

UNIVERSIDAD DON BOSCO
FACULTAD DE INGENIERÍA



TRABAJO DE GRADUACIÓN:

**PROPUESTA DE OPTIMIZACIÓN DEL PLAN DE MANTENIMIENTO
PREVENTIVO EN UN PARQUE SOLAR EN EL SALVADOR UTILIZANDO
MODELOS AVANZADOS**

PARA OPTAR AL GRADO DE:

MAESTRO(A) EN GESTIÓN ENERGÉTICA Y DISEÑO AMBIENTAL

PRESENTADO POR:

MAYORGA AMAYA MARIO ALFONSO
PERNETT ZÁRATE GISELE CAROLINA
VASQUEZ CASTELLANOS HÉCTOR GUSTAVO

ASESOR:

Mg. AYALA ALAS HÉCTOR ANÍBAL

ANTIGUO CUSCATLÁN, LA LIBERTAD EL SALVADOR CENTROAMÉRICA

JULIO DE 2025

CONTENIDO

ABREVIATURAS	3
CAPÍTULO 1.....	4
Introducción	4
1.1 Objetivos.....	5
1.2 Alcances	5
1.3 Justificación	5
1.4 Metodología	6
CAPITULO 2.....	8
Tipos de mantenimiento preventivo en un parque solar y herramientas de IA aplicables.....	8
2.1 Caracterización de SCADA en parques solares	8
a) Componentes del Sistema	8
b) Funcionalidades.....	8
c) Datos Adquiridos	9
2.2 Tipos de Mantenimiento en Parques Solares	10
2.2.1 Mantenimiento preventivo.....	10
2.2.2 Mantenimiento Predictivo.....	10
2.2.3 Mantenimiento Correctivo.....	11
2.3 Inteligencia artificial	11
2.4 Machine Learning (aprendizaje automático)	13
2.4.1 Aprendizaje supervisado (Supervised Learning)	14
2.4.2 aprendizaje no supervisado	17
2.5 Aprendizaje profundo y redes neuronales Artificiales	18
2.5.1 Redes Convolucionales (CNN).....	20
2.5.2 Redes Recurrentes (RNN).....	20
2.6 Casos de Estudio en el mundo y El Salvador	22
2.7 Contexto de la regulación de la IA en El Salvador	24
2.7.1 Compromisos y normativa relacionada	24
2.7.2 Implicaciones para la optimización del mantenimiento de una planta solar	25
CAPÍTULO 3.....	26
Optimización del mantenimiento preventivo enfocado en inversores de 215 kW con IA.....	26
3.1 Enfoque y tipo de investigación	26

3.1.1 Descripción del Caso de Estudio	26
3.2 Método de Regresión Lineal y RMSE.....	27
3.2.1 Arquitectura del modelo	27
3.2.2 Entrenamiento	28
3.2.3 Evaluación y validación: Transición del modelo estadístico a un enfoque de clasificación multivariable	31
3.3 Método Clasificación con Árboles	34
3.3.1 Arquitectura del modelo	34
3.3.2 Entrenamiento	34
3.3.3 Evaluación y validación	34
3.4 Modelo Autoencoder LSTM.....	37
3.4.1 Arquitectura del modelo LSTM Autoencoder	38
3.4.2 Entrenamiento del modelo	38
3.4.3 Evaluación y validación	39
3.5 Integración con el plan de mantenimiento	43
3.6 Comparativa de métodos propuestos	44
CAPÍTULO 4.....	45
Validación de la optimización del plan de mantenimiento mediante inteligencia artificial.....	45
4.1 Evaluación de la Aplicabilidad	45
4.1.1 Aplicabilidad en un entorno operativo real	45
4.1.2 Ventajas frente a métodos estadísticos y reglas fijas	45
4.1.3 Limitaciones identificadas	46
4.2 Análisis comparativo de costos.....	46
4.2.1 Costos operativos	46
4.2.2 Energía no servida	47
4.2.3 Costo de implementación de un sistema con herramientas de IA	49
CAPÍTULO 5.....	50
Conclusiones y recomendaciones.....	50
5.1. Conclusiones	50
5.2. Líneas de investigación recomendadas.....	51
REFERENCIAS.....	52

ABREVIATURAS

ANN	Artificial Neural Network
DC	Direct Current
IA	Inteligencia Artificial
IEEE	Institute of Electrical and Electronics Engineers
ML	Machine Learning
SCADA	Supervisory Control and Data Acquisition
O&M	Operación y Mantenimiento
MSE	Mean Square Error
RMSE	Root Mean Square Error
MAE	Mean Absolute Error
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
RF	Random Forest
LSTM	Long Short Term Memory
SVR	Support Vector Regression
MPPT	Maximum Power Point Tracking
ANIA	Agencia Nacional de Inteligencia Artificial
LFIMT	Ley de Fomento de la Innovación y Manufactura de Tecnologías

CAPÍTULO 1

Introducción

El Salvador ha experimentado una creciente participación de fuentes renovables en la generación eléctrica durante la última década, como parte de una transformación energética orientada hacia la sostenibilidad. Esta transición está respaldada por la Política Energética Nacional 2020–2050 [1], que establece como prioridad estratégica el incremento sostenido del uso de recursos como la energía solar, eólica, geotérmica e hidroeléctrica, con el objetivo de reducir la dependencia de derivados del petróleo y avanzar hacia un sistema energético bajo en carbono, reforzado también por el creciente interés por la transformación digital y la incorporación de tecnologías emergentes como la inteligencia artificial (IA), tanto en el sector público como privado, por medio de esfuerzos legislativos y estratégicos como la creación de la Agencia Nacional de Inteligencia Artificial (ANIA), que promueve el uso de IA en diferentes sectores incluyendo el energético. Por consiguiente, su aplicación en el sector, particularmente en la gestión de mantenimiento de plantas solares, que aún enfrentan retos relacionados con la variabilidad de su disponibilidad, representa una oportunidad clave para mejorar la confiabilidad y reducir los costos de operación y mantenimiento, que en ocasiones pueden estar asociados a fallas inesperadas. En este sentido, uno de los factores clave en la sostenibilidad técnica y económica de las plantas solares es su capacidad para mantenerse operativas con altos niveles de eficiencia. Las fallas imprevistas en los equipos, especialmente en los inversores, pueden generar interrupciones en la producción y aumentar significativamente los costos de operación, por ello, implementar un plan de mantenimiento preventivo y un sistema de baterías eficaz resulta fundamental para garantizar la continuidad del servicio y prolongar la vida útil de la planta. Tradicionalmente, este mantenimiento se ha basado en inspecciones periódicas, pruebas térmicas, monitoreo de parámetros eléctricos, actualización de firmware, revisión estructural, entre otros. Sin embargo, con el auge de la inteligencia artificial y el creciente acceso a datos en tiempo real a través de sistemas SCADA, se abre una nueva posibilidad: optimizar los mantenimientos mediante herramientas predictivas. La IA permite analizar grandes volúmenes de datos operativos, identificar patrones anómalos y anticipar fallas antes de que ocurran, mejorando así la toma de decisiones, reduciendo los tiempos de inactividad y minimizando la intervención humana. Este enfoque no solo contribuye a una mayor eficiencia operativa, sino que también fortalece la sostenibilidad económica del sistema energético renovable al reducir los costos totales del proyecto a lo largo de su ciclo de vida.

1.1 Objetivos

1.1.1 General

Optimizar el plan de mantenimiento preventivo para un parque solar ubicado en El Salvador utilizando modelos avanzados.

1.1.2 Específicos

- Analizar los tipos de mantenimiento preventivo aplicados en un parque solar, y explorar las herramientas de inteligencia artificial disponibles para mejorar su eficiencia.
- Diseñar un plan de mantenimiento preventivo optimizado enfocado en inversores de 215 kW donde se ponga en práctica herramientas de inteligencia artificial para anticiparse a posibles fallas.
- Validar el plan de mantenimiento mejorado mediante inteligencia artificial, evaluando su impacto en la reducción de costos operativos y la reducción de tiempos de no generación.

1.2 Alcances

El trabajo se desarrollará utilizando los registros históricos de un parque solar ubicado en Tecoluca, distrito del municipio de San Vicente Sur, del departamento de San Vicente en El Salvador. Se hará el análisis de variables meteorológicas, así como de los componentes individuales tanto como del sistema integrado y los datos históricos de la planta, con el fin de desarrollar estrategias integradas y personalizadas para la planificación del mantenimiento y optimizar la producción de energía. Se considerará el mantenimiento preventivo; a través de la aplicación de técnicas analíticas y de aprendizaje automático.

1.3 Justificación

El mantenimiento preventivo en parques solares es fundamental para garantizar su eficiencia operativa y prolongar la vida útil de sus componentes. Sin embargo, los métodos tradicionales presentan limitaciones al no adaptarse completamente a las condiciones específicas de cada instalación, lo que resulta en mayores costos operativos y tiempos de inactividad innecesarios. Además, el factor humano en los procesos de revisión y análisis introduce un grado de subjetividad, riesgo de error y variabilidad en la toma de decisiones, especialmente cuando se trata de grandes volúmenes de datos generados por los sistemas fotovoltaicos.

La integración de inteligencia artificial (IA) en estos procesos ofrece una solución innovadora al permitir una predicción más precisa de fallos y una planificación óptima de las actividades

de mantenimiento [2]. Este enfoque no solo reduce costos y tiempos asociados, sino que también mejora la disponibilidad y confiabilidad de los sistemas, contribuyendo al aprovechamiento máximo de la energía solar.

1.4 Metodología

Se revisó exhaustivamente la bibliografía disponible sobre los tipos de mantenimiento aplicables a sistemas fotovoltaicos, particularmente el mantenimiento preventivo, predictivo y correctivo, con énfasis en su aplicación dentro del contexto operativo de parques solares. Así mismo, se caracterizó el funcionamiento de los sistemas SCADA, destacando su relevancia como fuente primaria de datos para estrategias de mantenimiento inteligente. Se investigaron las principales técnicas de inteligencia artificial (IA), incluyendo los enfoques de aprendizaje supervisado, no supervisado y profundo, así como modelos específicos como la regresión lineal, árboles de decisión, redes neuronales artificiales (ANN), LSTM y Autoencoders, analizando su aplicabilidad en la predicción de fallas en inversores solares. Finalmente, se revisaron casos de estudio internacionales y se contextualizó la regulación vigente sobre IA en El Salvador, con el fin de identificar tanto las oportunidades como las posibles limitaciones para su implementación en el sector energético nacional.

Para el desarrollo de la propuesta, se seleccionó como caso de estudio una planta solar ubicada en El Salvador (en adelante La Planta) que cuenta con una capacidad instalada de 13.77 MWp, integrada por 25500 módulos fotovoltaicos de 540W. Los inversores transforman la energía generada en corriente continua por los módulos solares, a corriente alterna a 880V. Luego pasan por un transformador elevador de 880V a 13.2kV y posteriormente esa energía es inyectada a la red. Cada inversor cuenta con sensores que registran parámetros eléctricos, térmicos y operativos cada cinco minutos, estos datos son almacenados en una base de datos y monitorizados mediante el sistema SCADA. Se usaron datos correspondientes al año 2024 de enero a diciembre, extraídos del sistema SCADA, tales como temperatura interna, potencia activa, irradiancia, eficiencia y estado operativo de los equipos. A partir de esta información, se desarrollaron distintos modelos de predicción enfocados en la anticipación de fallas: un modelo de regresión lineal orientado a identificar anomalías térmicas a partir del rendimiento energético (yield); un modelo de clasificación basado en árboles de decisión y Random Forest para jerarquizar las variables críticas asociadas a fallas; y un modelo Autoencoder LSTM diseñado para detectar patrones anómalos en series temporales. Cada uno de estos modelos fue entrenado y validado en entornos de desarrollo como Google Colab y Jupyter Notebooks, haciendo uso de librerías especializadas como Scikit-learn, TensorFlow, Keras y Pandas. Finalmente, se establecieron criterios de umbral de alerta y se definieron ventanas de tiempo para evaluar la efectividad de cada modelo en la predicción de fallas en los inversores.

Se llevó a cabo una validación técnica del modelo Autoencoder LSTM en diferentes escenarios, considerando distintas cantidades de inversores y ventanas de tiempo, con el

objetivo de identificar su capacidad para anticipar fallas reales con un margen de entre 8 y 11 días. Paralelamente, se desarrolló un análisis comparativo de costos entre el enfoque tradicional de mantenimiento, basado en calendarios fijos, y la estrategia predictiva propuesta, tomando en cuenta aspectos como la reducción de fallas imprevistas, la disminución de intervenciones correctivas no planificadas y los ahorros asociados a la menor pérdida de energía no servida. Asimismo, se evaluó la aplicabilidad práctica del modelo dentro del entorno operativo de una planta solar, identificando ventajas como su baja demanda computacional, alta sensibilidad en la detección de patrones y capacidad de actualización continua; además, se reconocieron las posibles limitaciones relacionadas con la calidad de los datos disponibles y la necesidad de capacitación técnica del personal encargado de su implementación y seguimiento.

CAPITULO 2

Tipos de mantenimiento preventivo en un parque solar y herramientas de IA aplicables

En este capítulo se presenta un estudio bibliográfico sobre parques solares, detallando sus componentes principales, tales como módulos fotovoltaicos, cables de corriente continua (DC), inversores y transformadores. Asimismo, se analizan los distintos tipos de mantenimiento (preventivo, predictivo y correctivo), junto con diversas estrategias aplicables, incluyendo aquellas basadas en el tiempo de uso, cambios por bloques, tasa de falla y análisis costo-duración, evaluando sus aplicaciones, ventajas y desventajas. Además, se aborda la optimización de dichas estrategias a través del enfoque de mantenimiento integrado. Finalmente, se exploran herramientas de inteligencia artificial, con énfasis en técnicas de machine learning, describiendo los tipos de algoritmos utilizados, su utilidad, beneficios y formas de optimización.

