



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería del Diseño

Diseño de un método usando técnicas de inteligencia artificial y machine learning con Matlab para el mantenimiento y diagnóstico de fallos en paneles solares.

Trabajo Fin de Grado

Grado en Ingeniería Electrónica Industrial y Automática

AUTOR/A: Jordán Tomás, Joan

Tutor/a: Quiles Cucarella, Eduardo

CURSO ACADÉMICO: 2022/2023

## RESUMEN

La propuesta actual de Trabajo Final de Grado tiene como objetivo principal investigar y desarrollar una aplicación de técnicas de inteligencia artificial y aprendizaje automático utilizando Matlab en el ámbito del mantenimiento y diagnóstico de fallos en paneles solares. El propósito de este estudio es aprovechar el potencial de estas tecnologías avanzadas para mejorar la eficiencia y confiabilidad de los sistemas solares fotovoltaicos.

En primer lugar, se realiza una revisión exhaustiva de la literatura científica y técnica relacionada con el mantenimiento predictivo de paneles solares y el uso de inteligencia artificial y aprendizaje automático en este campo. Esto permite establecer una base sólida de conocimiento y comprensión sobre las mejores prácticas y las herramientas utilizadas.

Posteriormente, se diseña y desarrolla una aplicación utilizando Matlab que integra algoritmos de inteligencia artificial y aprendizaje automático. Estos algoritmos se aplican al análisis de datos recopilados de los paneles solares mediante sensores, como la intensidad, el voltaje y otros parámetros relevantes. El objetivo es detectar de manera temprana posibles fallos o anomalías en el rendimiento de los paneles solares, lo que permite tomar medidas correctivas de manera oportuna y minimizar los impactos negativos en la producción de energía.

Además, se llevan a cabo pruebas y experimentos utilizando conjuntos de datos reales para evaluar la efectividad y precisión de los algoritmos desarrollados. Esto permite validar la aplicación propuesta y proporcionar resultados cuantitativos que respalden su eficacia. Se evalúan aspectos como la precisión, la velocidad de procesamiento y la complejidad computacional.

En resumen, este trabajo de investigación tiene como objetivo contribuir al avance en el campo del mantenimiento predictivo de paneles solares, permitiendo una detección temprana de problemas y una optimización en la planificación de las tareas de mantenimiento. Se espera que los resultados obtenidos proporcionen información valiosa para la toma de decisiones en la gestión y operación de sistemas solares, contribuyendo así a la promoción de fuentes de energía limpia y sostenible.

## RESUM

El objetivo principal de la presente propuesta de Trabajo Fin de Grado es investigar y desarrollar una aplicación de técnicas de inteligencia artificial y aprendizaje automático utilizando Matlab en el campo del mantenimiento y diagnóstico de fallos en paneles solares. La finalidad de este estudio es aprovechar el potencial de estas tecnologías avanzadas para mejorar la eficiencia y fiabilidad de los sistemas solares fotovoltaicos.

En primer lugar, se realiza una revisión exhaustiva de la literatura científica y técnica relacionada con el mantenimiento predictivo de paneles solares y el uso de la inteligencia artificial y el aprendizaje automático en este campo. Esto permite establecer una base sólida de conocimiento y comprensión de las mejores prácticas y herramientas utilizadas.

Posteriormente, se diseña y desarrolla una aplicación utilizando Matlab que integra algoritmos de inteligencia artificial y aprendizaje automático. Estos algoritmos se aplican al análisis de los datos recogidos de los paneles solares mediante sensores, como la intensidad, el voltaje y otros parámetros relevantes. El objetivo es detectar de forma temprana posibles fallos o anomalías en el rendimiento de los paneles solares, lo que permite tomar medidas correctoras a tiempo y minimizar los impactos negativos en la producción de energía.

Además, se realizan pruebas y experimentos utilizando conjuntos de datos reales para evaluar la eficacia y precisión de los algoritmos desarrollados. Esto permite validar la aplicación propuesta y proporcionar resultados cuantitativos que confirman su eficacia. Se evalúan aspectos como la precisión, la velocidad de procesamiento y la complejidad computacional.

En resumen, el objetivo de este trabajo de investigación es contribuir al avance en el campo del mantenimiento predictivo de paneles solares, permitiendo la detección temprana de problemas y la optimización en la planificación de las tareas de mantenimiento. Se espera que los resultados obtenidos proporcionen información valiosa para la toma de decisiones en la gestión y operación de sistemas solares, contribuyendo así a la promoción de fuentes de energía netas y sostenibles.

## ABSTRACT

The current proposal for the Final Degree Project aims to investigate and develop an application of artificial intelligence and machine learning techniques using MATLAB in the field of maintenance and fault diagnosis in solar panels. The purpose of this study is to leverage the potential of these advanced technologies to improve the efficiency and reliability of photovoltaic solar systems.

Firstly, a comprehensive review of scientific and technical literature related to predictive maintenance of solar panels and the use of artificial intelligence and machine learning in this field is conducted. This allows for the establishment of a solid foundation of knowledge and understanding of best practices and tools used.

Subsequently, an application is designed and developed using MATLAB that integrates artificial intelligence and machine learning algorithms. These algorithms are applied to the analysis of data collected from the solar panels through sensors, such as intensity, voltage, and other relevant parameters. The goal is to detect potential faults or anomalies in the performance of the solar panels at an early stage, enabling timely corrective measures to be taken and minimizing negative impacts on energy production.

Furthermore, tests and experiments are conducted using real datasets to evaluate the effectiveness and accuracy of the developed algorithms. This validates the proposed application and provides quantitative results that support its efficacy. Aspects such as accuracy, processing speed, and computational complexity are evaluated.

In summary, this research aims to contribute to the advancement of predictive maintenance of solar panels, enabling early detection of issues and optimization in the planning of maintenance tasks. It is expected that the obtained results will provide valuable information for decision-making in the management and operation of solar systems, thus contributing to the promotion of clean and sustainable energy sources.

