenibilidad energética, Emisiones de gases de efecto invernadero, Energía eléctrica, Sistemas solares fotovoltaicos, Optimización de sistemas energéticos, Detección de fallas, Mantenimiento proactivo, Machine learning, Datos eléctricos y ambientales, Irradiancia (GHI y POA), Análisis de datos, Plantas solares, ICREA S.A.S., Eficiencia operativa

La investigación se enfoca en el desarrollo de un modelo automático para la detección de fallas en sistemas solares fotovoltaicos, un componente crucial para optimizar la eficiencia de estos sistemas y minimizar costos asociados a fallos imprevistos.

El problema principal radica en la dificultad de detectar y gestionar fallas en plantas solares fotovoltaicas, debido a la influencia de variables eléctricas, meteorológicas y físicas. La solución propuesta consiste en crear un modelo de machine learning que analice datos eléctricos y ambientales para identificar anomalías y prever fallos potenciales antes de que ocurran. Puntualmente este modelo analiza los datos de energía medida en la salida de los inversores y de irradiancia GHI y POA, para crear una relación entre estos dos datos y poder caracterizar los comportamientos inusuales. Este modelo pretende mejorar la eficiencia operativa al reducir tiempos de inactividad y optimizar el mantenimiento.

Los resultados obtenidos incluyen la implementación efectiva del modelo en una planta solar activa en Colombia, la identificación y caracterización de tres tipos de fallas importantes como lo son desconexión repentina de los inversores, limitaciones en los inversores y comportamientos anómalos en un grupo de inversores. La solución tiene el potencial de transformar la gestión de sistemas solares en Colombia, promoviendo una transición energética más eficiente y sostenible.

Abstract

Title: Development of a Model for the Automatic Fault Detection in Large-Scale Photovoltaic Solar Systems Associated with the Company Ingeniería Creativa – ICREA S.A.S.

Author: César Augusto Sierra Torres

Keywords: Energy transition, Renewable energy, Energy sustainability, Greenhouse gas emissions, Electric power, Photovoltaic solar systems, Energy systems optimization, Fault detection, Proactive maintenance, Machine learning, Electrical and environmental data, Irradiance (GHI and POA), Data analysis, Solar plants, ICREA S.A.S., Operational efficiency

The research focuses on developing an automated model for fault detection in photovoltaic solar systems, a crucial component for optimizing the efficiency of these systems and minimizing costs associated with unexpected failures.

The main problem lies in the difficulty of detecting and managing faults in photovoltaic solar plants due to the influence of electrical, meteorological, and physical variables.

The proposed solution involves creating a machine learning model that analyzes electrical and environmental data to identify anomalies and predict potential failures before they occur.

Specifically, this model analyzes energy data measured at the inverter output and irradiance data (GHI and POA) to establish a relationship between these two data points and characterize unusual behaviors.

The model aims to improve operational efficiency by reducing downtime and optimizing maintenance.

The results obtained include the effective implementation of the model in an active solar plant in Colombia, the identification and characterization of three significant types of faults: sudden disconnection of inverters, limitations in inverters, and anomalous behaviors in a group of inverters.

The solution has the potential to transform the management of solar systems in Colombia, promoting a more efficient and sustainable energy transition.

Introducción

En el contexto actual de transición energética, Colombia se enfrenta a un desafío crucial: avanzar hacia un modelo energético más sostenible y eficiente. Con una población en crecimiento y una economía en expansión, el país necesita urgentemente adoptar fuentes de energía limpias. Las estadísticas son elocuentes: Colombia ocupa el cuarto lugar en emisiones de gases de efecto invernadero en América Latina, y el sector energético es responsable de más del 60% de estas emisiones.

A pesar de los avances, el 40% de la energía eléctrica del país todavía proviene de fuentes no renovables, destacando la necesidad apremiante de acelerar la transición hacia energías renovables.

En este contexto, la empresa INGENIERIA CREATIVA – ICREA S.A.S. juega un papel fundamental al ofrecer soluciones innovadoras para el sector energético. Especializada en la optimización de sistemas energéticos, ICREA S.A.S. se enfrenta al reto de mejorar la gestión y mantenimiento de sistemas solares fotovoltaicos. La detección temprana de fallas es esencial para mantener el rendimiento óptimo y minimizar los tiempos de inactividad en estos sistemas, que son vitales para la sostenibilidad energética.

Las inspecciones manuales, aunque útiles, presentan limitaciones significativas, incluyendo retrasos en la identificación de problemas y costos elevados de mantenimiento. Para abordar estos desafíos, este trabajo de grado propone el desarrollo de un modelo automático de detección de fallas utilizando técnicas de machine learning. El objetivo es analizar datos eléctricos y ambientales, como la energía medida en la salida de los inversores y los datos de irradiancia (GHI y POA), para identificar anomalías y prever fallos potenciales antes de que ocurran.

El modelo propuesto se centra en clasificar y analizar datos de variables eléctricas y meteorológicas para detectar patrones inusuales y gestionar de manera proactiva el mantenimiento de los sistemas solares. La implementación de este modelo permitirá a ICREA S.A.S. optimizar el rendimiento de las plantas solares, reduciendo tiempos de inactividad y costos asociados, y proporcionando una base de datos sólida para una toma de decisiones más informada.

En resumen, en un momento crucial para la transformación energética en Colombia, ICREA S.A.S. se posiciona como un líder en la búsqueda de soluciones avanzadas y sostenibles. Este trabajo de grado no solo representa un avance en la eficiencia operativa de los sistemas solares, sino que también contribuye a una transición energética más eficiente y resiliente para el país.