2.1 Caracterización de SCADA en parques solares

Para caracterizar un sistema SCADA (Supervisory Control and Data Acquisition) para una planta solar, se deben considerar varios aspectos clave que permiten la supervisión y control eficiente de la operación de la planta, todo esto nos servirá para llevar a cabo el estudio y la obtención de datos [3]. A continuación, se detallan los elementos fundamentales que deben incluirse en la caracterización:

a) Componentes del Sistema

Sensores: Dispositivos que miden parámetros como la irradiancia solar, temperatura ambiente, velocidad y dirección del viento, y potencia activa generada. Estos datos son cruciales para el monitoreo del rendimiento de la planta.

Controladores: Equipos que reciben datos de los sensores y ejecutan comandos para controlar los inversores y otros dispositivos de la planta.

Interfaz de Usuario: Software que permite a los operadores visualizar datos en tiempo real, recibir alertas y gestionar la operación de la planta [5].

b) Funcionalidades

Monitoreo en Tiempo Real: Capacidad para visualizar datos de operación en tiempo real, lo que permite a los operadores identificar rápidamente cualquier anomalía o fallo en el sistema.

Almacenamiento de Datos: Registro de datos históricos que pueden ser utilizados para análisis de rendimiento y mantenimiento predictivo.

Control Remoto: Posibilidad de ajustar parámetros de operación y realizar configuraciones desde una ubicación central.

c) Datos Adquiridos

Estación meteorológica: los datos adquiridos de la estación meteorológica son fundamentales para el monitoreo y la optimización del rendimiento del sistema fotovoltaico tales como:

Irradiancia Solar: Medida de la cantidad de energía solar que incide sobre los paneles fotovoltaicos, generalmente expresada en W/m^2 . Este dato es crucial para evaluar la producción de energía de la planta, ya que la generación de electricidad está directamente relacionada con la cantidad de luz solar disponible [4].

Temperatura Ambiente: La temperatura del aire, medida en grados Celsius ($^{\circ}C$), que puede influir en la eficiencia de los paneles solares. Las altas temperaturas pueden reducir la eficiencia de conversión de energía de los módulos fotovoltaicos [4].

Velocidad y Dirección del Viento: Estos datos ayudan a entender las condiciones ambientales que pueden afectar la operación de la planta. La velocidad del viento puede influir en la temperatura de los paneles y, por lo tanto, en su rendimiento.

Humedad relativa: La humedad relativa del aire también se registra, ya que puede afectar la acumulación de polvo y suciedad en los paneles, lo que a su vez puede impactar su eficiencia.

Estos datos son adquiridos a través de sensores instalados en la planta y se integran en el sistema SCADA para el análisis y la toma de decisiones en tiempo real, permitiendo la implementación de estrategias de mantenimiento predictivo y optimización del rendimiento del sistema fotovoltaico.

Datos eléctricos: Los datos eléctricos obtenidos por el sistema SCADA en una planta solar son fundamentales para el monitoreo y la optimización del rendimiento del sistema fotovoltaico, estos pueden ser tales como:

Potencia Activa (AC): Este es el principal dato eléctrico que se registra, representando la cantidad de energía eléctrica generada por los inversores en kilovatios (kW). La potencia activa es crucial para evaluar el rendimiento de la planta y se obtiene a partir de los medidores de energía instalados en el sistema.

Datos de Inversores: Los inversores convierten la energía generada por los paneles solares (que es en corriente continua, DC) a corriente alterna (AC). Los datos de los inversores incluyen información sobre la eficiencia de conversión, el estado operativo y cualquier anomalía detectada durante su funcionamiento.

Historial de Producción: Se registra la producción de energía a lo largo del tiempo, lo que permite realizar análisis de rendimiento y detectar patrones o irregularidades en la generación de energía.

Estos datos son adquiridos a través de sensores y medidores conectados al sistema SCADA, que proporciona información en tiempo real y permite la toma de decisiones informadas para el mantenimiento y la optimización de la planta solar [6].

2.2 Tipos de Mantenimiento en Parques Solares

En el contexto de los sistemas fotovoltaicos, existen tres tipos principales de mantenimiento que son fundamentales para garantizar su eficiencia y prolongar su vida útil: el mantenimiento correctivo, el mantenimiento preventivo y el mantenimiento predictivo.

2.2.1 Mantenimiento preventivo

El mantenimiento preventivo en sistemas fotovoltaicos se centra en prevenir fallos mediante la atención a problemas menores antes de que se agraven. Este tipo de mantenimiento se divide en dos enfoques principales: el mantenimiento basado en el tiempo y el mantenimiento basado en condiciones.

Mantenimiento Basado en el Tiempo: Este enfoque implica la realización de inspecciones y reparaciones programadas de acuerdo con un calendario establecido, siguiendo las directrices de los manuales de operación. Aunque este método puede mejorar las prácticas de mantenimiento y reducir las fallas de los componentes, puede resultar costoso debido a visitas innecesarias, especialmente en sistemas fotovoltaicos de gran escala ubicados en áreas remotas.

Mantenimiento Basado en Condiciones: Este enfoque utiliza sistemas de monitoreo y análisis de salud para detectar signos tempranos de fallos o problemas de rendimiento. La detección rápida de fallos es crucial para prevenir interrupciones o daños en los sistemas fotovoltaicos. Se emplean diversas técnicas para el diagnóstico de fallos, que incluyen inspecciones visuales, evaluaciones de parámetros eléctricos, procesamiento de imágenes y análisis estadístico. Sin embargo, el monitoreo manual puede ser insuficiente para sistemas grandes y complejos, ya que tiende a centrarse en el rendimiento de los paneles en lugar de considerar el sistema en su totalidad.

El mantenimiento preventivo es esencial para maximizar la disponibilidad y eficiencia de los sistemas fotovoltaicos, y su implementación adecuada puede ayudar a minimizar los costos de mantenimiento a largo plazo.

2.2.2 Mantenimiento Predictivo

El mantenimiento predictivo en sistemas fotovoltaicos es una estrategia que se centra en anticipar fallos y deterioros en los componentes del sistema antes de que ocurran. A diferencia del mantenimiento basado en condiciones, que utiliza datos en tiempo real para tomar decisiones sobre el mantenimiento, el mantenimiento predictivo se basa en el análisis de datos históricos y en modelos de pronóstico para identificar tendencias de deterioro y estimar la vida útil restante de los componentes.

Este enfoque permite programar actividades de mantenimiento de manera planificada, lo que minimiza el tiempo de inactividad y reduce los costos asociados con el mantenimiento correctivo. En el sector de la energía solar, el mantenimiento predictivo se ha enfocado principalmente en los inversores y paneles fotovoltaicos, utilizando algoritmos de inteligencia artificial para predecir fallos. Por ejemplo, investigaciones recientes han aplicado

redes neuronales artificiales para la predicción de fallos en inversores, alcanzando una capacidad de pronóstico con hasta siete días de anticipación, según lo indicado en [7].

Además, la integración de técnicas de mantenimiento predictivo con pronósticos de producción de energía es crucial, ya que permite a los operadores programar el mantenimiento durante períodos de baja producción, lo que reduce el impacto en la generación de energía. Este enfoque también es fundamental para gestionar factores ambientales que afectan la eficiencia de los sistemas fotovoltaicos, como la acumulación de suciedad y nieve, optimizando así las visitas de los técnicos y reduciendo los costos asociados con el mantenimiento correctivo inesperado.

2.2.3 Mantenimiento Correctivo

El mantenimiento correctivo en sistemas fotovoltaicos se refiere a las acciones tomadas para abordar fallos, mal funcionamiento o daños que han sido identificados a través de monitoreo remoto o inspecciones rutinarias. Este tipo de mantenimiento es considerado un procedimiento no programado, ya que se lleva a cabo en respuesta a problemas que han surgido con el objetivo de restaurar la operación normal del sistema.

Sin embargo, el mantenimiento correctivo puede resultar costoso y puede causar interrupciones en la generación de energía, así como daños potenciales a componentes críticos del sistema. La dificultad de acceso a sitios remotos puede agravar estos problemas, ya que la necesidad de enviar personal a estas ubicaciones incrementa los costos de mantenimiento. Por lo tanto, reducir los tiempos de respuesta es crucial en el mantenimiento correctivo, lo que implica optimizar los tiempos de reconocimiento, intervención y reparación [8].

A pesar de que el mantenimiento correctivo seguirá siendo una prioridad para abordar daños en el equipo, se anticipan avances significativos en el mantenimiento predictivo, impulsados por técnicas de inteligencia artificial y dispositivos del Internet de las Cosas (IoT), que buscan mejorar la gestión y operación de las plantas fotovoltaicas.

2.3 Inteligencia artificial

El uso de las palabras inteligencia artificial parece ser un tema reciente, sin embargo, si se retoma la definición de [9] “Es la ciencia y la ingeniería de crear máquinas inteligentes, especialmente programas inteligentes de computadora.”, se puede llegar a la conclusión que la inteligencia artificial, no es algo nuevo, sus inicios datan desde 1947 con Alan Turing, el cual en su artículo publicado en 1950 “Computing machinery and intelligence”, donde a través del test de Turing planteado en el artículo ya se empieza a proponer la idea si una maquina puede pensar o tiene inteligencia. Esta tarea de imitar la inteligencia humana a través de las maquinas lleva más de 65 años en ejecución. Y ha sufrido altos y bajos a través del tiempo como se puede observar en la fig1. incluyendo 2 “inviernos” periodos en los cuales los avances en el tema no fueron prometedores sino al contrario desalentadores.



Fuente: Elaboración propia adaptada de [10]

Fig.1 Línea del tiempo de la inteligencia artificial

Este tema, ha retomado mucho auge a partir de la década de los años 2000, debido a los siguientes hitos:

1. La propuesta de varias teorías y técnicas de machine learning fueron propuestas, como: Árbol de decisión (Decision Tree), propuesto por J. R. Quinlan en 1986; máquina de soporte vectorial (support vector machine), propuesta por Vapnik y Cortes en 1995; Adaboost, propuesto por Freund y Schapire en 1997; bosques aleatorios (Random Forest), propuestos por Breiman en 2001. Y en el ámbito relacionado con las redes neuronales, el artículo, que promovió la propagación hacia atrás de los errores (Back-Propagation) publicado en 1986.
 2. Se crearon grandes bases de datos para poder entrenar modelos.
 3. Se incrementó en gran medida la capacidad de cómputo de las máquinas.
 4. Sistemas con uso de inteligencia artificial superaron a los humanos en concursos y competiciones, recuperando la confianza en los sistemas con inteligencia artificial.
- [10]

En el presente, las palabras inteligencia artificial parece ser incluso una palabra de moda, ya que se encuentra casi en todo nuestro día a día, está presente en temas como: ingeniería, transporte, redes sociales, publicidad, salud, industria, entre muchos otros, la energía no es la excepción a ello.

En la industria de la energía fotovoltaica la IA ha impactado en diversas áreas entre ellas diseño, control, predicción, mantenimiento, optimización y seguridad. [11]

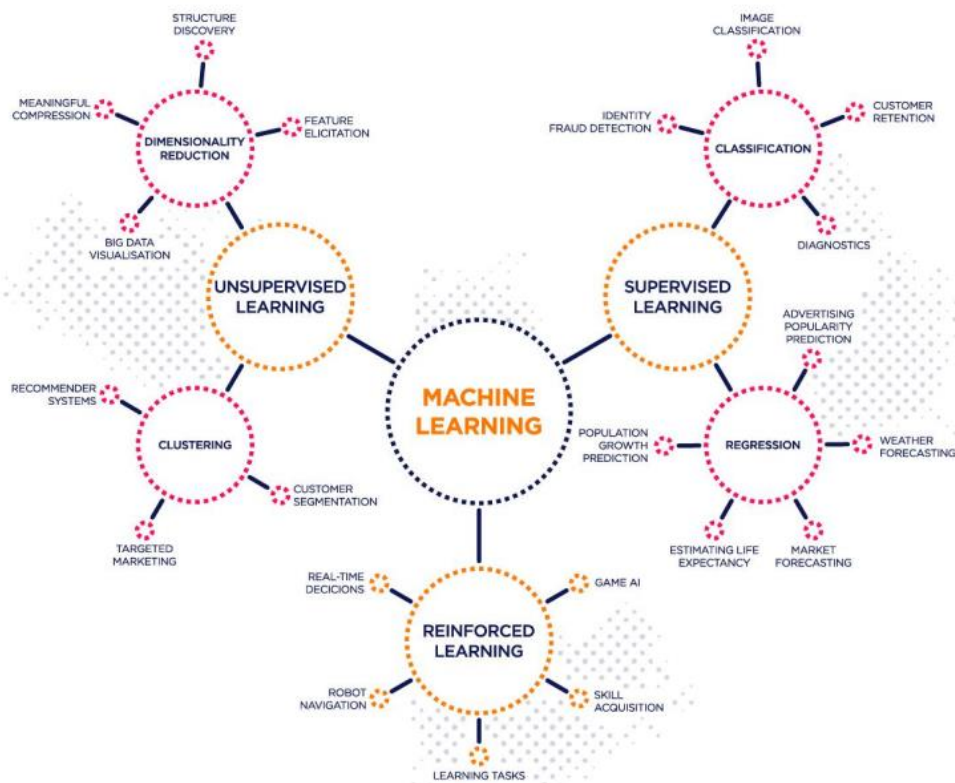
2.4 Machine Learning (aprendizaje automático)

Machine learning es un sub-campo de la inteligencia artificial [12] lo define como “el estudio de algoritmos que permiten a los programas de computadora mejorar automáticamente a través de la experiencia. La “experiencia” en esta definición hace referencia a la información anterior disponible para el sistema, por lo que la calidad y la cantidad de esta información anterior serán cruciales para el éxito de las predicciones futuras. [14]

La idea del aprendizaje automático se basa en que el sistema pueda aprender desde los datos ingresados, encontrar patrones y tomar decisiones sin mucha o ninguna intervención humana, es decir el sistema pueda identificar patrones complejos sin estar explícitamente programada. En base a esta idea, los pilares fundamentales para el machine learning son: los datos, los modelos y algoritmos y los métodos de evaluación.