# ÍNDICE

RESUMEN .....	1
RESUM .....	2
ABSTRACT .....	3
ÍNDICE.....	4
TABLA DE ILUSTRACIONES .....	6
ÍNDICE DE TABLAS .....	9
1. INTRODUCCIÓN .....	11
1.1. MOTIVACIÓN DEL PROYECTO .....	11
1.2. OBJETIVOS.....	12
1.3. ESTRUCTURA.....	13
1.4. RELACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE .....	14
2. ENERGÍA SOLAR E INSTALACIONES FOTOVOLTAICAS .....	16
2.1. PRINCIPIOS DE LA ENERGÍA SOLAR.....	17
2.2. CÉLULAS FOTOVOLTAICAS .....	19
2.3. SISTEMAS FOTOVOLTAICOS.....	24
2.3.1. Módulo fotovoltaico .....	24
2.3.2. Reguladores de carga .....	27
2.3.3. Inversores .....	28
2.3.4. Elementos de protección .....	30
2.3.5. Baterías.....	31
3. MÉTODOS DE DETECCIÓN Y DIAGNÓSTICO DE FALLOS EN SISTEMAS FOTOVOLTAICOS.....	34
3.1.1. TIPOS DE FALLOS EN INSTALACIONES FOTOVOLTAICAS.....	35
3.2. DIAGNÓSTICO Y DETECCIÓN DE FALLOS.....	39
3.3. INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING EN EL ANÁLISIS DE DATOS .....	41
4. DISEÑO DEL ALGORITMO .....	44
4.1. MODELO DEL SISTEMA FOTOVOLTAICO .....	44
4.2. ANÁLISIS DE LOS DATOS OBTENIDOS .....	46
4.2.1. Comportamiento normal del sistema.....	46
4.2.2. Fallo completo en uno de los seis IGBT (F1) .....	48
4.2.3. Fallo del sensor monofásico en un 20% (F2) .....	49
4.2.4. Caídas de tensión intermitentes (F3) .....	51
4.2.5. Entre 10% y 20% de sombreado parcial no homogéneo (F4).....	52
4.2.6. Circuito abierto de la matriz fotovoltaica en un 15% (F5).....	53



4.2.7.	Parámetro de ganancia del controlador PI con una reducción del 20% (F6) .....	55
4.2.8.	Parámetro de constante de tiempo del controlador PI con un aumento del 20% (F7) .....	56
5.	ENTRENAMIENTO Y RESULTADOS .....	59
5.1.	VALIDACIÓN DE LOS DATOS.....	60
5.1.1.1.	Árboles de decisión .....	60
5.1.2.	Análisis discriminante .....	65
5.1.3.	Clasificador Naive Bayes .....	67
5.1.4.	Nearest Neighbor Classifier .....	69
5.2.	TEST DE LOS ALGORITMOS .....	74
5.2.1.	Árbol de decisiones (Test).....	74
5.2.2.	Análisis discriminante (Test).....	78
5.2.3.	Clasificador Naives Bayes (Test).....	80
5.2.4.	Nearest Neighbor Classifier (Test).....	82
6.	PRESUPUESTO .....	88
6.1.	COSTOS DE MATERIALES Y SUMINISTROS.....	88
6.2.	RECURSOS HUMANOS .....	89
6.3.	LICENCIAS Y SOFTWARE.....	90
6.4.	OTROS.....	90
6.5.	PRESUPUESTO FINAL.....	91
7.	CONCLUSIONES Y POSIBLES MEJORAS .....	93
7.1.	CONCLUSIONES .....	93
7.2.	FUTURAS MEJORAS .....	95
8.	MANUAL DEL USUARIO.....	97
8.1.	OBTENCIÓN DE LOS DATOS.....	97
8.2.	VISUALIZACIÓN DE LAS SEÑALES .....	100
8.3.	CLASSIFICATION LEARNER .....	103
9.	PLIEGO DE CONDICIONES .....	107
9.1.	OBJETO.....	107
9.2.	CONDICIONES DE LOS MATERIALES.....	107
9.3.	CONTROL DE LA EJECUCIÓN.....	108
9.4.	PRUEBAS DE SERVICIO .....	108
10.	BIBLIOGRAFÍA.....	110
10.1.	BIBLIOGRAFÍA DE ILUSTRACIONES .....	112

## TABLA DE ILUSTRACIONES

<b>Ilustración 1:</b> Primer satélite con paneles solares (Vanguard 1) [31].....	18
<b>Ilustración 2:</b> Funcionamiento de una celda fotovoltaica [32].....	19
<b>Ilustración 3:</b> Panel solar monocristalino [33]. .....	20
<b>Ilustración 4:</b> Panel solar policristalino [33]. .....	21
<b>Ilustración 5:</b> Panel solar de película fina [34].....	22
<b>Ilustración 6:</b> Eficiencias según el tipo de célula [35]. .....	23
<b>Ilustración 7:</b> Punto de máxima potencia en la gráfica V-I [36]. .....	25
<b>Ilustración 8:</b> Área del factor de forma [37]. .....	26
<b>Ilustración 9:</b> Regulador de carga MPPT [38]. .....	27
<b>Ilustración 10:</b> Regulador de carga PWM [39]. .....	28
<b>Ilustración 11:</b> Tipos de onda [40]. .....	29
<b>Ilustración 12:</b> Curva de potencia(I-V) del módulo fotovoltaico en función de la irradiancia [41]. .....	30
<b>Ilustración 13:</b> Curva I-V del módulo fotovoltaico en función de la irradiancia [42]. .....	30
<b>Ilustración 14:</b> Instalación fotovoltaica completa [43]. .....	32
<b>Ilustración 15:</b> Fallo de Hot-Spot en placas solares [44]. .....	36
<b>Ilustración 16:</b> Incendio de un sistema fotovoltaico [45].....	37
<b>Ilustración 17:</b> Ilustración sombreado parcial [46]. .....	38
<b>Ilustración 18:</b> Modelo del sistema fotovoltaico [1]. .....	45
<b>Ilustración 19:</b> Comportamiento normal del sistema fotovoltaico F0M. ....	47
<b>Ilustración 20:</b> Comportamiento normal del sistema fotovoltaico F0L. ....	47
<b>Ilustración 21:</b> Comportamiento del sistema con el fallo 1 (F1M). .....	48
<b>Ilustración 22:</b> Comportamiento del sistema con el fallo 1 (F1L). .....	49
<b>Ilustración 23:</b> Comportamiento del sistema con el fallo 2 (F2M). .....	50
<b>Ilustración 24:</b> Comportamiento del sistema con el fallo 2 (F2L). .....	50
<b>Ilustración 25:</b> Comportamiento del sistema para el fallo 3 (F3M). .....	51
<b>Ilustración 26:</b> Comportamiento del sistema para el fallo 3 (F3L). .....	51
<b>Ilustración 27:</b> Comportamiento del sistema ante sombreado parcial (F4M). .....	52
<b>Ilustración 28:</b> Comportamiento del sistema ante sombreado parcial (F4L). .....	53
<b>Ilustración 29:</b> Comportamiento del sistema ante el fallo 5 (F5M). .....	54
<b>Ilustración 30:</b> Comportamiento del sistema ante el fallo 5 (F5L). .....	54
<b>Ilustración 31:</b> Comportamiento del sistema ante el fallo 6 (F6M). .....	55
<b>Ilustración 32:</b> Comportamiento del sistema ante el fallo 6 (F6L). .....	56