1. Objetivos

1.1. Objetivo General

Desarrollar un modelo de detección automática de fallas en sistemas solares fotovoltaicos a gran escala atendiendo los lineamientos de la empresa INGENIERIA CREATIVA – ICREA S.A.S.

1.2. Objetivos Específicos

- Identificar estrategias y modelos desarrollados para la detección de fallas en sistemas fotovoltaicos a partir de mediciones de variables eléctricas y ambientales en el sistema.
- Proponer un modelo que se adapte a los datos que son monitorizados por ICREA S.A.S. para la detección automática de fallas en sistemas fotovoltaicos.
- Validar el desempeño del modelo propuesto para la detección automática de fallas a partir de datos y eventos de falla recopilados en granjas solares en operación.

2. Identificación de Estrategias y Modelos Desarrollados

En el presente capítulo, se lleva a cabo una revisión de la literatura científica referente a la detección y descripción de fallas en sistemas solares fotovoltaicos. Con el propósito de lograr una visión comprensiva y fundamentada, se realizó una consulta en bases de datos académicas, tales como IEEE XPLORER, OXFORD ACADEMIC y ScienceDirect, entre otras. Esta revisión se centra en artículos que abordan tanto las estrategias implementadas para la detección de fallas como los modelos desarrollados para su identificación, empleando técnicas avanzadas de machine learning y métodos estadísticos. El objetivo primordial fue construir un marco teórico robusto que sirvió de guía para el desarrollo del presente proyecto.

La importancia de la identificación, análisis de estrategias y modelos radica en la necesidad de abordar el tema de investigación de manera informada y efectiva. Comprender las metodologías previamente utilizadas y los enfoques que han demostrado ser eficaces proporciona una base sólida sobre la cual construir el proyecto. Además, un conocimiento exhaustivo sobre las fallas en sistemas solares fotovoltaicos y los métodos de detección empleados posibilita una perspectiva más amplia y precisa, facilitando la implementación de un enfoque adecuado.

En el contexto de este proyecto, se entiende por estrategia el enfoque o método utilizado por diversos autores para abordar la detección y descripción de fallas en sistemas solares fotovoltaicos. Los criterios de evaluación para la selección de las estrategias más pertinentes se basan en su capacidad para utilizar datos de variables meteorológicas y eléctricas disponibles, los cuales son fundamentales para el desarrollo del proyecto. La aplicabilidad y efectividad de estas estrategias deben ser valoradas en función del contexto específico de los sistemas fotovoltaicos.

Entre las estrategias identificadas, se destaca la propuesta de (Venkatakrishnan y otros, 2013), quienes realizan una revisión exhaustiva de técnicas para la detección, localización y diagnóstico de fallas en sistemas solares fotovoltaicos. Su estrategia se

basa en una combinación de análisis de datos de rendimiento del sistema y técnicas avanzadas de diagnóstico. La revisión incluye metodologías diversas, tales como el análisis de la curva I-V y la comparación de datos históricos, para identificar anomalías y fallas con precisión. En otro ámbito (AbdukMawjood y otros, 2018) presentan una revisión sobre la detección y predicción de fallas en arreglos fotovoltaicos, destacando el uso de modelos predictivos para anticipar posibles fallas y mitigar el tiempo de inactividad del sistema.

El informe técnico elaborado por (China General Certification Center and Huawei Technologies Co., 2020) aborda el diagnóstico de curvas I-V, una técnica esencial para la evaluación del rendimiento de módulos fotovoltaicos y la identificación de fallas. Esta estrategia proporciona una metodología estandarizada para el análisis técnico de los sistemas. Finalmente, el informe del (Kontges y otros, 2014) revisa los fallos comunes en módulos fotovoltaicos, proporcionando una visión detallada sobre las fallas más frecuentes y sus causas, enfocándose en la caracterización y prevención de fallas para mejorar la confiabilidad y durabilidad de los sistemas fotovoltaicos.

Por otro lado, entre los modelos identificados, el de (Jordan & Hansen, 2023) emplea regresión múltiple para el análisis de la degradación en condiciones de cielo despejado. La técnica de regresión se utiliza para identificar patrones de degradación en los sistemas fotovoltaicos, basándose en datos históricos y variables meteorológicas. Por su parte, el modelo de (Reno & Hansen, 2016) está diseñado para identificar períodos de irradiancia en cielo despejado en series temporales de mediciones de GHI (Global Horizontal Irradiance). Utiliza análisis estadísticos para mejorar la precisión en la detección de períodos de alta irradiancia, crucial para la evaluación del rendimiento del sistema fotovoltaico.

Los modelos de (Jordan & Hansen, 2023) y (Reno & Hansen, 2016) ofrecen enfoques diferentes pero complementarios para el análisis de datos de irradiancia. Ambos modelos proporcionan herramientas valiosas para la detección y diagnóstico de fallas, cada uno con su propio conjunto de fortalezas.

La revisión documental ha proporcionado una comprensión detallada de las estrategias y modelos utilizados en la detección de fallas en sistemas solares fotovoltaicos. La integración de las estrategias revisadas revela un enfoque común hacia el análisis de datos y técnicas avanzadas de diagnóstico. Los modelos

analizados refuerzan la importancia de utilizar datos de irradiancia y variables meteorológicas para mejorar la precisión en la detección de fallas. Esta información resulta crucial para el desarrollo de un enfoque eficaz en el proyecto, proporcionando una base sólida sobre la cual construir.