El aprendizaje automático o machine learning se divide en 3 grandes subcampos: aprendizaje supervisado, aprendizaje no supervisado y el aprendizaje por refuerzo.

En la figura 2 se pueden observar aplicaciones de los tipos de aprendizaje automático y sus aplicaciones:



Fuente: Tomada de [12]

Fig.2 Tipos de Machine Learning

A continuación, se estudiarán los primeros dos campos con mayor profundidad y los algoritmos más comunes asociados a cada uno. También se le dará especial atención al campo del aprendizaje profundo (Deep Learning) donde se estudiarán los conceptos fundamentales y algunos tipos de redes neuronales

2.4.1 Aprendizaje supervisado (Supervised Learning)

El aprendizaje supervisado utiliza un conjunto de datos etiquetados para entrenar algoritmos y poder predecir resultados de nuevos datos. Los datos utilizados en la fase de entrenamiento muestran la salida (o resultado) correspondiente a cada entrada, para que se puedan encontrar correlaciones y patrones entre ellos. [12][14]

Explicado desde una perspectiva más formal y matemática se pudiera expresar la tarea del aprendizaje supervisado como:

Dado un conjunto de datos de entrenamiento de N pares de ejemplo entrada-salida:

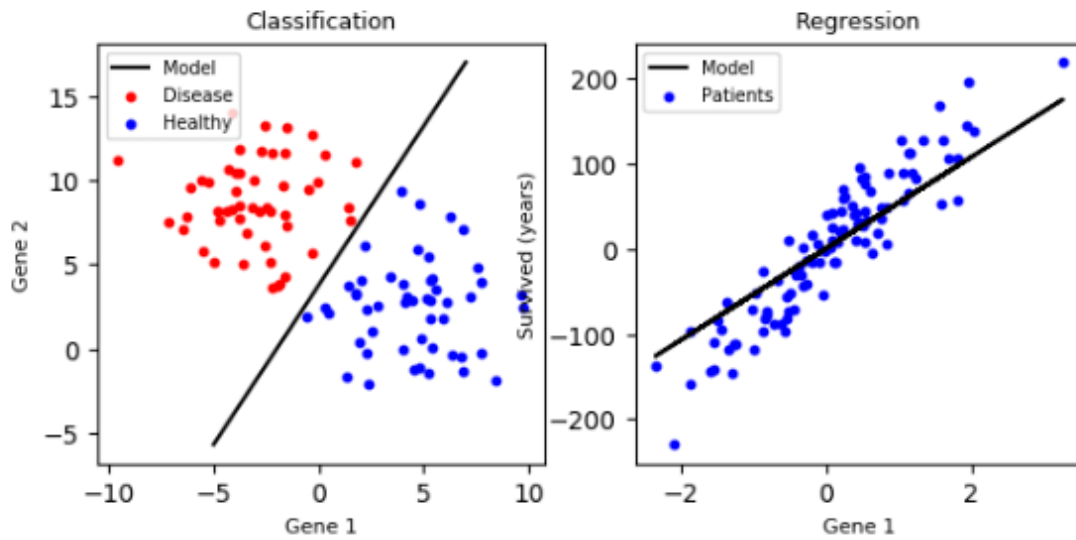
$$(x_1, y_1), (x_2, y_2) \dots (x_N, y_N)$$

donde cada y_j fue generado por una función desconocida $y = f(x)$
descubrir una función h que aproxime la verdadera función f .

Donde x y y pueden tomar cualquier valor, no necesariamente un valor numérico. Para probar si la función h se aproxima bien, se deben ingresar un conjunto de datos de prueba que no correspondían a los datos de entrenamiento, y se dirá que la función generalizó bien si puede producir correctamente los valores de y con los nuevos datos.

Cuando los valores de y son valores finitos (como pudiera ser mañana tarde o noche) el problema de aprendizaje se llama clasificación, en el caso de solo ser dos valores se conoce como clasificación booleana o binaria. Cuando el valor de y es un valor numérico el problema se conoce como regresión.[9][12]

En la figura 3 se puede ver los dos tipos de problemas planteados anteriormente.



Fuente: tomado de [14]

Fig.3 Un ejemplo de problema de clasificación (izquierda) y regresión (derecha)

Para ambos casos se utilizan datos etiquetados, pero cada uno se utiliza para distintos tipos de problemas y resultados. A continuación, se describirán distintos modelos de regresión y clasificación.

Árbol de decisiones

Es una de las formas más simple y más populares del aprendizaje automático. es un método para aproximar funciones objetivo de valores discretos, en el cual la función aprendida se representa mediante un árbol de decisión ver figura 4. [12] Los árboles de decisión son más utilizados para problemas de clasificación, el sistema va haciendo una serie de prueba desde el nodo raíz, evaluando el atributo de este, luego hacia abajo por los nodos ramas, hasta los nodos hojas, evaluando cada atributo y los posibles valores de estos hasta obtener un resultado.



Fuente: adaptada de [12]

Fig.4 Representación de un árbol de decisiones

La meta en los problemas de aprendizaje automático es entrenar un modelo que sea capaz de predecir la clase de la variable objetivo, aprendiendo de reglas de decisión simple, de datos anteriores. El reto es encontrar que atributos contribuyen con más peso para esta clasificación, es decir que atributos pueden ser considerados como nodos raíz. Para esta labor se utiliza una propiedad estadística llamada “ganancia de información” que es definida en términos de entropía como en (1) [10,14].

Entropía:

$$H(V) = \sum_k P(v_k) \log_2 \frac{1}{P(v_k)} = - \sum_k P(v_k) \log_2 P(v_k) \quad (1)$$

Donde:

$H(V)$ = entropía de una variable

$P(v_k)$ = la probabilidad del valor v_k

La ganancia de información es simplemente la reducción esperada de entropía causada por particionar los ejemplos según este atributo. Más precisamente, la ganancia de información, **Gain (S, A)**, de un atributo A en relación con una colección de ejemplos S se define como:

$$GAIN(S, A) = Entropía(S) - \sum_{v \text{ valores}(A)} \frac{|S_v|}{|S|} Entropía(S_v) \quad (2)$$

Donde:

A = el conjunto de todos los valores posibles para el atributo A

S = el subconjunto de S para el cual el atributo A tiene el valor.[8]

Los modelos de árbol de decisiones se ajustan de mejor manera a problemas con las siguientes características:

1. Instancias son representadas por pares atributo-valor, la situación más fácil para este modelo es cuando los atributos solo pueden tomar un pequeño número de valores disjuntos por ejemplo mañana, tarde y noche
2. La función objetivo tiene valores de salida discreto, por ejemplo, si o no
3. Se puede requerir descripciones disyuntivas
4. El conjunto de valores de entrenamiento pudiera contener errores
5. El conjunto de valores de entrenamiento pudiera carecer de valores en algunos atributos

El algoritmo de bosque aleatorio se basa en el algoritmo de árbol de decisión

2.4.2 aprendizaje no supervisado


A diferencia del aprendizaje supervisado, el aprendizaje no supervisado no utiliza datos etiquetados, el modelo debe reconocer patrones en las entradas, aunque no exista retroalimentación, ni una respuesta "correcta" es decir el algoritmo debe aprender sin ningún guía o supervisor. [13][14] [15]

Los algoritmos de aprendizaje no supervisado son mejores para resolver problemas más complejos, aunque esto requiera una capacidad computacional mayor, sin embargo, tienen una menor precisión si se les compara con algoritmos de aprendizaje supervisado. La base de este tipo de aprendizaje es encontrar similitudes y diferencias en conjuntos de datos masivos, para poder categorizarlos. Son usados para agrupamiento: detectar posibles grupos en los datos ingresados y reducción de dimensionalidad: reducción de características manteniendo la mayor cantidad de información posible. [15][16]

Este tipo de aprendizaje ha tenido mucho éxito en disciplinas como el reconocimiento de voz, la creación de autos autónomos y el procesamiento de lenguaje natural.

En el caso de una serie de fotografías, para el caso de aprendizaje supervisado se debe entregar una base de datos de fotografías etiquetados como perros, por ejemplo, para que el algoritmo pueda aprender en base a ejemplos. Para el caso de aprendizaje no supervisado solo se entrega una cantidad de fotos, y es el algoritmo el que debe determinar si estas son perros o no, en la gran cantidad de fotos debe ser capaz de distinguir cualidades distintivas como el hocico, las 4 patas orejas caídas etc.

Dentro de esta categoría se encuentran los Autoencoders, que es un modelo representado por 3 partes: el codificador, la representación latente y el decodificador como lo muestra la figura 5.



Fuente: obtenida de [27]


Fig.5 Representación de un autoencoder

La idea general del autoencoder es obtener una entrada, crear una representación latente y reconstruir la misma entrada lo más parecido posible a la entrada original, en la mayoría de los casos el codificador y el decodificador son redes neuronales como por ejemplo una red del tipo LSTM. Entre las aplicaciones de los autoencoders tenemos: Reducción de la dimensionalidad, clasificación, detección de anomalías y eliminación de ruido. Hoy en día existe una gran variedad de ellos que se combinan con otros métodos de inteligencia artificial dependiendo del problema a abordar.

2.5 Aprendizaje profundo y redes neuronales Artificiales

En la figura 1 se puede ver que el aprendizaje profundo es una sub rama del aprendizaje automático (machine learning), que se enfoca en modelos de redes neuronales profundas. Los patrones que los algoritmos de aprendizaje profundo extraen de los conjuntos de datos, son en realidad funciones que se representan como redes neuronales. [17]

En la figura 6 se puede observar una representación esquemática de una red neuronal, Los cuadros representan las entradas y cada círculo representa una neurona, que implementa una función con los datos de entrada y obtiene una salida, las flechas muestran como una salida de una neurona es la entrada de la neurona de la siguiente capa en este caso el flujo es de izquierda a derecha.



Fuente: obtenida de [19]

Fig.6 Representación esquemática de una red neuronal

Las redes neuronales artificiales han basado su característica de rendimiento en redes neuronales biológicas, son generalizaciones de modelos matemáticos de la cognición humana o la biología neuronal, y se basan en los siguientes supuestos:

1. El procesamiento de la información ocurre en muchos elementos simples llamados **neuronas**.
2. Las señales se transmiten entre las neuronas a través de enlaces de conexión.
3. Cada enlace de conexión tiene un peso asociado, que, en una red neuronal típica, multiplica la señal transmitida.
4. Cada neurona aplica una función de activación (generalmente no lineal) a su entrada neta (la suma de las señales de entrada ponderadas) para determinar su señal de salida.

Las ANN se caracterizan por su arquitectura, que es el patrón de conexiones entre las neuronas; su algoritmo de entrenamiento o aprendizaje, que es el método para determinar los pesos en las conexiones y su función de activación. [18]

Las arquitecturas características en las ANN son red de una sola capa, redes multicapas y redes competitivas. Los algoritmos de entrenamiento se dividen en aprendizaje supervisado, aprendizaje no supervisado y pesos fijos, y entre las funciones de activación comunes tenemos:

Función de identidad:

$$f(x) = x \quad \text{para todo } x \quad (3)$$

Función escalonada, con restricción Θ :

$$f(x) = \begin{cases} 0, & x < \theta \\ 1, & x \geq \theta \end{cases} \quad (4)$$

Función sigmoide:

$$S(x) = \frac{1}{1+e^{-x}} \quad (5)$$

Función sigmoide bipolar

$$S(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (6)$$

Las ANN tienen diferentes aplicaciones y depende del problema a resolver se utilizan diferentes tipos, entre los problemas más comunes tenemos: procesamiento de señales, control, reconocimiento de patrones, reconocimiento de voz entre otros. [18]

A continuación, se describirán distintos tipos de redes neuronales


2.5.1 Redes Convolucionales (CNN)

La idea en el diseño de las CNNs consiste en que las neuronas de las primeras capas extraerán características visuales locales, que es una característica cuya extensión está limitada a un pequeño fragmento, y las neuronas de las siguientes capas combinarán estas características para formar características de un orden superior o más complejo, por ejemplo, en el caso de reconocimiento facial, las primeras capas reconocerán líneas en un ángulo particular o segmentos de curvas, las siguientes capas combinando las anteriores reconocerán partes del cuerpo, y las últimas capas reconocerán rostros completos en una imagen. [18]

Lo importante del método es que la programación debe ser tal que se pueda analizar toda una imagen en fragmentos pequeños, y pueda aplicar una función matemática con ese barrido, de ahí el término convolucional.