<b>Ilustración 33:</b> Comportamiento normal del sistema ante el fallo 7 (F7M).....	57
<b>Ilustración 34:</b> Comportamiento normal del sistema ante el fallo 7 (F7L).....	57
<b>Ilustración 35:</b> Representación de la “Holdout Validation” [48].....	59
<b>Ilustración 36:</b> Estructura del árbol de decisiones [49].....	60
<b>Ilustración 37:</b> Matriz de confusión del Árbol Fino (MPPT).....	61
<b>Ilustración 38:</b> Matriz de confusión del Árbol Fino (IPPT).....	62
<b>Ilustración 39:</b> Matriz de confusión del Árbol Medio (MPPT).....	62
<b>Ilustración 40:</b> Matriz de confusión del Árbol Medio (IPPT).....	63
<b>Ilustración 41:</b> Matriz de confusión para el Árbol Grueso (MPPT).....	63
<b>Ilustración 42:</b> Matriz de confusión para el Árbol Grueso (IPPT).....	64
<b>Ilustración 43:</b> Matriz de confusión del Árbol de decisión Optimizado (MPPT).....	64
<b>Ilustración 44:</b> Matriz de confusión del Árbol de decisión Optimizado (IPPT).....	65
<b>Ilustración 45:</b> Matriz de confusión para el análisis discriminante lineal (MPPT).....	66
<b>Ilustración 46:</b> Matriz de confusión para el análisis discriminante lineal (IPPT).....	66
<b>Ilustración 47:</b> Matriz de confusión para el análisis discriminante cuadrático (MPPT).....	67
<b>Ilustración 48:</b> Matriz de confusión para el análisis discriminante cuadrático (IPPT).....	67
<b>Ilustración 49:</b> Matriz de confusión para el clasificador “Gaussian Naive Bayes” (MPPT).....	68
<b>Ilustración 50:</b> Matriz de confusión para el clasificador “Gaussian Naive Bayes” (IPPT).....	68
<b>Ilustración 51:</b> Matriz de confusión para Fine KNN (MPPT).....	70
<b>Ilustración 52:</b> Matriz de confusión para Fine KNN (IPPT).....	70
<b>Ilustración 53:</b> Matriz de confusión para Medium KNN (MPPT).....	71
<b>Ilustración 54:</b> Matriz de confusión para Medium KNN (IPPT).....	71
<b>Ilustración 55:</b> Matriz de confusión para Cubic KNN (MPPT).....	72
<b>Ilustración 56:</b> Matriz de confusión para Cubic KNN (IPPT).....	72
<b>Ilustración 57:</b> Matriz de confusión para Weighted KNN (MPPT).....	73
<b>Ilustración 58:</b> Matriz de confusión para Weighted KNN (IPPT).....	73
<b>Ilustración 59:</b> Matriz de confusión para Árbol Fino (MPPT)(Test).....	75
<b>Ilustración 60:</b> Matriz de confusión para Árbol Fino (IPPT)(Test).....	75
<b>Ilustración 61:</b> Matriz de confusión Árbol Medio (MPPT)(Test).....	76
<b>Ilustración 62:</b> Matriz de confusión Árbol Medio (IPPT)(Test).....	76
<b>Ilustración 63:</b> Matriz de confusión Árbol Grueso (MPPT)(Test).....	77
<b>Ilustración 64:</b> Matriz de confusión Árbol Grueso (IPPT)(Test).....	77
<b>Ilustración 65:</b> Matriz de confusión Árbol Optimizado (MPPT)(Test).....	78
<b>Ilustración 66:</b> Matriz de confusión Árbol Optimizado (IPPT)(Test).....	78
<b>Ilustración 67:</b> Matriz de confusión Análisis Discriminante Linear (MPPT)(Test).....	79
<b>Ilustración 68:</b> Matriz de confusión Análisis Discriminante Linear (IPPT)(Test).....	79



<b>Ilustración 69:</b> Matriz de confusión del Análisis Discriminante cuadrático (MPPT)(Test). ..	80
<b>Ilustración 70:</b> Matriz de confusión del Análisis Discriminante cuadrático (IPPT)(Test).....	80
<b>Ilustración 71:</b> Matriz de confusión para “Gaussian Naive Bayes” (MPPT)(Test). .....	81
<b>Ilustración 72:</b> Matriz de confusión para “Gaussian Naive Bayes” (IPPT)(Test).....	81
<b>Ilustración 73:</b> Matriz de confusión Fine KNN (MPPT)(Test).....	82
<b>Ilustración 74:</b> Matriz de confusión Fine KNN (IPPT)(Test).....	83
<b>Ilustración 75:</b> Matriz de confusión Medium KNN (MPPT)(Test). .....	83
<b>Ilustración 76:</b> Matriz de confusión Medium KNN (IPPT)(Test).....	84
<b>Ilustración 77:</b> Matriz de confusión Cubic KNN (MPPT)(Test). .....	84
<b>Ilustración 78:</b> Matriz de confusión Cubic KNN (IPPT)(Test).....	85
<b>Ilustración 79:</b> Matriz de confusión Weighted KNN (MPPT)(Test). .....	85
<b>Ilustración 80:</b> Matriz de confusión Weighted KNN (IPPT)(Test).....	85
<b>Ilustración 81:</b> Apartado de app's. ....	103
<b>Ilustración 82:</b> Introducir los datos en el Classification Learner. ....	103
<b>Ilustración 83:</b> Ventana de nueva sesión “New Season”. ....	104
<b>Ilustración 84:</b> Cómo utilizar la aplicación Classification Learner.....	105