La revisión de estrategias y modelos desarrollados en la literatura ha revelado una amplia gama de métodos y enfoques para la detección de fallas en sistemas solares fotovoltaicos. Los artículos revisados ofrecen una visión integral de los tipos de fallas, las técnicas de diagnóstico empleadas y los resultados obtenidos. Esta información establece las bases para la implementación de un programa de detección de fallas, orientando el desarrollo hacia una metodología efectiva y basada en evidencia. Los hallazgos destacan la importancia de adoptar un enfoque multifacético que combine técnicas de análisis de datos con modelos predictivos y estadísticos. La identificación precisa de fallas y la comprensión de sus implicaciones permitirá desarrollar un sistema de monitoreo y diagnóstico más robusto y eficiente, mejorando la confiabilidad y el rendimiento de los sistemas fotovoltaicos.

3. Modelo de Machine Learning Propuesto

El modelo propuesto consta de tres partes importantes:

3.1. Primera Parte: Exploración de la planta donde se va a implementar el modelo.

La planta se encuentra ubicada en el departamento del Valle del Cauca en Colombia, tiene una capacidad instalada de 9.8 MW y entro en operación desde finales del año 2018 hasta la actualidad.

Es una planta de generación solar conectada a la red, con una configuración de 9 inversores centralizados de la marca ABB, tal como se muestra en la figura 1. Los módulos fotovoltaicos empleados fueron módulos de silicio policristalino de 330 W de la marca JINKO SOLAR con un total de 34560. Las fichas técnicas de estos elementos serán presentadas como anexos.

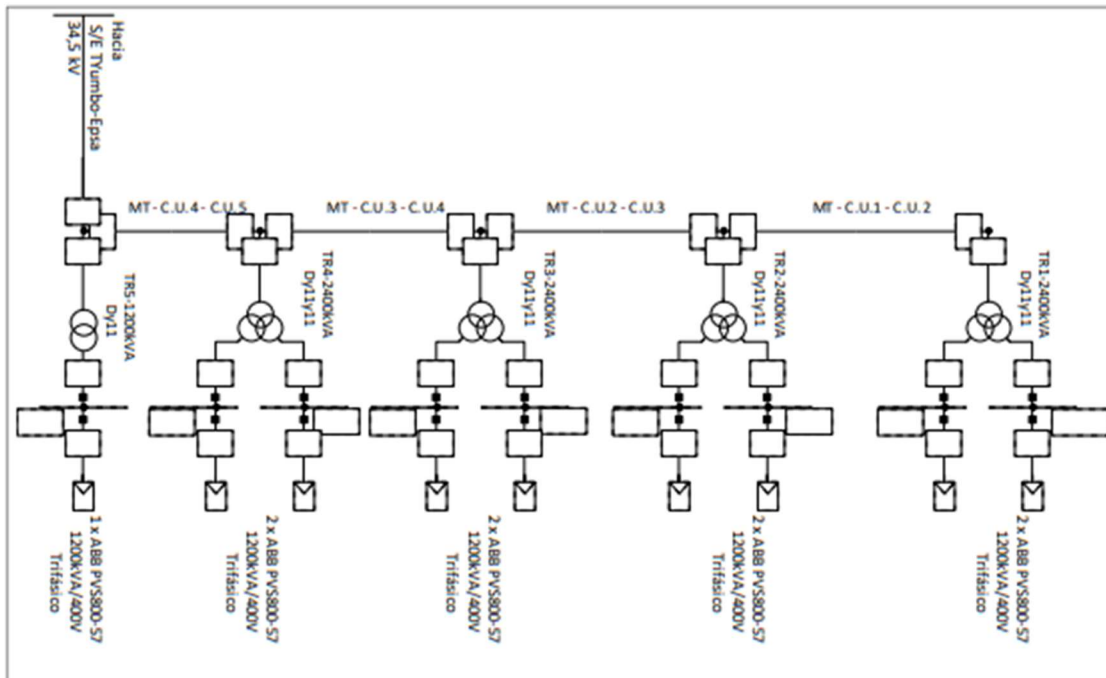


Figura 1. Configuración de la planta.

Nota: El grafico representa el diagrama unifilar de la planta analizada.

3.2. Segunda Parte: Análisis de datos meteorológicos y eléctricos.

La segunda parte y eje fundamental del modelo propuesto es el análisis de los datos meteorológicos y eléctricos existentes.

Los datos meteorológicos proporcionados por la empresa fueron: Irradiancia global horizontal (GHI) [W/m^2], Irradiancia en plano de arreglo (POA) [W/m^2], temperatura de modulo [$^{\circ}C$] y temperatura ambiente [$^{\circ}C$]. Se proporcionaron los datos en formato cincominutal desde el año 2021 hasta el año 2023, con 105.120 datos por año. Estos datos fueron medidos en sitio por medio de estaciones meteorológicas de propiedad de la empresa.

Fecha y hora	GHI	POA	T mod	T mod	POA	T amb	T amb
1/01/2022 6:05	-0,456	-0,91	32,94	20,5	-0,364	20,33	21,6
1/01/2022 6:10	0	-0,788	33,006	20,58	0	20,41	21,6
1/01/2022 6:15	0	0	33,1	20,61	0	20,5	21,6
1/01/2022 6:20	1,094	0,396	33,134	20,7	1,002	20,52	21,6
1/01/2022 6:25	2,184	1,152	33,13	20,7	2,002	20,6	21,62
1/01/2022 6:30	0,91	0	29,79	20,74	0,91	20,63	21,69
1/01/2022 6:35	1,638	0,668	33,15	20,85	1,548	20,76	21,69
1/01/2022 6:40	3,55	2,64	33,2	20,97	3,55	20,88	21,7
1/01/2022 6:45	5,55	4,642	33,2	21,02	5,46	20,96	21,7
1/01/2022 6:50	7,554	6,462	33,27	21,1	7,462	21	21,7

Figura 2: Datos meteorológicos proporcionados.