2.5.2 Redes Recurrentes (RNN)

En las RNNs la idea es procesar información de manera secuencial, este tipo de redes solo tienen una capa intermedia (hidden layer) pero también cuentan con un buffer de memoria, en este, se almacena el resultado de la capa intermedia y se vuelve a alimentar junto con la siguiente entrada de la secuencia, es decir en este flujo de información la entrada tiene la información almacenada de la salida de la entrada anterior creando un lazo que potencialmente debería tener contexto de todas las entradas anteriores, esta idea se puede comprender mejor en la figura 7.[18]




Fuente: obtenida de [18]

Fig.7 Representación de las redes neuronales recurrentes

Sin embargo, en casos donde la secuencia era muy larga las RNNs presentaban el problema, que el gradiente tendía a desaparecer por lo que la información ingresada en los primeros pasos no podía ser retenida efectivamente en periodos largos. Para solventar ese problema aparece una variante de estas redes neuronales recurrentes, la red llamada Long Short Term Memory (LSTM) que busca específicamente solventar este problema. [25]

Las redes neuronales del tipo LSTM han sido diseñadas para trabajar con secuencias de datos, ya que permiten conservar información relevante de estados anteriores en la serie temporal. Esta capacidad les permite anticipar con precisión eventos futuros, lo que las convierte en una herramienta ideal para problemas donde existen dependencias de largo plazo entre variables. Las LSTM incorporan mecanismos de control denominados puertas (de entrada, olvido y salida), que regulan el ingreso, almacenamiento y salida de información desde la celda de memoria. Gracias a esta arquitectura, las LSTM son capaces de superar el problema del gradiente desvanecido y mantener el aprendizaje de patrones que dependen de información remota en el tiempo. [26]



Fuente: adaptada de [26]

Fig.8 Arquitectura de LSTM

En la figura 8 podemos observar las 3 arquitecturas de la red que incluye las puertas mencionadas anteriormente, la puerta de olvido (forget gate) que se encarga de decidir qué información en la célula será descartada, la puerta de entrada (input gate) que decide que nueva información será añadida y la puerta de salida (output gate) controla la salida de la capa intermedia, este mecanismo de puertas es el que permite actualizar o retener información relevante a lo largo del tiempo.

2.6 Casos de Estudio en el mundo y El Salvador

La creciente adopción de la energía solar ha impulsado el desarrollo de estrategias avanzadas de mantenimiento para maximizar la eficiencia y prolongar la vida útil de los módulos fotovoltaicos. La implementación de IA en este ámbito permite la detección temprana de fallos, la predicción de rendimiento y la optimización del mantenimiento de las instalaciones.

Se han realizado pruebas donde aplican redes neuronales a largo plazo (LSTM) para la predicción de la degradación y el rendimiento de los módulos fotovoltaicos [20]. El caso de estudio es una planta del proyecto Alice Springs ubicado en Australia, los datos fueron proporcionados por el Desert Knowledge Australia Solar Center, consistiendo no solo en las características específicas de la planta, sino mediciones que fueron tomadas cada 5 minutos entre 2016 y 2020. Con ello aplicaron metodologías utilizando técnicas de Edge Computing para el procesamiento distribuido de datos, minimizando la latencia y mejorando la eficiencia en la toma de decisiones. Asimismo, comparan diversos enfoques de predicción, evaluando su precisión mediante métricas como el error medio absoluto (MAE) y el error cuadrático medio, con el objetivo de determinar la configuración óptima para la detección y diagnóstico de anomalías.

Mientras que en [21], donde desarrollan estrategias de mantenimiento integrado para fuentes de energía renovable basadas en métodos analíticos e inteligencia artificial, toman la Planta Solar Sokoto y el Parque Eólico Katsina, en Nigeria para caso de estudio y utilizan herramientas de machine learning como ANN y la Regresión por Vectores de Soporte (SVR). En el caso de la planta solar, las variables específicas tomadas fueron la irradiancia solar y la temperatura, como características de entrada por su impacto directo en la producción. La irradiancia se modeló como una variable aleatoria, representada por una función de distribución beta, lo que refleja la incertidumbre asociada con fenómenos de insulación como el polvo y la cobertura de nubes.

Asimismo, la aplicabilidad de la IA ha sido experimentada a través de simulaciones como en [22] donde simulan los datos de una Planta Termosolar de Torre, y emplean Análisis de Efectos y Criticidad del Modo de Fallo (FMECA), para estimar el índice de criticidad de los elementos de la planta solar a partir de 3 parámetros: severidad, ocurrencia y detectabilidad, sin embargo, no hay priorización de fallos debido a la ponderación igualitaria de los 3 parámetros. Por lo que también usaron Redes Bayesianas (BN) para modelar y simular diferentes escenarios de criticidad, permitiendo corregir las estimaciones de FMECA, aplicando teoría de probabilidad para calcular la criticidad posterior de cada subsistema. Y por último entrenan redes neuronales artificiales (ANN) con los datos obtenidos con BN para predecir el índice de criticidad de cada elemento de la planta, su arquitectura de entrada fue compuesta por cinco variables (criticidad de subsistemas) y una salida (criticidad general de la planta).

Por otro lado, para un acercamiento al contexto climático local, en la referencia [23] usan un modelo experimental en Dakar, Senegal, donde aplican técnicas de IA para la optimización de sistemas fotovoltaicos en regiones tropicales, lo cual tiene ciertas implicaciones climáticas. Al implementar algoritmos inteligentes como las ANN y los sistemas de inferencia adaptativa neuro-difusa (ANFIS), modelo obtenido a través del software Matlab, se logra optimizar el seguimiento del punto máximo de potencia (MPPT) en condiciones climáticas variables (temporada seca y lluviosa). Concluyendo que el uso de dicha tecnología puede ayudar a reducir las pérdidas de energía asociadas a condiciones meteorológicas no uniformes, además que el estudio comparativo de los métodos de optimización permitiría identificar el modelo más adecuado y eficiente según las condiciones específicas de una región, y de esta forma personalizar las estrategias de mantenimiento de los sistemas.

A nivel nacional aún no existen casos de estudio o empresas que actualmente hayan integrado IA en el análisis específico de una planta solar. No obstante, en el proceso de investigación se observó que existe interés por dichas aplicaciones y el desarrollo e implementación de otro tipo de tecnologías que trabajan con IoT para la optimización de los mantenimientos de paneles solares, como el uso de sensores de suciedad, donde se tienen 2 celdas, la celda limpia, que se limpia de manera regular y la celda sucia, que se deja ensuciar de manera natural, estos sensores comprenden sistemas de cálculo integrados al IoT para visualizar los datos a través de una plataforma específica en tiempo real. De esta forma pueden medir con gran precisión el porcentaje de pérdida por suciedad, de forma diaria.

2.7 Contexto de la regulación de la IA en El Salvador

Actualmente, El Salvador está en proceso de consolidar una legislación específica sobre inteligencia artificial. Anteriormente, el país había adoptado lineamientos internacionales e impulsado políticas que pudieran facilitar el desarrollo y uso de IA en distintos sectores.

Uno de los pilares clave es la Agenda Digital de El Salvador, que establece la base para la transformación digital del país y menciona indirectamente la IA como una herramienta estratégica. Si bien la IA no figura como un pilar independiente aún, su integración en áreas como la modernización del Estado, la educación y la seguridad es reconocida como esencial para el crecimiento tecnológico del país.

2.7.1 Compromisos y normativa relacionada

El país ha dado pasos significativos en la regulación de la IA a través de compromisos con organismos internacionales [24]:

- En 2021, El Salvador adoptó la Recomendación sobre la Ética de la Inteligencia Artificial de la UNESCO, un marco global para el desarrollo responsable de la IA.
- En 2022, se convirtió en el primer país de Centroamérica en iniciar la implementación de estas recomendaciones.
- En 2023, participó en el Foro sobre la Ética de la Inteligencia Artificial en América Latina y el Caribe, donde reafirmó su compromiso con el desarrollo ético y regulado de la IA.

La reciente aprobación de la “Ley de Fomento de la Inteligencia Artificial y Tecnologías” en El Salvador marca un hito significativo para el desarrollo tecnológico del país, donde vale destacar los puntos claves del comunicado publicado [25]:

- Creación de la ANIA: Agencia Nacional de Inteligencia Artificial, la cual estará adscrita a la Presidencia de la República. Y será responsable de regular y promover el uso de la IA en el país.
- Laboratorios y Centros de Investigación: promoverán su creación para proporcionar recursos, orientación y capacitación a la población interesada.
- Creación del Registro Nacional de Desarrolladores de IA: el cual será administrado por la ANIA, cuyo rol será proteger la propiedad intelectual, controlar el uso indebido de las herramientas por terceros, eximiendo de ello a quienes estén registrados, entre otros incentivos y controles.
- Protección de datos personales: la ANIA trabajará de la mano con la Agencia de Seguridad Cibernética para supervisar y aplicar la Ley de Protección de Datos Personales y la Ley de Ciberseguridad y Seguridad de la información.
- Recursos energéticos: se pretende mejorar la detección de yacimientos para geotermia, optimizar la gestión de los recursos hídricos, entre otras aplicaciones que aportarían enormemente al mercado energético.

Adicional a lo anterior, los incentivos fiscales que la Ley de Fomento a la Innovación y Manufactura de Tecnologías (LFIMT) otorgaría a empresas del sector tecnológico, incluyendo aquellas que trabajan con IA, podría representar una oportunidad para el

desarrollo de soluciones de IA en el sector energético y, en particular, para la optimización del mantenimiento de plantas solares.

2.7.2 Implicaciones para la optimización del mantenimiento de una planta solar

Si bien la regulación de IA en El Salvador aún está tomando forma, los avances mencionados sugieren que el país está en proceso de consolidar un marco normativo que permita su aplicación en sectores estratégicos, en este caso, las ventajas de ser utilizada en una planta solar:

- Optimizar la predicción y gestión del mantenimiento, reduciendo costos operativos.
- Monitorear el desempeño de los paneles solares, identificando fallos antes de que ocurran.
- Automatizar la toma de decisiones con base en datos meteorológicos e históricos de la planta.

Para aprovechar al máximo el potencial de la IA en el mantenimiento de plantas solares en El Salvador, se plantean las siguientes acciones:

- Seguir de cerca el desarrollo normativo en materia de IA, especialmente las leyes de protección de datos y ciberseguridad.
- Aprovechar incentivos fiscales establecidos en la LFIMT para la adopción de IA en procesos industriales y energéticos.
- Fomentar colaboraciones con instituciones gubernamentales y académicas que promuevan la investigación en IA aplicada al sector energético.
- Asegurar el cumplimiento de estándares internacionales en el desarrollo de IA para garantizar la ética y transparencia en su aplicación.

CAPÍTULO 3

Optimización del mantenimiento preventivo enfocado en inversores de 215 kW con IA.

En este capítulo se explicará qué datos serán usados en el análisis, entre ellos la temperatura y la irradiancia para la predicción de potencia generada, al mismo tiempo se hará su procesamiento, depuración y normalización. Se justificará por qué las variables seleccionadas son relevantes para predecir el rendimiento y mantenimiento preventivo. Se detallará el flujo de datos y la manera como se integrarán los datos históricos. Adicionalmente, se explicarán los modelos de aprendizaje automatizado (machine learning) y redes neuronales, donde se especificarán los entornos en los cuales desarrollar las redes neuronales y machine learning, así como los recursos necesarios del hardware. Finalmente, se evaluarán las variables ingresadas en la IA para comenzar a optimizar el mantenimiento preventivo. Posteriormente se aplicarán las herramientas de evaluación.

3.1 Enfoque y tipo de investigación

La investigación tiene un enfoque cuantitativo-aplicado, cuyo objetivo es analizar datos operacionales reales para mejorar el sistema de mantenimiento preventivo de un parque solar en El Salvador. Este estudio se considera no experimental, longitudinal y descriptivo-tecnológico ya que no existen variables que se manipulan para recopilar información; simplemente, se registran partes relacionadas con la inteligencia artificial de los datos operacionales, siguiendo una metodología definida en investigaciones previas respecto al mantenimiento predictivo en sistemas energéticos.

3.1.1 Descripción del Caso de Estudio

Durante el periodo de análisis (año 2024), se identificaron un total de 14 fallos que requirieron reemplazo de equipos para todos los casos. Estos eventos son los que se toman en consideración para la validación posterior de la predicción del modelo entrenado.

En primera instancia, se tomó como antecedente el informe realizado por el fabricante de los inversores, donde se concluía que los equipos habían sido afectados por factores externos, principalmente la humedad, sin embargo, se consideraron distintas variables para encaminar los modelos de prueba, ya fueran métodos estadísticos, entrenamiento de IA o una combinación de ambas. Se ocuparon diferentes modelos para la evaluación del caso de estudio, a continuación, se presenta cada uno de ellos, las consideraciones asociadas, los resultados obtenidos y una comparación final de los mismos.

Para todos los modelos se recopilaron datos de las siguientes fuentes:

- El sistema SCADA de la planta, que contiene registros de variables como:
 - Potencia activa (kW)
 - Temperatura interna del inversor (°C)
 - Corriente de entrada/salida
 - Tensión DC/AC
 - Estado operativo del inversor
 - Alarmas
 - Irradiancia (W/m²)

- Temperatura ambiente(°C)
- Y otros
- Registros históricos de fallos
- Programa de mantenimiento

Las herramientas y entornos utilizados fueron los siguientes:

- Python 3.10 como lenguaje de programación.
- Librerías: TensorFlow, Keras y Scikit-learn para el entrenamiento y evaluación del modelo.
- Pandas y NumPy para la manipulación de los datos.
- Matplotlib y Seaborn para la visualización de datos.
- Entorno de ejecución: Google Colab para entrenamiento y visualización. Jupyter Notebooks para entrenamiento en los casos donde los recursos disponibles de Google Colab no fuesen suficientes.
- Excel 2013 para visualización complementaria de tendencias operativas y validación con el equipo de O&M.

3.2 Método de Regresión Lineal y RMSE

En este modelo la variable a considerar inicialmente fue el "yield" que es la energía generada por potencia instalada, es decir, kWh/kWp. El primer paso fue el análisis comparativo del Yield entre los inversores de la planta, tomando datos diarios por el periodo de 1 año (2024), con ello se pudieron identificar los inversores cuya producción había disminuido significativamente respecto a los demás o se había interrumpido, y cuáles no presentaron interrupciones. Esto coincidió con las fechas reportadas de fallo de inversores.