# ÍNDICE DE TABLAS

<b>Tabla 1:</b> Precisión de los árboles de decisión (MPPT).....	60
<b>Tabla 2:</b> Precisión de los árboles de decisión (IPPT).....	61
<b>Tabla 3:</b> Precisión de los análisis discriminantes (MPPT).....	65
<b>Tabla 4:</b> Precisión de los análisis discriminantes (IPPT).....	65
<b>Tabla 5:</b> Precisión de los clasificadores Naives Gaussiano (MPPT).....	68
<b>Tabla 6:</b> Precisión de los clasificadores Naives Gaussiano (IPPT).....	68
<b>Tabla 7:</b> Precisión de las técnicas de KNN (MPPT).....	69
<b>Tabla 8:</b> Precisión de las técnicas de KNN (IPPT).....	69
<b>Tabla 9:</b> Precisión de los árboles de decisión (MPPT)(Test).....	74
<b>Tabla 10:</b> Precisión de los árboles de decisión (IPPT)(Test).....	74
<b>Tabla 11:</b> Precisión de análisis discriminante (MPPT)(Test).....	79
<b>Tabla 12:</b> Precisión de análisis discriminante (IPPT)(Test).....	79
<b>Tabla 13:</b> Precisión de los clasificadores Naives Bayes (MPPT)(Test).....	81
<b>Tabla 14:</b> Precisión de los clasificadores Naives Bayes (IPPT)(Test).....	81
<b>Tabla 15:</b> Precisión de los clasificadores KNN (MPPT)(Test).....	82
<b>Tabla 16:</b> Precisión de los clasificadores KNN (IPPT)(Test).....	82
<b>Tabla 17:</b> Presupuesto de recursos materiales.....	88
<b>Tabla 18:</b> Presupuesto de recursos humanos.....	89
<b>Tabla 19:</b> Presupuesto de licencias y software.....	90
<b>Tabla 20:</b> Presupuesto de gastos varios.....	90
<b>Tabla 21:</b> Presupuesto total del proyecto.....	91



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

# 1. INTRODUCCIÓN

En primer lugar, vamos a hablar sobre la motivación por la cual hemos decidido hacer un trabajo sobre este tema. Esta motivación viene dada por distintos factores, ya sea por la posibilidad de mercado y de estudio, tanto como por las preferencias personales. Después desarrollaremos un poco cuáles van a ser los objetivos de este proyecto, así pues, tendremos una meta a la que debemos acercarnos. Por último, explicaremos la estructura que va a seguir este documento, así pues, pondremos en contexto al lector.

## 1.1. MOTIVACIÓN DEL PROYECTO

Uno de los motivos por el cual se ha decidido realizar este proyecto es diseñar un algoritmo basado en “Machine Learning” que permite aumentar la eficiencia, la rentabilidad y la confiabilidad de las instalaciones fotovoltaicas. Al mejorar en la temprana detección de los datos anómalos que extraemos del sistema fotovoltaico, podemos hacer una reparación que evite que estos aparatos (bastante costosos y con una esperanza de vida de 20 años) se dañen de forma permanente y reduzcan su eficiencia o incluso ocurran incendios.

Como podemos observar, aquí se halla un gran mercado adaptándose a las características de cada usuario para otorgarle un algoritmo que le reduzca los costes de mantenimiento y alargue la vida útil de su instalación.

Por otro lado, es importante destacar que este proyecto también hace dar un salto a las energías renovables, las cuales van a ser cruciales en las próximas décadas debido a la necesidad de reducir nuestra huella de carbono. Este algoritmo es capaz de dar una seguridad mayor al usuario, y hace que se desechen menos paneles solares, reduciendo tanto la basura electrónica como la abusiva compra de estos y, por otro lado, aumenta tanto el rendimiento como la generación de esta energía. Es más, este método puede ser trasladado a otro tipo de energía renovable, con su correspondiente estudio y diseño, haciendo así que este método pueda englobar muchas ramas del mantenimiento.

Otra motivación es también la mejora del mantenimiento en la ingeniería, el cual es un gran olvidado, pero es capaz de mejorar tanto la eficiencia como la seguridad de cualquier ámbito de la industria. Este también reduce la generación de basura electrónica, la cual es un problema bastante importante en nuestra sociedad.

## 1.2. OBJETIVOS

Este apartado tiene como propósito explicar los objetivos del proyecto, estos van a ser la base fundamental del proyecto y nos van a guiar hacia dónde queremos enfocar el proyecto. A continuación, vamos a detallar varios objetivos del proyecto:

1. Investigar y comprender el campo del mantenimiento y diagnóstico de fallos en paneles solares, así como el uso de técnicas de inteligencia artificial y machine learning en este ámbito.
2. Diseñar un algoritmo de inteligencia artificial y machine learning utilizando Matlab para el análisis de datos de paneles solares, con el objetivo de detectar y diagnosticar diferentes tipos de fallos.
3. Seleccionar y preprocesar las variables relevantes de la base de datos proporcionada, como corriente de salida, tensión de salida, tensión DC, corriente trifásica, frecuencia de la tensión y corriente y tensión trifásica.
4. Entrenar y evaluar modelos de inteligencia artificial y machine learning, alimentándolos mediante una los datos seleccionados anteriormente y utilizando varios métodos y técnica de machine learning para comparar cuál es el que detecta y diagnostica los fallos.
5. Analizar y discutir los resultados obtenidos, destacando la efectividad del algoritmo en la detección y diagnóstico de fallos en paneles solares.
6. Concluir los logros y contribuciones del proyecto, así como sus limitaciones, y proporcionar recomendaciones para su aplicación en el campo del mantenimiento predictivo de paneles solares.

Todos estos objetivos van a intentar ser resueltos de la mejor manera posible con los recursos y tiempo que se tiene para la realización del trabajo de fin de grado.

### 1.3. ESTRUCTURA

El proyecto se divide en varias etapas que se describen a continuación. En primer lugar, nos encontramos con la sección de fundamentos teóricos que aborda los conceptos clave relacionados con la energía y los paneles solares, así como, cuál fue el inicio del aprovechamiento de la energía solar, cuál es la técnica utilizada para extraer energía y de que están compuestos los sistemas fotovoltaicos.