Nota: El grafico representa los datos meteorológicos proporcionados para el desarrollo del proyecto.

Los datos eléctricos proporcionados por la empresa fueron: Energía producida por intervalo (kWh) de nueve inversores los cuales componen la planta solar que fue usada en el análisis. De igual forma los datos se proporcionaron en formato cincominutal desde el año 2021 hasta el año 2023, con 105.120 datos por año.

Fecha y hora	E_INV1	E_INV2	E_INV3	E_INV4	E_INV5	E_INV6	E_INV7	E_INV8	E_INV9
1/01/2022 6:05	0	0	0	0	0	0	0	0	0
1/01/2022 6:10	0	0	0	0	0	0	0	0	0
1/01/2022 6:15	0	0	0	0	0	0	0	0	0
1/01/2022 6:20	-0,074	-0,068	-0,09	-0,094	-0,081	-0,068	-0,078	-0,063	-0,081
1/01/2022 6:25	-0,029	-0,023	-0,033	-0,04	-0,029	-0,028	-0,029	-0,031	-0,029
1/01/2022 6:30	-0,151	-0,148	-0,165	-0,165	-0,17	-0,158	-0,154	-0,17	-0,17
1/01/2022 6:35	-0,083	-0,085	-0,086	-0,079	-0,11	-0,079	-0,083	-0,102	-0,093
1/01/2022 6:40	0,094	0,089	0,072	0,079	0,063	0,085	0,091	0,068	0,072
1/01/2022 6:45	0,251	0,243	0,249	0,251	0,217	0,259	0,252	0,239	0,241
1/01/2022 6:50	0,097	0,096	0,137	0,14	0,123	0,107	0,091	0,131	0,13

Figura 3: Datos eléctricos proporcionados.

Nota: El grafico representa los datos electricos proporcionados para el desarrollo del proyecto.

3.3. Tercera Parte: Construcción del modelo.

En conjunto con el equipo ICREA, luego de exponer las ideas importantes de los artículos anteriormente consultados, complementar con ideas propias de cada uno de los miembros del equipo y revisar los datos disponibles para trabajar, se estableció un modelo que iba a generar una revisión general de todos los datos de acotándolos de forma diaria de 06:00 a 18:00 h en el cual se generaba una correlación entre la irradiancia GHI medida en sitio ese día y la energía producida por cada inversor, adicionalmente realizaba un análisis de la temperatura de modulo. El modelo se desarrolló en Python y en la primera fase de desarrollo, nos imprimía un diagrama de barras donde, el tamaño de estas barras nos indicaba la cantidad de energía producida en ese intervalo de tiempo, El color mostraba la temperatura de modulo y nos mostraba una barra negra adicional que indicaba la desviación estándar de la correlación que se había planteado. El modelo tiene la capacidad de solo imprimirnos en este diagrama solamente los días y a las horas en los que se presentaron desviaciones estándar altas las cuales fueron catalogadas como outliers o valores atípicos como se muestra en la figura 4.




Figura 4: Días y horas a las cuales se presentaron Outliers.

Nota: El grafico representa el primer resultado obtenido por el modelo el cual nos imprime los días y las horas a las cuales se presentan outliers.

Luego de desarrollar esta primera fase del modelo, nos centramos en analizar los días que nos imprimió el programa y en crear una segunda fase que nos muestre gráficamente ese instante de tiempo que nos marcó el programa. Para lograr esto, utilizamos el mismo principio de la correlación y pedimos al programa que nos imprimiera la gráfica la energía de salida de los inversores en color azul, pero el valor atípico o outlier lo graficara en color verde y así poder identificar visualmente la falla.

También nos imprime la temperatura de modulo en el instante de tiempo en el que se produce el outlier.

Y por último una gráfica comparativa en donde se imprime la irradiancia optima esperada en color azul y la irradiancia GHI medida en sitio en color verde.

El modelo nos imprime un documento donde muestra las tres graficas mencionadas anteriormente como lo muestra la figura 5.