Una vez identificados los inversores “fallados” y “no fallados” con base al Yield, la siguiente variable a considerar fue la Temperatura interna (°C), ya que el sobrecalentamiento suele ser un síntoma temprano de fallo, provocado por ventilación obstruida, deficiencia en la disipación térmica, falla de componentes internos, etc., además que un inversor puede seguir produciendo mientras se degrada térmicamente, algo que no siempre se ve reflejado en el yield, por ejemplo, en condiciones normales, mayor yield equivale a mayor temperatura interna, sin embargo, si el yield es bajo y la temperatura alta, se considera anormal, puede haber un desbalance interno y conlleva a la disminución en el rendimiento y durabilidad del equipo, que es el caso de La Planta. Para realizar el desarrollo correcto del modelo, se depuraron los datos extraídos del SCADA, eliminando valores nulos, verificando insistencias y unificando la información horaria con las fechas.

3.2.1 Arquitectura del modelo

Con el objetivo de obtener una visión más detallada de dicho argumento, se definió el yield como una variable independiente (dato de entrada) y la temperatura interna como dependiente, y así identificar si los inversores fallados tienen un comportamiento térmico anómalo, es decir, si están más calientes de lo esperado para su rendimiento. Para ello el modelo a utilizar inicialmente, fue “Regresión Lineal”, el cual es tanto un método estadístico,

como un modelo de aprendizaje automático (ML), en este caso fue aplicado como ML utilizando datos históricos horarios de inversores sanos por el periodo de un año, con el objetivo de predecir la temperatura interna (°C) esperada de un inversor en función de su producción (yield) y ajustar la recta minimizando el error cuadrático medio, es decir, es un modelo supervisado de regresión porque se entrena usando dichos datos etiquetados, la relación matemática con la que aprende es:

$$T = a \times Yf + b \quad (7)$$

Donde:

T = Temperatura interna estimada

Yf = producción específica (kWh/kWp)

a = Coeficiente de pendiente (cuánto aumenta la temperatura del inversor por cada unidad de yield que aumenta)

b = intersección (temperatura interna estimada cuando el yield es 0)

Para este modelo se usó la plataforma Google Colab:

- Las librerías Pandas y NumPy para manejo de datos
- Matplotlib para visualización de resultados
- Skcikit-Learn para entrenamiento

Con la fórmula se entrena un modelo de regresión lineal simple implementado con Scikit-Learn. Una vez entrenado, el modelo se aplica a nuevos datos para predecir la temperatura esperada y compararla con la real. Con ello se logró establecer un patrón térmico normal de operación del inversor en función de su producción, detectar desviaciones térmicas anómalas si la temperatura real supera significativamente la predicción del modelo (considerándolo un posible fallo térmico incipiente).

3.2.2 Entrenamiento

Para cuantificar la desviación entre la temperatura predicha y la real de forma objetiva y reproducible, se aplicó un umbral basado en error (Root Mean Square Error o RMSE), ¿por qué este último como umbral?

En modelos de Regresión Lineal, se pueden probar tres tipos de errores:

- a) Error Cuadrático o Mean Square Error (MSE)

Es la medida de qué tan lejos están las predicciones de un modelo respecto a los valores reales, siendo la forma de evaluar el rendimiento del modelo en aprendizaje automático. Se realiza al cuadrado para evitar la cancelación de términos negativos además de dar mayor peso a los valores atípicos. Un buen modelo tendrá un valor más cercano a 0. En el caso de la Temperatura interna, estaría en unidad cuadrada (°C²), por lo que es menos interpretable directamente, penaliza más fuerte errores grandes por el cuadrado.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (8)$$

Donde:

MSE = Error cuadrático medio

n = número de datos

Y_i = valores observados

\hat{Y}_i = valores predichos

b) Error Absoluto Medio o *Mean Absolute Error* (MAE)

Es más interpretativo, no eleva al cuadrado los errores, se mide en términos absolutos. Al centrarse únicamente en el tamaño de los errores, ayuda a identificar qué tan lejos están las predicciones de los resultados reales si se desea una visión equilibrada. Sin embargo, puede no reflejar adecuadamente el impacto de los errores, ya que, al tratarlos por igual, es posible que no penalice los errores más atípicos, por otro lado, puede ser útil si los datos de entrenamiento tienen valores atípicos. No es diferenciable en 0.

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (9)$$

Donde:

MAE = error absoluto medio

y_i = predicción

x_i = valor verdadero

n = número total de datos

c) Raíz del Error Cuadrático Medio o *Root Mean Square Error* (RMSE)

Es la raíz cuadrada del MSE, mantiene la unidad original de los datos y penaliza más los errores grandes (si se quiere interpretar los errores en la misma escala de los datos). Cuanto menor sea el RMSE (cerca de 0) mejor será el modelo y sus predicciones.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (10)$$

Donde:

RMSE = raíz del error cuadrático medio

i = variable i

n = número de datos que no fallan

x_i = serie temporal de observaciones reales


\hat{x}_i = serie temporal estimada

El RMSE representa el error promedio en °C, y sirve como umbral adaptativo para identificar cuándo un inversor se está calentando más de lo esperado.

La prueba se realizó con 2 inversores no fallados, los resultados obtenidos de las pruebas sobre inversores no fallados son los siguientes:

Prueba Inversor 1.01 con datos horarios por 1 año (2024):

- Coeficiente: 46.8019 (°C por unidad de yield)
- Intersección: 30.81 (°C cuando yield = 0)
- RMSE: 5.79 (°C)



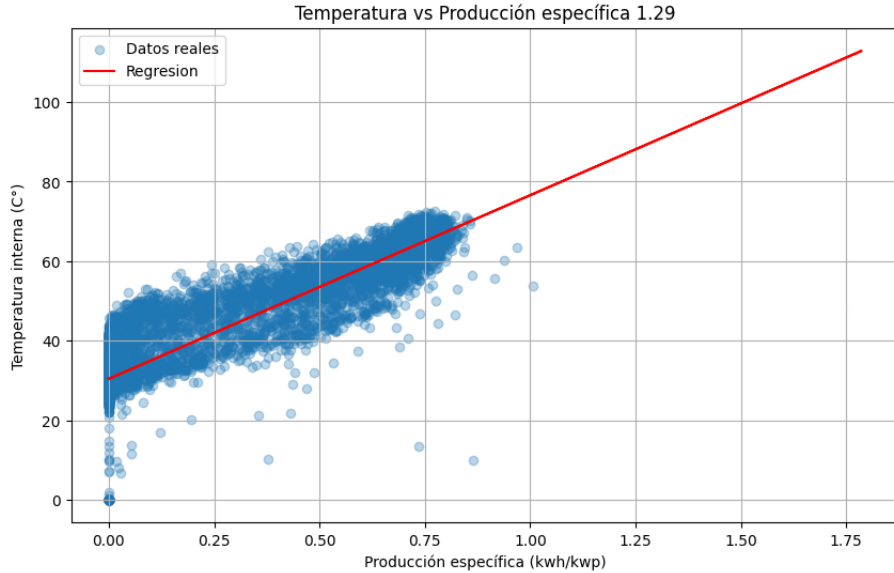
Fuente: Elaboración propia

Fig.9 Relación entre la temperatura real y la predicha, Inversor 1.01

Nota. La gráfica muestra el comportamiento térmico de un inversor no fallado (1.01) respecto a su producción, la línea de regresión indica la temperatura predicha, todo lo que se encuentre por encima de la línea, mientras no supere 2 RMSE, es considerado normal, por debajo de la línea, no es considerado anómalo ya que no hay sobrecalentamiento.

Prueba Inversor 1.29 con datos horarios por 1 año (2024):

- Coeficiente: 46.1228 (°C por unidad de *yield*)
- Intersección: 30.45 (°C cuando *yield* = 0)
- RMSE: 6.03 (°C)



Fuente: Elaboración propia

Fig.10 Relación entre la temperatura real y la predicha, Inversor 1.29

3.2.3 Evaluación y validación: Transición del modelo estadístico a un enfoque de clasificación multivariable

Una vez entrenado el modelo, se aplicaron nuevos datos de otros inversores. Para cada punto de medición se calcula la temperatura esperada, se compara con la temperatura real, se define un punto anómalo si:


$$|T_{real} - \hat{T}| > 2 \times RMSE \quad (11)$$

Esta condición permite detectar anomalías térmicas que superan el comportamiento histórico esperado en condiciones normales, es decir, un error mayor a $2 \times RMSE$ bajo el principio estadístico de que más del 95% de los datos deben situarse dentro de $\pm 2\sigma$ (asumiendo una distribución normal de los residuos), lo cual es una señal de anomalía con alta probabilidad. Es ideal si se quiere detectar fallos tempranos, aunque se arriesgue alguna falsa alarma.

Al cargar los datos de inversores identificados como “fallados”, el modelo calcula el error térmico para detectar anomalías, definiendo un “umbral crítico” de anomalías diarias equivalente a 3 en la escala horaria, obteniendo los siguientes resultados:

Prueba Inversor 2.07 con datos horarios por 1 año (2024):

- Total anomalías térmicas = 2234




Fuente: Elaboración propia

Fig.11 Gráfica de anomalías térmicas detectadas por día, Inversor 2.07

Nota: el umbral crítico se puede definir manualmente, puede haber factores que provoquen anomalías térmicas que no necesariamente sea síntoma de un fallo de inversor, sin embargo, de acuerdo con el reporte el inversor 2.07 falló el 28 de julio, mostrando un comportamiento térmico anómalo previo a dicha falla.

Prueba Inversor 1.14 con datos horarios por 1 año:

- Total anomalías térmicas = 1649



Fuente: Elaboración propia

Fig.12 Gráfica de anomalías térmicas detectadas por día, Inversor 1.14


No obstante, se identificaron algunas limitaciones en este enfoque, a pesar de su simplicidad e interpretabilidad, al ignorar otras variables eléctricas y ambientales relevantes, no captura relaciones no lineales ni efectos de interacción entre múltiples variables que influyen en la falla de inversores, por lo que solo se detectan síntomas sin entender del todo qué otras variables podían influir en el deterioro térmico o funcional (como desbalance de fases, sobrecorriente etc.), y por consiguiente jerarquía de causas.

Para superar dichas limitaciones, a continuación, se implementó un modelo de clasificación supervisada basado en Random Forest Classifier, utilizando un amplio conjunto de variables:

- Corrientes en cada fase (A)
- Tensiones en cada fase (V)

- Eficiencia (%)
- Factor de potencia
- Frecuencia (Hz)
- Humedad relativa (%)
- Irradiancia (W/m2)
- Temperatura ambiente (°C)
- Yield (kWh/kWp)
- Temperatura interna del inversor (°C)

El modelo se entrenó con los datos etiquetados “fallado” y “no fallado”, utilizando el mismo registro histórico de 2 inversores (1.14 fallado, 1.29 no fallado), y su objetivo principal no fue predecir el momento de la falla sino identificar qué variables están asociadas a los inversores que presentan fallas, y cuál es su importancia relativa en el comportamiento del sistema, así se logró pasar de un modelo estadístico univariable a uno multivariable interpretativo centrado en entender las condiciones asociadas a fallos. El conjunto de entrenamiento fue dividido en 80% entrenamiento y 20% prueba, y al ser evaluado dio como resultado una precisión del 88%. Con ello se procedió a clasificar qué variables eléctricas o ambientales son las de mayor relevancia para la predicción de fallas.



Fuente: Elaboración propia

Fig.13 Jerarquización de variables con RandomForestClassifier

Si bien no es un modelo predictivo en el tiempo, permite caracterizar estados operativos, dando paso a modelos más avanzados de predicción como Decision Tree Classifier o LSTM, que se describen más adelante.

3.3 Método Clasificación con Árboles

Con este método el objetivo fue predecir fallas de inversores en función de condiciones térmicas. Se entrenó un modelo de clasificación con árboles de decisión (Decision Tree Classifier), dado su bajo costo computacional y su capacidad interpretativa con características valiosas en entornos industriales.

Las variables analizadas fueron:

- Temperatura interna del inversor(°C).
- Temperatura ambiente (°C).
- Tensión de fase 1-3 (V).
- Tensión de fase 2-3 (V).
- Tensión de fase 1-2 (V).

Se realizó una depuración de los datos para eliminar:

- Valores donde la temperatura interna era cero.
- Valores nulos o inconsistentes.
- Se renombraron títulos de variables para un manejo más adecuado de los datos.

Se utilizaron los datos de 1 inversor con falla y un inversor sin falla para poder realizar el entrenamiento apropiado del modelo, cada uno de estos inversores contenían datos con frecuencia de 5 minutos durante un año.

3.3.1 Arquitectura del modelo

Decision Tree Classifier es un algoritmo de clasificación que se basa en la estructura de un árbol de decisiones, donde cada nodo interno representa una pregunta sobre una característica, cada rama representa el resultado de esa pregunta, y cada nodo hoja representa una clase predicha.

3.3.2 Entrenamiento

Durante la fase de entrenamiento del modelo, se empleó la técnica de validación cruzada con el propósito de evaluar su capacidad de generalización. Asimismo, se realizó un ajuste de hiper parámetros fundamentales, tales como la profundidad máxima del árbol y el número mínimo de muestras requeridas por hoja. La selección de la configuración óptima se basó en el análisis de métricas de desempeño, priorizando la maximización de la precisión y la reducción del error de clasificación.


3.3.3 Evaluación y validación

Los resultados indicaron una alta capacidad del modelo para anticipar comportamientos anómalos antes de que ocurriera una falla crítica, validando su utilidad para aplicaciones de

mantenimiento predictivo. Además, se realizaron pruebas con datos de inversores que fallaron en la vida real, confirmando que el modelo detectaba tendencias anómalas días antes de la falla registrada.


La evaluación del modelo se llevó a cabo utilizando datos operativos de cuatro inversores que presentaron fallas durante el periodo de análisis. El conjunto de datos abarcó un historial de un año, con una resolución temporal de cinco minutos, lo que proporcionó una base robusta para el análisis de comportamiento previo a las fallas. Sin embargo, el modelo fue finalmente descartado, ya que mostró una capacidad limitada para generalizar su desempeño. Aunque en los primeros casos analizados logró detectar comportamientos anómalos, al ser aplicado a los demás inversores, no logró identificar tendencias similares, incluso ante fallas verificadas. En varios escenarios, los parámetros monitoreados no alcanzaron los umbrales establecidos por el modelo, lo que impidió la emisión de alertas o advertencias tempranas. Esta limitación evidenció una baja fiabilidad del modelo para ser utilizado como herramienta predictiva a escala general en el parque solar.