Seguidamente, nos enfocamos los métodos de detección y diagnósticos de fallos donde empezaremos viendo el tipo de fallos que puede tener una instalación fotovoltaica en general, seguidamente hablaremos sobre los métodos de diagnóstico y detección de fallos que se puede emplear e introduciremos el papel de la inteligencia artificial en el campo del mantenimiento predictivo.

Una vez ya hemos hecho una introducción teórica al tema, ya podemos empezar a explicar el proceso de diseño que hemos llevado hasta obtener el algoritmo completo. En primer lugar, explicaremos el sistema fotovoltaico del que hemos extraído todos los datos para el entrenamiento del algoritmo. En segundo lugar, haremos un análisis de los datos obtenidos analizando fallo por fallo, como varían su comportamiento eléctrico del comportamiento normal.

El siguiente paso es entrenar los modelos y analizar cómo se ha comportado cada modelo, para así posteriormente ver cómo actúan en la parte de Test. Una vez simulados todos los modelos pasamos a la parte de presupuesto del proyecto, donde incluiremos todos los gastos habidos para el desarrollo de estos algoritmos.

En último lugar, haremos una conclusión global sobre todos los modelos entrenados y sobre todo el proyecto en general para posteriormente explicar futuras mejoras y aplicaciones de este proyecto. No obstante, antes de acabar el proyecto dejaremos un manual de instrucciones para poder recrear este proyecto y una bibliografía para poder indagar aún más en el tema.

## 1.4. RELACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE

Los objetivos de desarrollo sostenible (ODS) son una serie de 17 objetivos propuestos por los países miembros de las Naciones Unidas en 2015 para la agenda del 2030. Estos objetivos recogen una amplia colección de cosas que mejorar en los estados. A continuación, mostraremos los que más se relacionan con nuestro proyecto:

- **ODS 7. Energía asequible y no contaminante:** El algoritmo desarrollado en este proyecto hace que el rendimiento de la energía solar sea mayor, por lo que el precio de la energía se abarata y se vuelve más asequible. Por otro lado, la detección temprana de los fallos puede evitar incendios que produzcan contaminación y eliminan gran parte de basura electrónica al prevenir el fallo.
- **ODS 9. Industria, innovación e infraestructura:** La aplicación del algoritmo a los paneles solares es un campo de innovación, ya que es bastante reciente, además podemos hablar de infraestructura, puesto que es una fuente de energía que puede utilizarse en cualquier infraestructura de cualquier industria.
- **ODS 11. Ciudades y comunidades sostenibles:** Este proyecto hace una gran apuesta por las energías renovables como la energía solar, la cual, bien implementada en las ciudades, puede hacer estas autosostenibles y con una baja producción de efectos invernadero.
- **ODS 13. Acción por el clima:** Gracias al aumento de rendimiento y de vida útil de las placas, podemos decir que esta tecnología es un gran avance contra la acción por el clima, ya que reduce tanto gases de efecto invernadero como basura electrónica.

Cabe destacar que estos son los objetivos que más relacionados están con el proyecto, no obstante, puede haber otros incluidos dependiendo del enfoque que le queramos dar al proyecto



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny



## 2. ENERGÍA SOLAR E INSTALACIONES FOTOVOLTAICAS

La energía solar es una forma de energía renovable que se obtiene de la radiación solar. Una de las formas de aprovechar esta energía son los sistemas fotovoltaicos [1], que convierten la radiación solar en electricidad.

Los sistemas fotovoltaicos constan de paneles solares, que están formados por células solares. Estas células solares están hechas de silicio y tienen la capacidad de convertir la energía solar en energía eléctrica. Los paneles solares se conectan entre sí para formar un conjunto solar y se instalan en un lugar donde reciban la mayor radiación solar posible.

Además de los paneles solares, una instalación fotovoltaica también incluye un inversor, que convierte la energía eléctrica generada por los paneles solares en una forma de energía que puede utilizarse en los hogares o en la red eléctrica.

Las instalaciones fotovoltaicas tienen muchas ventajas, ya que son una fuente de energía renovable y limpia, no emiten gases de efecto invernadero y requieren poco mantenimiento. Además, a medida que avanza la tecnología solar, se desarrollan nuevos materiales y dispositivos adicionales para aumentar la eficiencia y la capacidad de generación de energía de los paneles solares.

Sin embargo, aunque la energía solar tiene muchas ventajas, también presenta algunas limitaciones. Una de ellas es la necesidad de una gran superficie de paneles solares para generar una cantidad significativa de energía, lo que puede suponer un reto en zonas con espacio limitado. Además, el coste inicial de la instalación puede ser elevado, aunque a largo plazo se espera que los costes disminuyan a medida que mejore la tecnología y se optimice la fabricación de paneles solares.


Para seguir avanzando en el campo de la energía solar, se está investigando intensamente en materiales que mejoren la eficiencia y la durabilidad de los paneles solares. También se están explorando nuevas ideas y enfoques para maximizar el rendimiento de las instalaciones fotovoltaicas, como el uso de sistemas de seguimiento solar y almacenamiento de energía. Además, se están aplicando soluciones de mantenimiento inteligente para optimizar el funcionamiento de las instalaciones y reducir los costes de mantenimiento a largo plazo. Con estas continuas mejoras, se espera que la energía solar desempeñe un papel cada vez más importante en el suministro sostenible de energía en todo el mundo.

## 2.1. PRINCIPIOS DE LA ENERGÍA SOLAR

Históricamente, siempre se ha intentado aprovechar la energía solar [2] debido a que es la mayor fuente de energía que tiene la tierra, ya que, el sol irradia una energía de  $3,87 \times 10^{1026}$  J/s, y a la tierra nos llega una energía de  $4,03 \times 10^{24}$  J/año (6720 veces de la necesidad energética mundial). El uso esta energía se remonta a la época de los griegos y los romanos, cuando, utilizando lentes, hacían converger todos los rayos en un mismo punto para producir fuego. Pero no fue hasta 1839, cuando el físico francés Alexandre Edmond Becquerel descubrió el efecto fotovoltaico. Cuando el físico francés empezó a darse cuenta de que, si la luz incidía sobre ciertos materiales, estos creaban una diferencia de potencial. A esto se le llamó efecto fotovoltaico. Hacía el 1870 el profesor W. Grylls Adams y su estudiante R. Evans Day, comenzaron a estudiar cómo extraer energía a través de este efecto. Y fue en el año 1885 cuando Charles Fritts logró crear el primer módulo fotoeléctrico, este constaba de un manto de selenio sobre una capa de un material metálico y recubriéndola de una capa muy fina y transparente de oro [3].