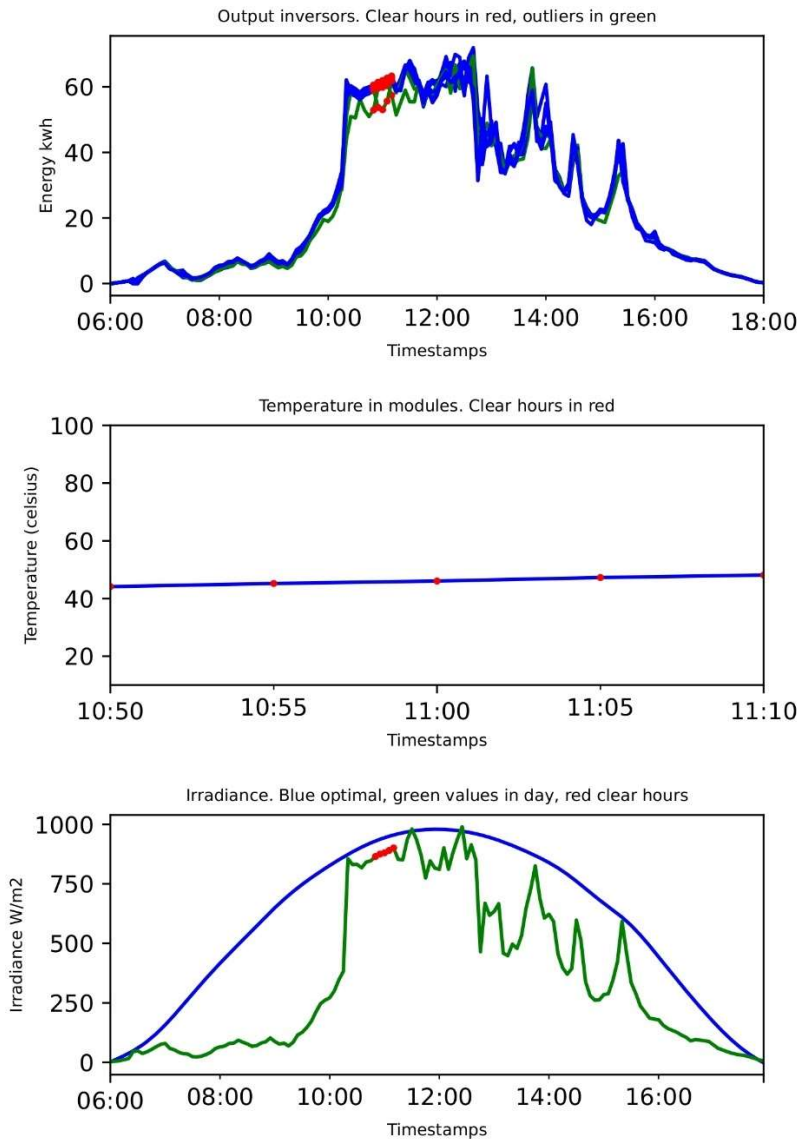


Figura 5: Documento generado por el modelo.

Nota: El grafico representa la impresión de las graficas de datos de manera diaria generadas por el programa.

Luego de concretar esta segunda fase, se procedió a realizar el análisis de cada uno de los días que nos filtró el programa y poder caracterizar porque sucedían estos outliers.

Para mayor comprensión se presenta el siguiente diagrama de flujo, el cual resume todo el modelo propuesto.

MODELO DE MACHINE LEARNING PROPUESTO

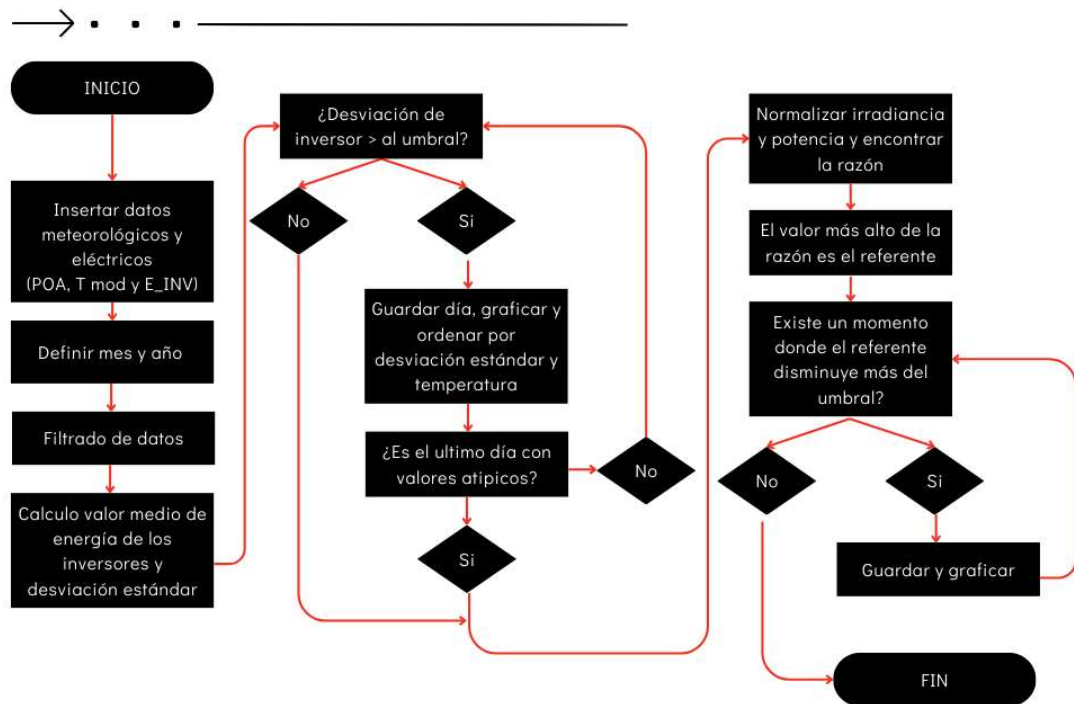


Figura 6: Diagrama de flujo del modelo propuesto.

Nota: El grafico representa un diagrama de flujo que explica el funcionamiento del modelo.

4. Validación de Desempeño del Modelo Propuesto

La validación del modelo de detección automática de fallas en sistemas solares fotovoltaicos es un paso crucial para asegurar su efectividad y confiabilidad en entornos operativos reales. Este capítulo detalla los métodos y resultados de la validación del modelo propuesto, el cual se fundamenta en el análisis de datos eléctricos y meteorológicos de la planta solar anteriormente mencionada, ubicada en el departamento del Valle del Cauca, Colombia.

La validación de este modelo se llevo acabo en tres etapas principales:

4.1. Primera etapa: Comparación de resultados

Se realizo una comparación entre los resultados generados por el modelo y los datos históricos de fallas recopilados de la planta. Esto incluyó la identificación de anomalías detectadas por el modelo y su correspondencia con eventos de falla documentados.

4.2. Segunda etapa: Análisis de desempeño

Se utilizaron un conjunto de métricas de desempeño, como la precisión, la tasa de verdaderos positivos y la tasa de falsos positivos, para evaluar la efectividad del modelo en la identificación de fallas.