A continuación, se presentan ejemplos gráficos del comportamiento térmico y de producción de inversores con falla inminente. Se observa una tendencia anómala o inestable en los días previos a la falla:



Fuente: Elaboración propia


Fig.14 Comportamiento de temperatura interna del inversor 1.28 en los días previos a su falla



Fuente: Elaboración propia

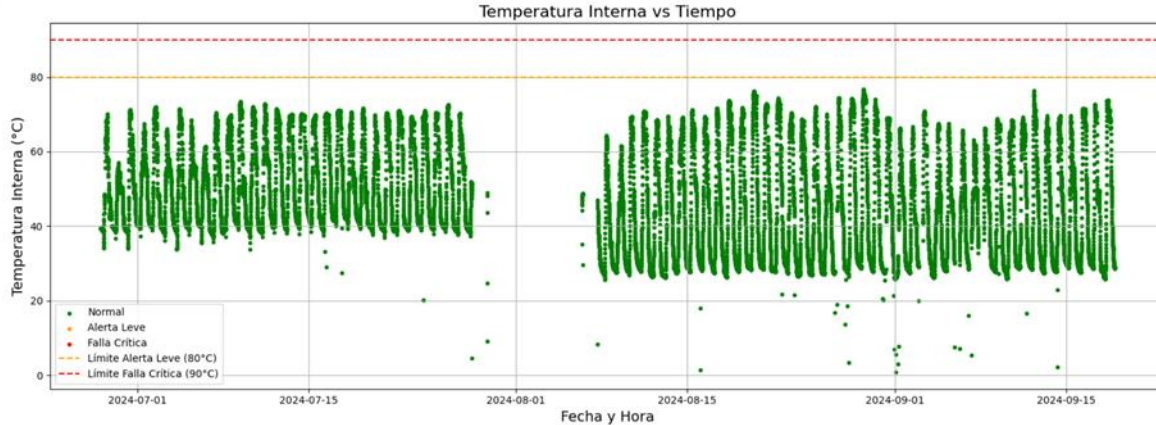
Fig.15 Comportamiento de temperatura interna del inversor 1.12 en los días previos a su falla

En las gráficas Fig. 14 y Fig. 15 muestran cómo los modelos de IA detectan desviaciones antes de que se registre la falla real, lo cual valida su uso como herramienta predictiva para optimizar los planes de mantenimiento. Al aplicar el modelo a otros inversores con historial de fallas, se observaron ciertas limitaciones en cuanto a la consistencia en la detección de patrones anómalos. En algunos casos, las tendencias previas a la falla no fueron tan claras o no se alinearon con los umbrales establecidos como en la Fig. 16 y Fig. 17, lo que afectó la generación oportuna de alertas. Estos hallazgos sugieren que, si bien el modelo demuestra capacidades valiosas para casos específicos, su desempeño podría beneficiarse de ajustes adicionales que mejoren su capacidad de generalización a un conjunto más amplio de equipos. Esto abre la puerta a futuras mejoras en el entrenamiento del modelo, incluyendo la incorporación de más datos, variables complementarias o enfoques híbridos que refuercen su precisión y aplicabilidad a escala de planta.



Fuente: Elaboración propia

Fig.16 Comportamiento de temperatura interna del inversor 2.07 en los días previos a su falla



Fuente: Elaboración propia

Fig.17 Comportamiento de temperatura interna del inversor 2.08 en los días previos a su falla

3.4 Modelo Autoencoder LSTM

En este modelo se realiza un análisis a las variables a lo largo del tiempo para identificar si existen patrones que anteceden a los fallos en los inversores. La metodología está basada en análisis de series temporales y aprendizaje automático para extraer información relevante de los datos históricos, registrados por el sistema SCADA de la planta.

Se realizó una depuración de los datos para eliminar:

- Registros con irradiancia menor a 20 W/m^2 y potencia activa igual a cero, para solo trabajar con horas de generación.
- Valores nulos o inconsistentes
- Se homogeneizaron las fechas y horas para asegurar sincronización entre los archivos.
- Registros donde la potencia activa fuera cero en más de 2 inversores, para discriminar salidas de la planta asociados a fallas externas

Las variables seleccionadas para el modelo fueron:

- Potencia activa (kW)
- Temperatura interna del inversor ($^{\circ}\text{C}$)
- Eficiencia (%)
- Irradiancia (W/m^2)

Estas fueron elegidas por su alta correlación con el estado de salud del inversor y porque mostraron comportamientos anómalos en los días previos al fallo en los casos históricos analizados. Para ello se utilizó un análisis con inteligencia artificial del tipo supervisado, de acuerdo con lo explicado anteriormente en el apartado 3.2.3, el modelo Random Forest Classifier (Fig. 13).

3.4.1 Arquitectura del modelo LSTM Autoencoder

El modelo utilizado es un Autoencoder basado en redes neuronales LSTM (Long Short-Term Memory), configurado con la siguiente arquitectura:

- Capa de entrada: Esta capa tiene el tamaño de datos correspondiente a los datos de las ventanas temporales y al número de variables
- Capa LSTM codificadora: reduce la dimensionalidad de la secuencia de entrada, comprimiendo la secuencia de entrada, esta parte representa el comportamiento típico del sistema
- Capa LSTM decodificadora: intenta reconstruir la secuencia original. Si el modelo falla al reconstruir una secuencia (es decir, el error de reconstrucción es alto), se interpreta como una anomalía.

Este tipo de modelo permite capturar dependencias temporales a largo plazo

3.4.2 Entrenamiento del modelo

Conjunto de entrenamiento

Se entrenó el modelo exclusivamente con ventanas normales (es decir, sin fallos ni anomalías) para que aprendiera el comportamiento típico de operación del inversor.

El conjunto total fue dividido en:

- 80% para entrenamiento
- 20% para validación

Se utilizó el algoritmo Adam como optimizador y la función de pérdida MSE (Mean Squared Error).

Para la selección del conjunto de entrenamiento se ocuparon 2 criterios:

1. Cantidad de inversores
2. Cantidad de tiempo

La combinación de esos criterios junto a la segmentación de las ventanas temporales permitió hacer diferentes escenarios.

Segmentación de ventanas temporales

Se utilizaron dos tipos de ventanas una equivalente a 1 día y otro a 7 días. Estas ventanas se desplazaron con un stride (paso) de 1 día para maximizar el número de ejemplos.

Estandarización global

Todas las variables fueron normalizadas utilizando una función de estandarización global entrenado únicamente con datos normales. Esto permite organizar los datos de manera eficiente y consistente, eliminando la redundancia y mejorando la integridad de la información permitiendo que el modelo aprenda el comportamiento típico del inversor, y facilite la detección de desviaciones posteriores.

Umbral de detección de anomalías

Una vez entrenado el modelo, se calculó el error de reconstrucción para cada ventana. Posteriormente, se definió un umbral de anomalía basado en el percentil 95 del error observado en los datos normales. Este umbral fue seleccionado debido a que ofrecía los mejores resultados, al incluir únicamente valores considerablemente atípicos, excluyendo aquellos valores fuera del rango normal que pudieran deberse a condiciones operativas comunes en la planta y no a una condición previa a fallo. Cualquier ventana con error superior a este umbral será clasificada como ventana anómala. Cualquier ventana con error superior a este umbral será clasificada como ventana anómala.

Escenarios utilizados

Los diferentes escenarios que se probaron para la detección de las anomalías fueron los siguientes:

- 3 inversores 3 meses en ventanas de 1 día
- 3 inversores 3 meses en ventanas de 7 días
- 3 inversores 6 meses en ventanas de 1 día
- 6 inversores 3 meses en ventanas de 7 días

3.4.3 Evaluación y validación


El modelo fue validado en cada uno de los escenarios, utilizando ventanas generadas a partir de inversores que fallaron (según datos históricos), pero que no fueron usados en el entrenamiento. Los resultados mostraron que, en la mayoría de los casos, el modelo identificaba ventanas anómalas días antes del fallo real. Se elaboraron curvas temporales para visualizar el error de reconstrucción en los días previos al fallo, demostrando un crecimiento progresivo del error hasta alcanzar el umbral. A continuación, se presenta al menos un inversor evaluado en cada uno de los escenarios anteriormente mencionados, para este caso el inversor evaluado es el inversor identificado como 1.28, el cuál presentó la falla el día 16 de mayo del año 2024.



Fuente: Elaboración propia

Fig.18 LSTM en escenario 3 inversores - 3 meses en ventanas de 1 día

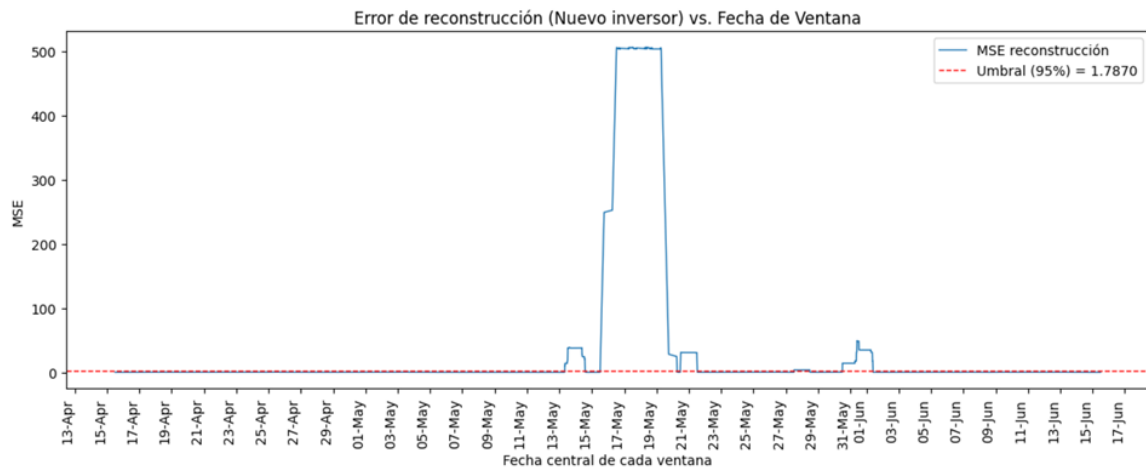
Nota: Se puede observar que en este escenario se observa una anomalía 3 días antes de la falla, pero luego se presenta un comportamiento normal y posteriormente un día de anticipación a la falla.



Fuente: Elaboración propia

Fig.19 LSTM en escenario 3 inversores - 3 meses en ventanas de 7 días


Nota: Para este escenario se presenta un comportamiento anómalo desde el 8 de mayo unos 8 días antes de la falla, y se presenta en tendencia creciente hasta el día de la falla.



Fuente: Elaboración propia

Fig.20 LSTM en escenario 3 inversores - 6 meses en ventanas de 1 día

Nota: Para este escenario se tiene un comportamiento parecido al primer escenario.



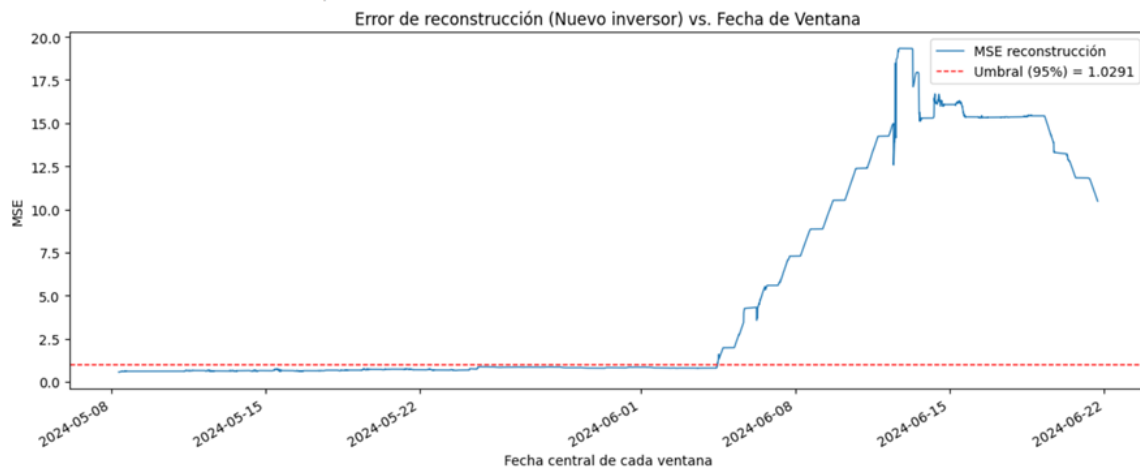
Fuente: Elaboración propia

Fig.21 LSTM en escenario 6 inversores - 3 meses en ventanas de 7 días

Nota: Para este caso se tiene un comportamiento parecido al segundo escenario, considerando en este caso que el error es mucho mayor comparado con el segundo, como se puede observar en la fig. 21.

Sin embargo, se observa que para el escenario de 3 inversores 3 meses en ventanas de 7 días se tiene un comportamiento que predice la falla de una manera más efectiva mostrándola con unos días más de antelación, además este escenario se vuelve más efectivo ya que ocupa menos recursos a la hora del entrenamiento del modelo, obteniendo casi los mismos resultados que con más tiempo o más inversores, en cuanto a la tendencia a observar.


En este escenario se verifican otros inversores tantos fallados como no fallados para validar el modelo obteniendo lo siguiente:



Fuente: Elaboración propia

Fig.22 LSTM Inversor 1.17 fecha de fallo: 11/06/2024


Nota: Como se puede observar en el gráfico de la fig.22 la predicción de comportamiento anómalo es de 11 días anteriores a la falla.