En el año 1941 R.S. Olh descubrió la primera célula fotovoltaica de silicio, pero no fue hasta una década más tarde que empezó la fabricación de estas. Darryl Chapin, en febrero de 1953, empezó a investigar con el silicio, logrando una eficiencia del 2,3% y una eficiencia teórica de un 23%. Aunque finalmente tan solo llego a lograr un 6%. A finales de abril de ese mismo año, Bell Laboratories presentaron la Batería Solar Bell, la cual pudo hacer girar una mini noria ganándose a la prensa y generando  $60 \text{ W/m}^2$ . A partir de aquí empezó a utilizarse más esta tecnología, la primera gran aplicación fue para alimentar las líneas telefónicas en zonas rurales de Georgia.

La energía solar tuvo una gran revolución en el 1955 con la entrada de esta en el sector aeroespacial. Gracias a la carrera espacial, los paneles solares empezaron a tener mayor importancia. Esta tecnología encajaba perfectamente en este ámbito, ya que es un sistema autónomo e infinito de extracción de energía si el panel solar no tiene ninguna degradación, esto hacía que el satélite enviara información durante siete años, mientras que las baterías químicas solo duraban 6 meses. El primer panel solar se utilizó en el satélite Vanguard1 [4] (1958), el más antiguo en órbita en la actualidad. A continuación, en la figura 3, podemos ver cómo estaban situadas las placas en este satélite.



*Il·lustració 1: Primer satèl·lite con paneles solares (Vanguard 1) [31].*


A raíz de este satélite, las placas solares empezaron a utilizarse en casi todas las misiones espaciales, desde misiones a Marte hasta misiones orbitales a cometas. Sin embargo, esta tecnología no es perfecta, ya que con solo una capa de polvo las placas dejarían de extraer energía correctamente y ya no servirían para nada.

Por otro lado, las aplicaciones terrestres eran mucho menores, esto se debe a que en las misiones aeroespaciales el coste de producción no importa, a diferencia de las aplicaciones terrestres donde se busca la mayor eficiencia a pesar del precio. La primera instalación comercial se realizó en 1966 en el faro de la isla de Ogami (Japón), sustituyendo la energía solar por gas.

Solar Power Corporation empezó a investigar en las placas de silicio para reducir su coste y poder implementarlas en aplicaciones terrestres. Esta compañía se dio cuenta de que en vez de utilizar silicio cristalino puro se podía utilizar el silicio de rechazo del sector de los semiconductores, logrando un coste de fabricación de 10\$/W. Las primeras ventas masivas fueron hacia sectores como telefonía, radio o televisión.

## 2.2. CÉLULAS FOTOVOLTAICAS

El efecto fotovoltaico, cuyo término proviene del griego "φως" que significa "luz" y "-voltaico" que proviene del campo de la electricidad en honor a Alejandro Volta. Fue descubierto por Albert Einstein en 1920 y por el que recibió un Premio Nobel, se produce cuando los electrones absorben cuantos de energía luminosa (fotones) linealmente proporcionales a la frecuencia de la fuente de luz, esta energía tiene que ser. La extracción de energía mediante el efecto fotovoltaico consiste en exponer un semiconductor dopado [5] a una radiación electromagnética de forma que el fotón incidente incide sobre el electrón y lo desplaza de su posición creando un hueco en las envolturas orbitales del átomo. Como podemos ver en la siguiente figura, este efecto se puede aprovechar creando una célula fotovoltaica, que no es otra cosa que diseñar el material dopado para que los fotones avancen en una posición y siempre haya un hueco por el que circule la corriente, y así crear una diferencia de potencial.




*Ilustración 2: Funcionamiento de una celda fotovoltaica [32].*

Para realizar esta generación de energía, estas células construidas por semiconductores se les induce un campo eléctrico mediante la unión 'p-n' [6]. Hoy en día el material más utilizado es el

silicio (en torno a un 90%) debido a su abundancia en la tierra, su amplio conocimiento y su costo de explotación.

Las células de silicio cristalino son las más utilizadas hoy en día, en torno a un 87,4%. Este tipo de células incluyen las monocristalinas y las policristalinas. Las células monocristalinas son las más utilizadas en el mercado para instalaciones en tejados debido a su color negro plano (ilustración 3). El nombre de esta tecnología viene dado por su forma de fabricación, en este caso la placa está formada por un solo cristal, esto se consigue mediante un proceso de fusión a alta temperatura del silicio al que se le incorpora un cristal "semilla" [7]. Luego se extrae la "semilla", y se forma un gran cristal o lingote, inmediatamente después se forman las celdas mediante un laminado de silicio, obteniendo una mayor pureza y un mayor rendimiento, ya que los electrones pueden moverse con mayor libertad.




*Ilustración 3: Panel solar monocristalino [33].*

Normalmente, estas placas están formadas por 60 células colocadas en 6 filas de 10, con una producción de 340W-400W, lo que significa que tienen unas dimensiones de 164cm x 99cm. Sin embargo, también podemos encontrar paneles monocristalinos de 72 células.

Debido a la mayor complejidad de fabricación, estas células son más caras, pero no necesariamente peores, ya que obtienen un mayor rendimiento. El rendimiento [8] de los paneles monocristalinos oscila entre el 17% y el 23%, por lo que es ideal para las personas que quieren poner más energía solar en un espacio limitado.

Por otro lado, encontramos el material policristalino. Los paneles policristalinos se utilizan en los casos en que el presupuesto es más limitado. En este tipo de células la fabricación comienza como el anterior (añadiendo una semilla al silicio fundido), pero en este caso no se extrae la "semilla", y se deja enfriar todo, formándose así varios cristales, lo que le da su característico color azulado (ilustración 4).



*Ilustración 4: Panel solar policristalino [33].*

Debido a sus múltiples cristales, este tipo de células hace que los fotones no fluyan con tanta facilidad, lo que provoca un menor rendimiento que oscila entre el 15% y el 17%. La producción de un panel de 60 células puede alcanzar los 300W.