4.3. Tercera etapa: Validación Cruzada

Se aplico la técnica de validación cruzada para asegurar que el modelo generalizara adecuadamente a diferentes conjuntos de datos. Esto implicó dividir los datos disponibles en subconjuntos y utilizar algunos para entrenar el modelo y otros para probar su rendimiento.

4.4. Resultados Obtenidos

Los resultados obtenidos del modelo fueron analizados en relación con los eventos de falta identificados en la planta. Se observaron los siguientes hallazgos:

4.5. Limitaciones en inversores:

El modelo analizó los datos meteorológicos y de energía proporcionados para los años 2021, 2022, 2023 y 2024 identificando un patrón de comportamiento anormal en los inversores que comienza en septiembre de 2022 y limita la energía entregada por ciertos inversores en particular. Específicamente el 23 de septiembre de 2022, el inversor 4.1 presenta una limitación en la energía entregada que no supera los 774 kWh, lo cual contrasta con el comportamiento esperado según la irradiancia y se aleja del rendimiento de los otros inversores, como se muestra a continuación.

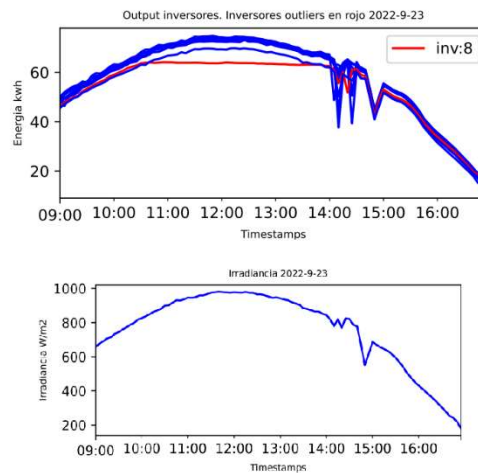


Figura 7: Comportamiento anormal de los inversores.

Nota: El grafico representa un comportamiento anómalo encontrado por el programa.

Este comportamiento limitante en la energía se mantiene constante en el inversor 4.1 y, a partir de octubre de 2023, este comportamiento se replica en los inversores 1.1, 1.2, 2.1 y 4.2, todos situados en el mismo límite de 774 kWh. A continuación, se puede observar como el comportamiento limitante se ha propagado a los otros inversores mencionados para octubre de 2023.

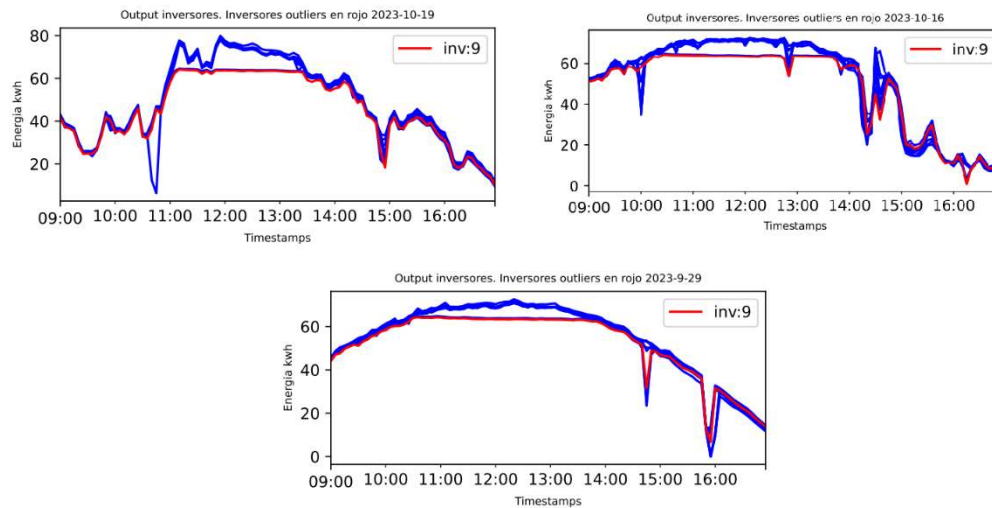


Figura 8: Comportamiento de limitación de energía en los inversores.

Nota: El grafico representa un comportamiento anómalo encontrado por el programa.

Si se evalúa el comportamiento de los inversores a largo plazo, se puede observar que la limitación de energía se vuelve más evidente, lo que conlleva una pérdida del recurso solar, ya que la planta no opera a su máxima capacidad para entregar energía en su punto de inyección. Por lo tanto, se descarta una limitación por curtailment, como se muestra a continuación.

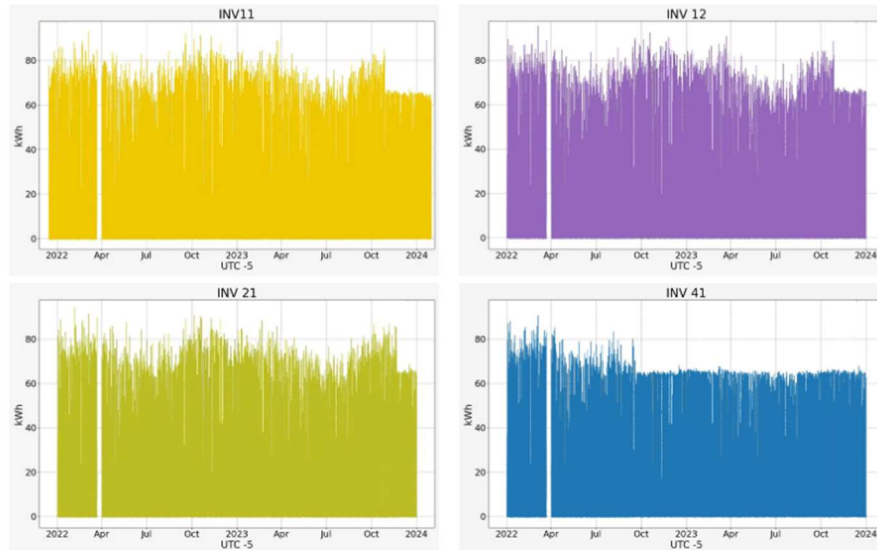


Figura 9: Comportamiento de limitación de energía en los inversores a largo plazo.
 Nota: El grafico representa un comportamiento anómalo encontrado por el programa.