Fuente: Elaboración propia

Fig.23 LSTM Inversor 2.07 fecha de fallo: 28/07/2024


Nota: Como se puede observar en el gráfico de la fig. 23 la predicción de comportamiento anómalo es de 8 días anteriores a la falla.



Fuente: Elaboración propia

Fig.24 LSTM Inversor 1.13 no fallado

Nota: Como se puede observar en la fig.24 la predicción es satisfactoria ya que no presenta valores fuera del umbral, ya que este caso es un inversor no fallado.



Fuente: Elaboración propia

Fig.25 LSTM Inversor 1.18 no fallado

Nota: Para este caso se observa en la gráfica de la fig. 25 que para cierto día el gráfico supera el umbral indicando una posible anomalía, sin embargo, los valores lo superan por muy poco comparado con los fallados.

3.5 Integración con el plan de mantenimiento

A partir de la información generada por el modelo, se propuso una estrategia de mantenimiento predictivo basada en alertas anticipadas. Los principales elementos fueron:

- Generación automática de alertas si se detecta una ventana anómala en un inversor.
- Clasificación de criticidad según el valor del error y la tendencia.
- Priorización de inspecciones térmicas y revisión de conexiones eléctricas en inversores con alertas frecuentes.
- Optimización de recursos de mantenimiento mediante programación anticipada de intervenciones.

Al integrar los resultados de los diferentes modelos, se propone una arquitectura de mantenimiento optimizado basada en tres niveles funcionales:

- a. Monitoreo continuo con regresión lineal + RMSE

Funciona como un primer filtro para detectar desviaciones térmicas que excedan los parámetros históricos normales de operación y podría utilizarse para emitir alertas inmediatas ante sobrecalentamientos injustificados.

- b. Clasificación y explicación con árboles de decisión (Decision Tree) y Random Forest (RF)

El árbol de decisión proporciona reglas claras que detallan condiciones de riesgo, mientras RF clasifica el estado del inversor con base en múltiples variables y destaca cuáles son más determinantes para el fallo. Esto orientaría las inspecciones mejorando la asignación de recursos.

- c. Detección anticipada con Autoencoder LSTM

Al aplicarse de forma regular en ventanas semanales, el modelo detectaría secuencias anómalas y genera alertas predictivas con antelación suficiente para ejecutar mantenimientos preventivos programados. Se recomienda utilizar la configuración más efectiva validada: 3 inversores, 3 meses en ventanas de 7 días.

3.6 Comparativa de métodos propuestos

Cada método probado permitió un análisis profundo de las distintas variables que influyen en el comportamiento anómalo de un inversor, y con ello se logró un mayor acercamiento a la predicción de fallas, los resultados evidencian algunas limitaciones, sin embargo, su aplicación permitiría generar alertas tempranas que logren realmente mejorar un plan de mantenimiento. A continuación, en la Tabla 1, se hace una comparativa resumida de cada método.

Tabla 1.

Método	Ventajas	Desventajas	Limitaciones
Método de Regresión Lineal y RMSE	Fácil de implementar y comprender; permite establecer relaciones lineales entre variables.	Limitado a relaciones lineales; baja sensibilidad a variaciones complejas.	No captura relaciones no lineales; dependiente de la calidad del yield.
Arboles de decisión	Capacidad para manejar relaciones no lineales; jerarquiza variables importantes.	Puede sobre ajustarse con muchos árboles; sensibilidad a valores atípicos.	Dificultad para interpretar modelos complejos en Random Forest.
LSTM Autoencoder	Detecta patrones complejos en series temporales; identifica anomalías sin supervisión directa.	Mayor complejidad computacional; requiere más datos y entrenamiento intensivo.	Requiere una arquitectura bien ajustada.

Fuente: Elaboración propia

CAPÍTULO 4

Validación de la optimización del plan de mantenimiento mediante inteligencia artificial.

En este capítulo se validará la optimización del plan de mantenimiento desarrollado en el capítulo anterior, mediante técnicas de inteligencia artificial, así como los hallazgos clave relacionados con la predicción de fallas.

Se analizará cómo el modelo propuesto se posiciona en términos de aplicabilidad y ventajas frente a enfoques tradicionales. Asimismo, se presentará un análisis comparativo de los costos asociados al mantenimiento preventivo utilizando el modelo de inteligencia artificial propuesto frente a los métodos tradicionales; y finalmente, se evaluarán aspectos como la reducción de costos operativos, el impacto económico de la disminución de fallas y los beneficios económicos de una mayor eficiencia en la gestión del mantenimiento.

4.1 Evaluación de la Aplicabilidad

La validación del modelo no solo debe estar enfocada en su precisión estadística sino también en su aplicabilidad práctica en un entorno real, y las ventajas que este podría ofrecer respecto al enfoque tradicional u otros enfoques. A continuación, se presentan los elementos que demuestran esta validación.

4.1.1 Aplicabilidad en un entorno operativo real

La implementación del modelo está orientada para aplicarse en un ambiente real, que tenga a disposición cualquier operario de una planta solar, para ello se buscó a través de los diferentes modelos, los escenarios que dieran los mejores resultados con los menores recursos computacionales, haciendo una valoración costo-beneficio, y así, poder implementar la herramienta de seguimiento sin necesidad de invertir en un hardware nuevo, por lo que se buscó que tuviera los requerimientos normales de un computador típico en un centro de control.

Se comprobó que el modelo para LSTM permite anticipar anomalías con un horizonte temporal de entre 8 y 11 días, ofreciendo tiempo suficiente para la programación de intervenciones preventivas o planes de acción.

4.1.2 Ventajas frente a métodos estadísticos y reglas fijas

Comparado con los métodos tradicionales de monitoreo y seguimiento, el modelo de inteligencia artificial demostró ventajas notables:

Mayor objetividad: Cuando el análisis se realiza a través de métodos estadísticos con mucha intervención humana, esto puede permitir sesgos del operador queriendo encontrar patrones con base a experiencias anteriores.

Mayor sensibilidad y especificidad: La capacidad de los modelos con inteligencia artificial para identificar patrones complejos es mucho mayor que la de un humano analizando un conjunto grande de datos.

Adaptabilidad: El modelo puede actualizarse con datos recientes para reajustar su comportamiento ante cambios en las condiciones operativas (ensuciamiento de módulos, degradación de equipos, variaciones estacionales, etc.).

Capacidad de multivariable: A diferencia de enfoques basados en una o dos variables, el modelo integra múltiples señales en simultáneo, permitiendo un diagnóstico más integral.

4.1.3 Limitaciones identificadas

Si bien los resultados fueron satisfactorios, se identificaron limitaciones importantes:

Dependencia de la calidad de los datos: La precisión del modelo decrece significativamente ante datos incompletos o con errores de registro. Este es un tema crítico, pero que podría también automatizarse con scripts generados que realicen el filtrado correcto de los datos.

Curva de aprendizaje: El personal técnico requiere capacitación específica para interpretar los indicadores generados por el sistema. Esta limitante aplicaría para cualquier sistema nuevo que se deseara implementar, sin embargo, es necesario considerarla.

Capacidad de cómputo: El procesamiento en tiempo real o casi real demanda muchos más recursos informáticos a los empleados en otros enfoques, sobre todo cuando el análisis se quiere hacer con series temporales mayores o una mayor cantidad de equipos.

4.2 Análisis comparativo de costos

El análisis económico es un componente esencial para valorar la viabilidad de la implementación de esta nueva herramienta, el enfoque de este análisis será tanto en costos operativos de mantenimiento como en costos por energía no generada. A continuación, se describen los costos comparativos entre el modelo propuesto y el enfoque tradicional.

4.2.1 Costos operativos

En su enfoque tradicional, la planta solar evaluada destinaba recursos a inspecciones periódicas con una frecuencia definida por el fabricante de los equipos y las buenas prácticas. Este enfoque implicaba:

- Mantenimientos preventivos programados con un cronograma y una calendarización fija. Para esta planta en particular, en el caso de los inversores, se realizaba un mantenimiento semestral de la zona de ventiladores.
- Intervenciones correctivas tras la ocurrencia de fallas no detectadas a tiempo.

El costo anual promedio de mantenimiento bajo este esquema se encuentra en el rango de \$112,000.00 - \$156,000.00, considerando mano de obra y recursos. Como se puede ver en [31].

Con este nuevo enfoque, los costos operativos per se, no implicarían una reducción o aumento significativo, ya que la frecuencia de mantenimientos preventivos que se vería afectada sería únicamente la asociada a la limpieza de los ventiladores que debería de hacerse

con una periodicidad mayor, ya que como se observó en el modelo de árbol de decisión la temperatura interna fue un problema clave antes de los fallos de los inversores.

Sin embargo, si se pudiera ver una reducción en las intervenciones de tipo correctivas, estas suelen tener un costo mucho más elevado que las intervenciones de tipo preventivas, ya que carecen de planificación, muchas veces se debe recurrir a recursos y horas hombre extra, lo que puede implicar sobrecostos. Si la falla se logra detectar con días de anticipación, el operador podrá prepararse y tomar diferentes planes de acción, uno de ellos puede ser la reducción de potencia en el inversor para evitar la falla inminente del mismo, y así gestionar la garantía con el proveedor.

4.2.2 Energía no servida

Las pérdidas por energía no servida son las que representan un ahorro significativo con la implementación de este nuevo enfoque, para evaluar esta implicación económica se plantearán 2 escenarios:

- Primer escenario, será el más optimista, en el que se logra un acuerdo con el proveedor *“si se puede comprobar que el fallo está asociado a los fallos ocurridos anteriormente, la garantía se pueda aplicar inmediatamente, si detectan 2 días de ese comportamiento”*.
- Segundo escenario, donde *“el comportamiento anormal se debe presentar durante 5 días y posterior a ello el fabricante autoriza reducir potencia hasta el cambio del inversor”*.

Para hacer el análisis económico se tomarán las siguientes premisas:

- El precio de la energía del PPA se estimará en \$100.00/MWh
- Se tomará un promedio del tiempo en el cual está fuera de línea el inversor con base al histórico de fallos

Tabla 2. Días fuera de línea por inversor, de acuerdo con histórico de fallos.

Identificación	Días fuera de generación
Inversor 1.12	4
Inversor 1.14	6
Inversor 1.17	7
Inversor 1.22	11
Inversor 1.23	4
Inversor 1.25	6
Inversor 1.27	8
Inversor 1.28	4
Inversor 2.03	13
Inversor 2.04	3
Inversor 2.07	23
Inversor 2.08	11

Inversor 2.17	4
Inversor 2.21	11
Promedio	8

Fuente: Elaboración propia

Nota: para este caso son 8 días en promedio.

Debido a que la falla se pudiera presentar en cualquier época del año se asumirá una generación promedio de las diferentes épocas del año y de diferentes inversores.

Tabla 3. Generación promedio de algunos inversores, en distintos días del año.

Energía Inversor (kWh)	10/1/2024	10/3/2024	7/6/2024	4/9/2024	21/11/2024	Promedio
1.12	1665.30	1728.60	1302.74	1272.65	1116.22	1417.10
1.14	1214.70	1709.60	1291.90	1239.31	1106.19	1312.34
1.17	1305.30	1730.90	1070.60	1271.56	1105.06	1296.68
1.22	1613.40	1683.90	1264.30	1240.00	1089.00	1378.12
1.23	1442.30	1649.10	1227.90	1225.50	1072.37	1323.43
1.25	1513.60	1685.00	1272.28	1233.50	1083.31	1357.54
1.27	1535.80	1690.60	1281.40	1080.81	1080.85	1333.89
1.28	1524.60	1649.10	1287.70	1231.38	1098.00	1358.16

Fuente: Elaboración propia con datos del SCADA

Nota: En el caso de este proyecto un promedio de 1347kwh diarios

Con esto se calcula el valor de pérdida por no generación de 14 inversores fallados durante 8 días cada uno, siendo este el caso base:

Tabla 4. Escenario 1: estimado de pérdida económica por no generación.

Número de fallos	Días Fallados	Generación diaria (kWh)	Generación Total (MWh)	Pérdida al año
14	8	1347	150.86	\$ 15,086.40

Fuente: Elaboración propia

Nota: de acuerdo con las condiciones de este escenario, donde no se tendrían fallos (el cambio se realizaría antes de la falla) se tendría un ahorro de \$15,086.40

Tabla 5. Escenario 2: estimado de pérdida económica por no generación.

Número de fallos	Días generando al 50%	Generación diaria (kWh)	Generación Total (MWh)	Pérdida al año
14	8	673.5	75.43	\$ 7,543.20

Fuente: Elaboración propia

Nota: considerando que el comportamiento anómalo fue detectado con 8 días de anticipación, 5 días fueron de comprobación y posterior a eso 8 días de generación a media potencia en lo que se reemplaza el inversor, el ahorro sería de \$7,543.20

Como se puede observar el enfoque del escenario 2 realmente representa un ahorro, en términos económicos, y rendimiento de la planta.

4.2.3 Costo de implementación de un sistema con herramientas de IA

En este apartado se estimará los costos que podrían estar asociados a la implementación de las herramientas con inteligencia artificial, para ello se considerará lo siguiente:

2. Infraestructura (hardware y software)
3. Desarrollo de la solución y automatización
4. Entrenamiento de personal y mantenimiento del modelo

La planta ya cuenta con el sistema SCADA y el almacenamiento de datos por lo que esto no representaría un costo adicional, de igual manera si se utiliza Python como software base, este es gratuito.

El desarrollo de la solución, la automatización y la integración, para este caso propuesto podría rondar entre \$5,000.00 y \$10,000.00 dependiendo del nivel de detalle y complejidad requerido [28], aquí se incluiría un reentrenamiento cada 6 - 12 meses en base a la actualización de datos que podría rondar \$500.00 - \$1000.00. [29] [30]

El entrenamiento de personal (2 técnicos) y la creación de un manual de operación que incluya el documento de uso y protocolo basado en alertas generadas por IA \$1,000.00 - \$1,500.00

Por lo que la implementación tendría un costo inicial estimado en \$7,000.00 y un costo de mantenimiento de \$500.00 anuales.