Otro factor a favor de este tipo de panel es la temperatura, ya que las placas policristalinas alcanzan temperaturas más bajas y mantienen su rendimiento menos reducido.

Este tipo de panel comenzó a popularizarse bastante entre las personas que tenían más terreno, pero menos presupuesto entre 2012 y 2016. Sin embargo, aunque su coste es menor, los paneles monocristalinos son más comunes.

Además, existen más formas de fabricación de las placas solares como las de cristal de película delgada. Estos tipos de paneles son totalmente diferentes de los anteriores. Son negros y sin contornos (ilustración 5). En general, estos paneles solares son ligeros y flexibles, lo que mejora mucho el proceso de instalación. El mayor uso de este tipo de tecnología es en instalaciones industriales o servicios públicos. Esto se debe a sus menores índices de eficiencia, que requieren disponer de más espacios. También se utilizan en barcos o en tiendas de campaña por su facilidad de instalación.

La forma de fabricación también es totalmente diferente. En este caso, su fabricación consiste en depositar material fotovoltaico, como silicio amorfo (a-Si), telurio de cadmio (CdTe) sobre una superficie sólida como vidrio o cobre, indio, seleniuro de galio (CIGS). Estas sustancias se sensibilizan con colorante (DSC). Cada una de estas sustancias crea un tipo de panel solar, pero todos acaban siendo de capa fina, ya que son ligeros y a veces flexibles.



*Il·lustració 5: Panel solar de pel·lícula fina [34].*


Por otro lado, las placas solares también se pueden clasificar por el tipo y forma de sus células.

En cuanto al tipo de células, tenemos, además de las utilizadas en las placas convencionales, las células partidas, que no es más que dividir las células en trozos más pequeños, lo que nos proporciona ciertas ventajas como: mejor eficiencia, mejor respuesta a altas temperaturas y mayor resistencia a las micro fisuras, con una vida útil más larga.

Otro tipo de células son las PERC [10], es un tipo de tecnología que se aplica en la cara posterior del silicio para reflejar los electrones de la parte trasera a la delantera donde se produce el efecto fotoeléctrico, obteniendo así una alta eficiencia. Ambos tipos de células tienen un precio muy razonable.

Por último, también existen células de tipo P (dopadas con boro), de tipo N (dopadas con fósforo), células de contacto posterior (IBC) y células de hetero unión.

Cada una de ellas tiene un tipo de característica. Podemos ver todos los tipos y su rendimiento a lo largo de toda la trayectoria en la figura 7.



Il·lustració 6: Eficiències segons el tipus de cèl·lula [35].



## 2.3. SISTEMAS FOTOVOLTAICOS

Para un correcto funcionamiento y control de los sistemas fotovoltaicos es necesario implementar varios dispositivos adicionales. Los cuales son módulos fotovoltaicos, reguladores, inversores, elementos de protección y baterías. Todo ello es lo que conforma una instalación fotovoltaica, no obstante, hay instalaciones en las cuales no son necesarios todos los elementos.

### 2.3.1. Módulo fotovoltaico

La unión de las células fotovoltaicas tanto en serie como en paralelo es lo que forma el módulo fotovoltaico, ya que una célula por sí sola solo puede generar entre 1W y 3W. Al asociar estas células en serie lo que haremos es incrementar el voltaje, mientras que cuando las asociamos en paralelo aumentaremos la intensidad. Con lo que los parámetros de intensidad y voltaje vendrán definidos por:

$$V_{ca \text{ módulo}} = V_{ca \text{ célula}} * N_p \quad I_{cc \text{ módulo}} = I_{cc \text{ célula}} * N_s$$


Una vez asociadas todas las células, estas se encapsulan con materiales protectores de agentes externos como aire, polvo, agua, etc. Estos materiales otorgan rigidez y seguridad a la placa, también permite que se pueda unir una estructura para que esta quede fijada al suelo en el ángulo y dirección deseados.

Para poder extraer el máximo rendimiento de un módulo fotovoltaico debemos observar los parámetros característicos de este. Estos parámetros normalmente vienen fijados en las hojas de características del fabricante.

- **Punto de máxima potencia (MPP) [9]:** El punto de máxima potencia o ‘Maximum Power Point’ es el punto de trabajo en el cual la potencia entregada a la carga es máxima. Esta potencia viene definida por la siguiente ecuación:

$$P_{MPP} = V_{MPP} * I_{MPP}$$

En la siguiente gráfica podemos observar en la curva de V-I cuál es el punto de máxima potencia.



Il·lustració 7: Punt de màxima potència en la gràfica V-I [36].

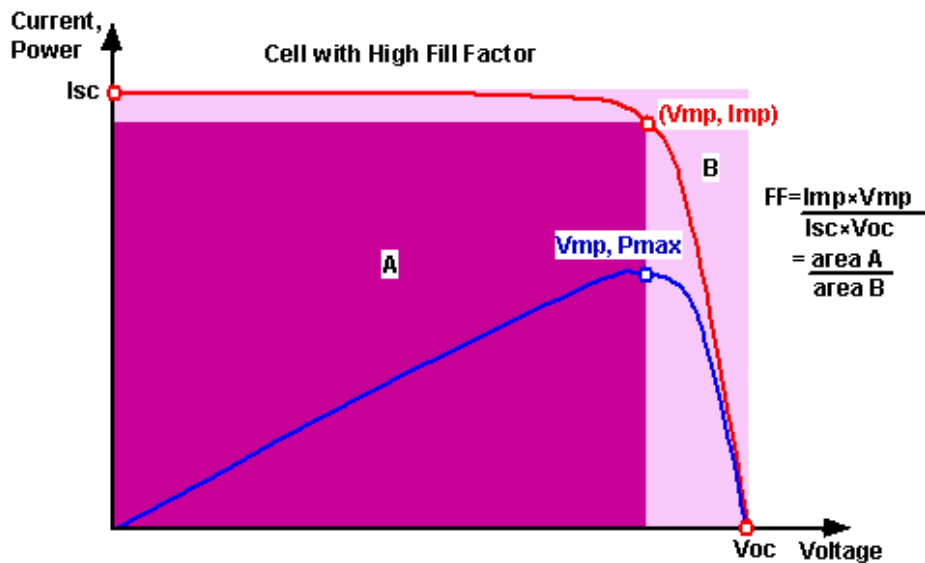
- **Tensió de circuit obert ( $V_{ca}$ ):** Es la màxima tensió que puede entregar el panel solar cuando está en circuito abierto, es decir, sin ninguna carga conectada y sin sus bornes conectados ( $I=0$ ).
- **Corriente de cortocircuito ( $I_{cc}$ ):** Es la máxima intensidad que puede entregar el panel cuando este está en cortocircuito, es decir, sin carga y con sus bordes conectados ( $V=0$ ).
- **Rendimiento ( $\eta$ ):** Coeficiente entre la potencia máxima del módulo solar y potencia de la irradiancia incidente.