En la imagen siguiente se puede observar cómo el inversor 4.1 está limitado a 744 kWh, a pesar de que la planta no supera su límite de inyección de energía a la red de 9800 kWh.

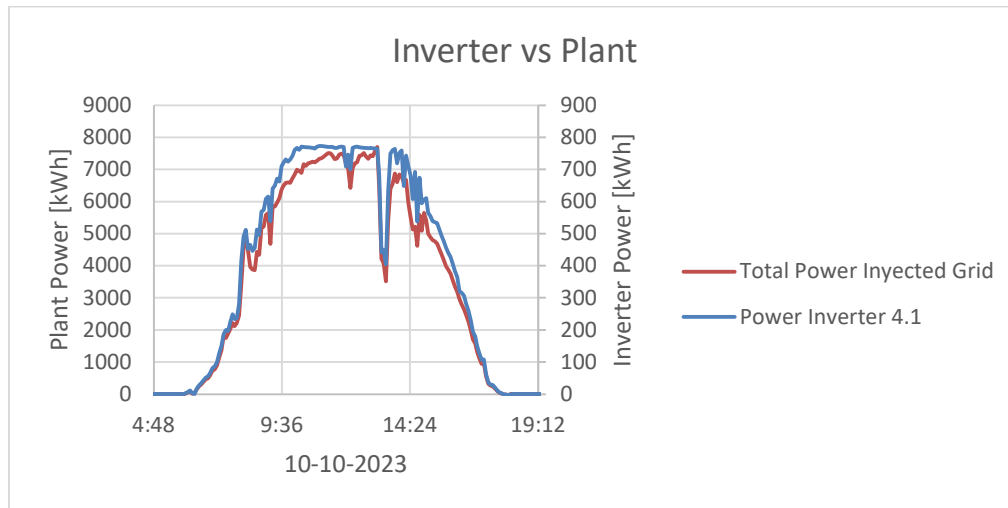


Figura 10: Comportamiento de la potencia del inversor vs Comportamiento de la planta.
 Nota: El grafico representa una comparación entre la energía producida por un inversor y la energía producida por la planta.

En conjunto con el equipo ICREA, se propuso las siguientes hipótesis del comportamiento anormal de la limitación en los inversores. Sin embargo, se sugiere llevar a cabo un análisis más detallado para obtener claridad sobre las causas de las fallas y también sus posibles soluciones:

- Limitación programada en el controlador de la planta.
- Fallo en los strings conectados a los inversores limitados.
- Degradación de los inversores.

4.6. Inversores apagados:

El modelo desarrollado, también detecto comportamientos anómalos en los inversores que ocurren sin un patrón específico; sin embargo, son repetitivos y afectan directamente el rendimiento de la planta. Este es el caso de los inversores que presentan una caída espontánea en la producción de energía, a pesar de que los niveles de irradiancia son normales y otros inversores están operando correctamente. Este comportamiento es especialmente evidente en los inversores 5.1, 3.1 y 3.2, con una mayor recurrencia de este tipo de fallas en los meses de julio y agosto de 2023. A continuación, se presenta el comportamiento anómalo de los inversores que reducen su producción de energía a 0.




Figura 11: Comportamiento anormal de inversores apagados.

Nota: El grafico representa un comportamiento anómalo encontrado por el programa.

El comportamiento anómalo detectado por el programa sugiere que no existe una correlación fuerte entre la temperatura y el apagado de los inversores, lo que podría ser la primera hipótesis sobre la causa de este bajo rendimiento en los inversores. Sin embargo, se sugiere realizar un análisis más detallado con mediciones reales en el sitio para abordar las causas del problema detectado. En conjunto con el equipo ICREA, se propuso las siguientes hipótesis:

- Configuración incorrecta del controlador.
- Conexiones eléctricas defectuosas en la planta.
- Deterioro de los inversores.

4.7. Conjunto de inversores anómalos:

El modelo desarrollado, también permite detectar días en los que los comportamientos anómalos no son atribuibles a un inversor en particular o a un grupo de ellos, sino al conjunto completo. Esto facilita la identificación de momentos en los que la planta, en general, se comportó de manera inesperada.

Los casos más notorios de estos comportamientos fueron detectados en el año 2022. El 15 junio, se observó que la potencia de la planta fluctuaba más abruptamente que la irradiancia. En el caso del 13 de agosto, toda la planta presentó una caída a 0 kWh, en la energía entregada desde las 10:40 a.m. hasta la 01:40 p.m., a pesar de que las condiciones de irradiancia y temperatura no se encontraban fuera de los rangos normales. Esto sugiere una falla mucho más pronunciada en la planta, que también podría ser atribuible a procesos de maniobra, desconexiones o dallas significativas que comprometen el funcionamiento general de la planta. A continuación, se muestran estos comportamientos anómalos de la planta:

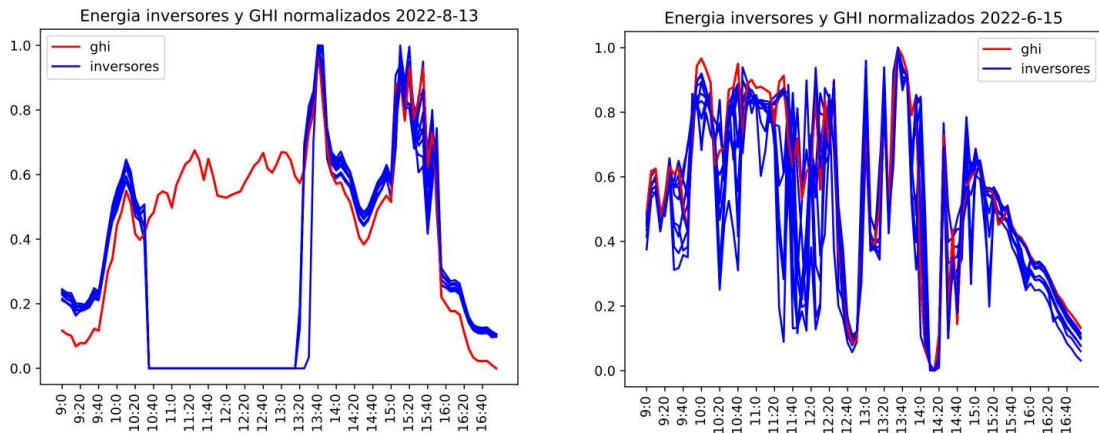


Figura 12: Comportamientos anómalos de la planta.

Nota: El grafico representa un comportamiento anómalo encontrado por el programa.

Finalmente, el modelo desarrollado es capaz de generar un archivo con la información de todos los días en los cuales la planta presento un comportamiento adecuado, conforme a lo esperado. Esto permite realizar análisis más profundos que son esenciales para cumplir con los requisitos regulatorios de las plantas solares en Colombia.

5. Conclusiones y Recomendaciones

- La implementación de un modelo de detección automática de fallas en sistemas solares fotovoltaicos es crucial en el contexto de la transición energética en Colombia. La necesidad de optimizar el rendimiento de las plantas solares se alinea con los objetivos nacionales de descarbonización y sostenibilidad.

- El modelo desarrollado ha demostrado ser efectivo en la identificación de anomalías en la producción de energía de los inversores, proporcionando herramientas útiles para la gestión proactiva del mantenimiento. La capacidad de correlacionar datos meteorológicos y eléctricos permiten un análisis más detallado y preciso de las condiciones operativas de la planta.

- La validación del modelo a través de la comparación con datos históricos ha revelado patrones significativos en el comportamiento de los inversores. Se identificaron limitaciones de energía y comportamientos anómalos, lo que sugiere la necesidad de intervenciones técnicas para mejorar la eficiencia operativa. La correlación entre los datos de irradiancia y producción de energía confirma la utilidad del modelo en la predicción de fallas.

- Las hipótesis propuestas para explicar los comportamientos anómalos, como limitaciones programadas y fallas en los strings, ofrece una base para investigaciones futuras. La posibilidad de detallar las causas subyacentes permitirá implementar soluciones adecuadas, mejorando la confiabilidad y durabilidad de los sistemas fotovoltaicos.

- Este trabajo no solo contribuye al conocimiento académico sobre la detección de fallas en sistemas solares, sino que también proporciona una herramienta práctica para empresas como INGENIERIA CREATIVA – ICREA S.A.S. La implementación de este modelo permitirá optimizar la gestión del mantenimiento y por ende maximizar la producción de energía.

- Se sugiere continuar el desarrollo del modelo incorporando algoritmos de machine learning más avanzados y explorando la integración de tecnologías IoT para un monitoreo en tiempo real. Además, se recomienda realizar estudios adicionales para validar el modelo en diferentes condiciones operativas y en otras plantas solares del país.

Referencias

- AbdukMawjood, K., Shady S, R., & Walid G, M. (2018). Detection and Prediction of Faults in Photovoltaic Arrays: A Review. *2018 IEEE 12th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG 2018)*. <https://doi.org/10.1109/CPE.2018.8372609>
- Agudelo, J. (06 de Mayo de 2022). Obtenido de <https://www.bancolombia.com/empresas/capital-inteligente/tendencias/sostenibilidad/como-avanza-la-transicion-energetica-en-colombia>
- China General Certification Center and Huawei Technologies Co. (2020). *Smart I-V Curve Diagnosis*.
- Jordan, D., & Hansen, C. (2023). *Clear-sky detection for PV degradation analysis using multiple regression*. Renewable Energy.
- Kontges, M., Kurtz, S., Packard, C., Jahn, U., Berger, K., Kato, K., & Friesen, T. (2014). *Review of Failures of Photovoltaic Modules*. Report IEA-PVPS T13-01:2014.
- Parson, C. (28 de September de 2021). Obtenido de <https://la.blogs.nvidia.com/blog/que-es-un-modelo-de-machine-learning/#:~:text=%C2%BFQu%C3%A9%20Es%20un%20Modelo%20de%20ML%3F%20Un%20modelo,ML%20son%20los%20motores%20matem%C3%A1ticos%20de%20la%20IA>.
- Reno, M., & Hansen, C. (2016). *Identification of periods of clear sky irradiance in time series of GHI measurements*. Renewable Energy.
- Ruiz, A. (2019). *Energía solar fotovoltaica. Autoconsumo. Energía solar térmica*. Centro de Estudios Financieros .
- Venkatakrisnan, G. R., Rengaraj, R., Tamilselvi, S., Harshini, J., Sahoo, A., AhamedSaleel, C., . . . Riffat, S. (2013). Detection, location, and diagnosis of different faults in large solar PV system - a review. *International Journal of Low-Carbon Techonologies*, 659-674.