Esto implicaría que, si esta planta mantuviera una tasa de fallo similar todos los años, el retorno de la inversión de la implementación, sería en 1 año para el escenario número 2.

CAPÍTULO 5

Conclusiones y recomendaciones

5.1. Conclusiones

El desarrollo e implementación de modelos de inteligencia artificial permitió demostrar cómo un enfoque basado en datos puede transformar la estrategia de mantenimiento preventivo de un parque solar. Esto por medio de 3 enfoques progresivos: regresión lineal que permitió establecer una relación estadística entre la producción de energía y la temperatura interna de los inversores utilizando el Error cuadrático Medio como métrica, si bien esta herramienta demostró ser útil como un primer filtro, su limitación radica en la cantidad de variables y que no es predictivo; como evolución de este análisis se entrenó un modelo Random Forest Classifier, que permitiría extender la capacidad del árbol de decisión individual mediante la adición de múltiples árboles, también permitió identificar la importancia relativa de las variables en la clasificación de inversores como “fallados” y “no fallados”, centrándose más en la caracterización del comportamiento operativo anómalo que en predicciones temporales; posteriormente al incorporarse el modelo Decision Tree Classifier, facilitó la segmentación explícita de los datos con base en umbrales críticos de variables que podrían ayudar al personal técnico a entender cuándo y por qué un inversor puede considerarse en estado anómalo, aunque su capacidad predictiva fue moderada; y finalmente el modelo basado en Autoencoder LSTM resultó ser el más preciso en términos de anticipación de fallos, permitió detectar secuencias de comportamiento atípico entre 8 y 11 días de anticipación antes de una falla documentada, resultando una herramienta más robusta para la predicción temprana.

Se logró una comprensión más profunda del comportamiento térmico y eléctrico de los inversores, resaltando que el mantenimiento preventivo es esencial para garantizar la disponibilidad y eficiencia de los sistemas fotovoltaicos; sin embargo, los enfoques tradicionales presentan limitaciones en cuanto a costos de mantenimiento y tiempos de ejecución. En este contexto, el mantenimiento predictivo, respaldado por técnicas de inteligencia artificial, se posiciona como una alternativa efectiva al permitir la anticipación de fallos y la planificación oportuna de intervenciones, lo que reduce significativamente los periodos de inactividad y los costos del mantenimiento correctivo. Asimismo, la integración de modelos predictivos con pronósticos de producción energética resulta clave para minimizar el impacto en la generación durante las labores de mantenimiento. En general, la inteligencia artificial representa una herramienta poderosa para optimizar la gestión de dichas labores, superando las limitaciones de los métodos manuales y estadísticos convencionales, al ofrecer análisis más objetivos, precisos y adaptativos.

Se concluye que la implementación de un plan de mantenimiento preventivo optimizado para inversores de 215 kW, basado en datos operativos reales y modelos de inteligencia artificial, permitió anticipar fallas con alta precisión, destacándose el modelo Autoencoder LSTM por su capacidad para detectar anomalías térmicas con hasta 11 días de anticipación. La identificación de variables clave como la temperatura interna, la irradiancia y la eficiencia

del inversor contribuyó a un diagnóstico más preciso y multivariable, mientras que la integración de alertas automáticas y criterios de priorización en la estrategia operativa fortaleció la toma de decisiones y la eficiencia del mantenimiento. Aunque presenta limitaciones asociadas a la calidad de los datos, la necesidad de formación técnica y el uso de recursos computacionales, su aplicación permite una reducción significativa de costos correctivos y pérdidas por energía no servida, generando beneficios económicos relevantes a mediano y largo plazo.

5.2. Líneas de investigación recomendadas

Con base en los resultados obtenidos y en búsqueda por maximizar el impacto de la implementación de inteligencia artificial en el mantenimiento preventivo de parques solares, se proponen líneas de investigación futuras para superar las limitaciones identificadas, ampliar la aplicabilidad del plan diseñado y optimizar aún más los costos y tiempos de mantenimiento:

Ampliación del modelo a otros componentes críticos de la planta solar. Extender el enfoque de predicción de fallos a transformadores, combiner boxes y módulos fotovoltaicos, analizando su comportamiento y degradación con IA.

Explorar la integración en tiempo real del modelo entrenado en sistemas SCADA operativos, evaluando su rendimiento en condiciones dinámicas con datos en vivo y determinando la latencia y confiabilidad operativa bajo carga real.

Se recomienda que futuras investigaciones incorporen variables adicionales como el Performance Ratio (PR), el Yield y otros indicadores de rendimiento energético, ya que estos permiten un análisis más integral del estado operativo de los equipos. La inclusión de estas métricas puede mejorar la sensibilidad y precisión de los modelos predictivos, al ofrecer una visión más completa del comportamiento real de la planta, permitiendo anticipar fallas o degradaciones que no siempre son evidentes a partir únicamente de variables eléctricas o térmicas.

REFERENCIAS

- [1] Consejo Nacional de Energía. (2019). Política Energética Nacional 2020–2050. Gobierno de El Salvador. <https://www.cne.gob.sv/politica-energetica>
- [2] Won Shin, Jeongyun Han, Wonjong Rhee “AI-Assistance for predictive maintenance of renewable energy systems”. Accedido el 18 de noviembre de 2024. [En línea]. Disponible: <https://www.sciencedirect.com/science/article/pii/S0360544221000244>
- [3] Hazrat, S. F., Khatri, P., Butt, M. A., & Zaman, M. (2018, abril). Review of SCADA systems for photovoltaic power plants. <https://www.ijcrt.org/viewfull.php?&p=IJCRT1892239>
- [4] Shaik, F., Lingala, S. S., & Veeraboina, P. (2023). Effect of various parameters on the performance of solar PV power plant: a review and the experimental study. <https://doi.org/10.1186/s40807-023-00076-x>
- [5] Syamsuddin, A., Adhi, A. C., Kusumawardhani, A., Prahasto, T., & Widodo, A. (2024). “Predictive maintenance based on anomaly detection in photovoltaic system using SCADA data and machine learning”. *Results in Engineering*. <https://doi.org/10.1016/j.rineng.2024.103589>
- [6] Segovia Ramírez, I., Pliego Marugan, A., & García Marquez, F. P. (2022). “A novel approach to optimize the positioning and measurement parameters in photovoltaic aerial inspections”. *Renewable Energy*. <https://doi.org/10.1016/j.renene.2022.01.071>
- [7] Betti, A., Lo Trovato, M. L., Leonardi, F. S., Leotta, G., Ruffini, F., & Lanzetta, C. (2019). *Predictive maintenance in photovoltaic plants with a big data approach* [Preprint]. <https://www.researchgate.net/publication/330751510>
- [8] Abdulla, H., Sleptchenko, A., & Nayfeh, A. (2024). “Photovoltaic systems operation and maintenance: A review and future directions”. *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2024.114342>
- [9] McCarthy, J. (2004). What is artificial intelligence? Stanford University, Formal Reasoning Group. <https://www-formal.stanford.edu/jmc/whatisai.pdf>
- [10] Jiang, Y., Li, X., Luo, H., Yin, S., & Kaynak, O. (2022). Quo vadis, artificial intelligence? Discover Artificial Intelligence. <https://doi.org/10.1007/s44163-022-00022-8>
- [11] Kurukuru, V. S. B., Haque, A., Khan, M. A., Sahoo, S., Malik, A., & Blaabjerg, F. (2021). A Review on Artificial Intelligence Applications for Grid-Connected Solar Photovoltaic Systems. *Energies*. <https://doi.org/10.3390/en14154690>
- [12] Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill. <https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf>

- [13] Autor(es). (2023). Solar Generation Forecasting with Transfer Learning (Tesis de posgrado). Green Research Institute, Universidad Tecnológica de Noruega. Recuperado de <https://ikee.lib.auth.gr/record/349447/files/GRI-2023-40122.pdf>
- [14] Mahesh, B. (2020). Machine Learning Algorithms – A Review. International Journal of Science and Research (IJSR). <https://doi.org/10.21275/ART20203995>
- [15] Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). Foundations of Machine Learning (2ª ed.). The MIT Press. <https://mitpress.mit.edu/9780262039406/foundations-of-machine-learning/>
- [16] Naeem, S., Ali, A., Anam, S., & Ahmed, M. M. (2023). An Unsupervised Machine Learning Algorithms: Comprehensive Review. International Journal of Computing and Digital Systems. https://www.researchgate.net/publication/368983958_An_Unsupervised_Machine_Learning_Algorithms_Comprehensive_Review
- [17] Bishop, C. M. (2006). Pattern recognition and machine learning. Springer. <https://www.microsoft.com/en-us/research/wp-content/uploads/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf>
- [18] Kelleher, J. D. (2019). Deep Learning. The MIT Press. <https://mitpress.mit.edu/9780262537551/deep-learning/>
- [19] Fausett, L. (1994). Fundamentals of neural networks: Architectures, algorithms, and applications. Prentice Hall. [https://dl.matlabyar.com/siavash/Neural%20Network/Book/Fausett%20L.-Fundamentals%20of%20Neural%20Networks_%20Architectures,%20Algorithms,%20and%20Applications%20\(1994\).pdf](https://dl.matlabyar.com/siavash/Neural%20Network/Book/Fausett%20L.-Fundamentals%20of%20Neural%20Networks_%20Architectures,%20Algorithms,%20and%20Applications%20(1994).pdf)
- [20] Vicente-Gabriel, J.; Gil-González, A.-B.; Luis-Reboredo, A.; Chamoso, P.; Corchado, J.M. “LSTM Networks for Overcoming the Challenges Associated with Photovoltaic Module Maintenance in Smart Cities”. *Electronics* 2021, 10, 78. Accedido el 30 de enero de 2025. [En línea]. Disponible: <https://www.mdpi.com/948454>
- [21] Sa'ad, “Developing integrated maintenance strategies for renewable energy sources based on analytical methods and artificial intelligence (AI): comparisons and case study”, Electronic Thesis or Dissertation, Univ. Lorraine, 2023. Accedido el 18 de noviembre de 2024. [En línea]. Disponible: [www.https://hal.univ-lorraine.fr/tel-04513110](https://hal.univ-lorraine.fr/tel-04513110)
- [22] Samir Benammar and Kong Fah Tee, “Criticality Analysis and Maintenance of Solar Tower Plants by Integrating the Artificial Intelligence Approach”, *Energies* 2021, 14(18), 5861. Accedido el 19 de febrero de 2025. [En línea]. Disponible: <https://doi.org/10.3390/en14185861>

[23] FUSADES. (2024). "Mejores prácticas para la regulación de los sistemas de inteligencia artificial (IA) en El Salvador". Serie de Investigación 2024-1. Fundación Salvadoreña para el Desarrollo Económico y Social. Accedido el 18 de noviembre de 2024. [En línea]. Disponible: https://fusades.org/publicaciones/SI_regulacion_IA.pdf

[24] Asamblea Legislativa de El Salvador “Ley de Inteligencia Artificial ayudará a mejorar los servicios públicos e impulsar la economía” *Sala de Prensa, miércoles 26, febrero 2025*. Accedido el 26 de febrero de 2025. [En línea]. Disponible: <https://www.asamblea.gob.sv/node/13492>

[25] Sakib Ashraf Zargar, “Introduction to Sequence Learning Models: RNN, LSTM, GRU”, Department of Mechanical and Aerospace Engineering, North Carolina State University, 2021. Accedido el 2 de marzo de 2025. [En Línea]. Disponible: https://www.researchgate.net/publication/350950396_Introduction_to_Sequence_Learning_Models_RNN_LSTM_GRU

[26] Safwan Mahmood Al-Selwi, Mohd Fadzil Hassan, Said Jadid Abdulkadir, Amgad Muneer, Ebrahim Hamid Sumiea, Alawi Alqushaibi, Mohammed Gamal Ragab, “RNN-LSTM: From applications to modeling techniques and beyond—Systematic review”, *Journal of King Saud University - Computer and Information Sciences*, Volume 36, Issue 5, June 2024. Accedido el 2 de marzo de 2025. [En Línea]. Disponible: <https://doi.org/10.1016/j.jksuci.2024.102068>

[27] Umberto Michelucci, “An Introduction to Autoencoders”, TOELT AILAB Publications, January 2022. Accedido 2 de marzo de 2025. [En Línea]. Disponible: <https://arxiv.org/pdf/2201.03898>

[28] G. Decaix et al., “A smarter way to digitize maintenance and reliability”, McKinsey & Company, Apr. 2021. [En Línea]. Disponible: <https://www.mckinsey.com/capabilities/operations/our-insights/a-smarter-way-to-digitize-maintenance-and-reliability>

[29] “Moving from Reactive to Predictive: How IOT-Enabled Maintenance Drives Efficiency and Cost Savings”, IIOT-World, Feb. 2025. [En Línea]. Disponible: <https://www.iiot-world.com/predictive-analytics/predictive-maintenance/predictive-maintenance-cost-savings/>

[30] Alam, Mahfuz & Islam, Rafiqul. (2023). AI-Based Predictive Maintenance for U.S. Manufacturing: Reducing Downtime and Increasing Productivity. *International Journal of Advanced Engineering Technologies and Innovations*, Volume 01 Issue 01 (2023). [En Línea]. Disponible: <https://ijaeti.com/index.php/Journal/article/view/711?articlesBySimilarityPage=20>

[31] IRENA (2020), Renewable Power Generation Costs in 2019, International Renewable Energy Agency, Abu Dhabi. Accedido el 5 de mayo de 2025. [En Línea]. Disponible:

https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2020/Jun/IRENA_Power_Generation_Costs_2019.pdf