$$\eta = \frac{P_{m\acute{a}x}}{P_{irradiancia}}$$

- **Factor de forma (FF):** Es el coeficiente entre la potencia real medida en el momento y la potencia máxima teórica.

$$FF = \frac{P_{real}}{P_{m\acute{a}x\ te\acute{o}rica}}$$

También podemos observar que el factor de forma es el área comprendida en el punto máxima potencia, como se puede observar en la ilustración 8.



Il·lustració 8: Àrea del factor de forma [37].

Todos estos datos nos lo facilitan el fabricante en las condiciones de test estándar.

- **Standard Test Condition (STC):** Estos son los parámetros estándar que se utilizan para medir los parámetros básicos.
  - 1) Irradiancia: 1000 W/m<sup>2</sup>
  - 2) Masa de aire (AM): 1,5
  - 3) Temperatura: 25°C
- **Normal Operation Cell Temperature (NOCT):** Temperatura que alcanza la célula cuando el módulo se somete a las siguientes condiciones:
  - 1) Irradiancia: 800W/m<sup>2</sup>
  - 2) Masa de aire (AM): 1,5
  - 3) Temperatura: 20°C
  - 4) Velocidad del viento: 1m/s

El NOCT tiene parámetros más ajustados a l realidad y este nos permite saber a qué temperatura está en cada momento el panel solar mediante la fórmula:

$$T_c = T_{amb} + \frac{NOCT - 20^{\circ}C}{800 \frac{W}{m^2}} * G$$

Donde:

T<sub>c</sub>: Temperatura de la célula.

T<sub>amb</sub>: Temperatura ambiente.

NOCT: Normal Operation Cell Temperature.

G: Irradiancia.

### 2.3.2. Reguladores de carga

Este dispositivo es necesario a la hora de unir los paneles solares con las baterías [10]. Estos ayudan a evitar situaciones de sobrecarga, con la misión de garantizar una carga suficiente y en la situación de sobre descarga para evitar una descarga excesiva de las baterías, con el fin de evitar una rápida degradación de esta.

Los reguladores PWM y MPPT son los dos tipos de reguladores más utilizados.

- **Regulador MPPT (Maximum Power Point Tracking):** Está compuesto por un diodo de protección, un convertidor de tensión CC-CC y un seguidor de máxima potencia. Permitiendo que las baterías no se dañen, ya que la tensión de salida de las placas fotovoltaicas es mayor que la de entrada de las baterías, esto se debe a que a mayor tensión y menor intensidad tengan las placas, más pequeñas son las pérdidas de estas. Por otra parte, el seguidor de máxima adapta la tensión de funcionamiento del campo fotovoltaico para proporcionar la máxima potencia. A pesar de este ajuste de tensiones, la potencia de entrada y salida de los reguladores es siempre la misma, por lo tanto, esto requiere un aumento de intensidad.



*Ilustración 9: Regulador de carga MPPT [38].*

- **Regulador PWM:** Este regulador, a diferencia del anterior, no busca el punto de máxima carga, sino que está diseñado para dañar lo mínimo posible a las baterías [11]. Este utiliza la modulación de ancho de pulso para igualar la tensión de la instalación fotovoltaica a la tensión de carga de las baterías, y también controla cuando la batería está cargada para evitarle sobrecargas.

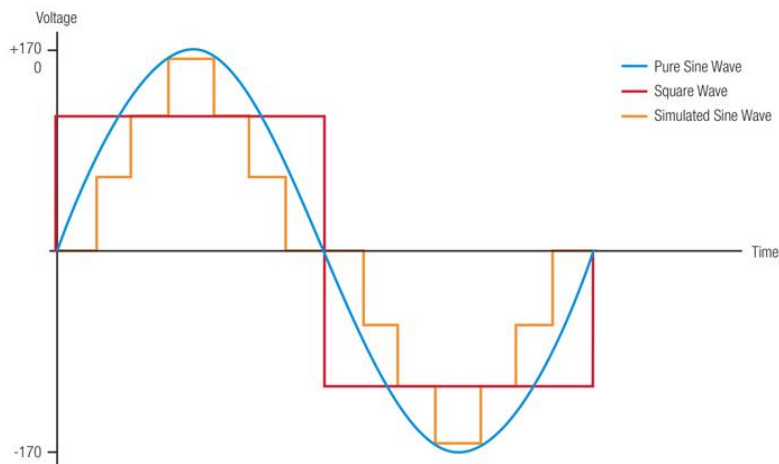


*Il·lustració 10: Regulador de carga PWM [39].*

### 2.3.3. Inversores

Para la conexión a la red, es necesario utilizar inversores [12], ya que la red en la mayoría de los países europeos funciona con una tensión alterna de 230 V a 50 Hz. Para ello se pueden utilizar distintos tipos de inversores. Se clasifican según su forma de onda:

- **Onda cuadrada:** Estos inversores son los más económicos y se denominan así porque la onda generada es un modelo de onda sinusoidal, como en la figura 9. Sin embargo, su rendimiento se sitúa en torno al 50-60%, ya que tienen una distorsión armónica total (THD) bastante alta, en torno al 40%, la potencia de sobrecarga también es baja, en torno al 15%.
- **Onda semi sinusoidal:** Son las más utilizadas en zonas rurales para la electrificación de electrodomésticos, por el hecho de que solo tienen un 20% de THD y tienen un porcentaje superior al 90%.
- **Sinusoidal:** Son la mejor opción para cualquier tipo de aplicación, ya que no presenta THD. Los inversores sinusoidales empiezan a ser los más utilizados gracias a las grandes prestaciones que presentan. Además, algún tipo de electrodoméstico o algunas cargas inductivas como motores requieren este tipo de inversor.

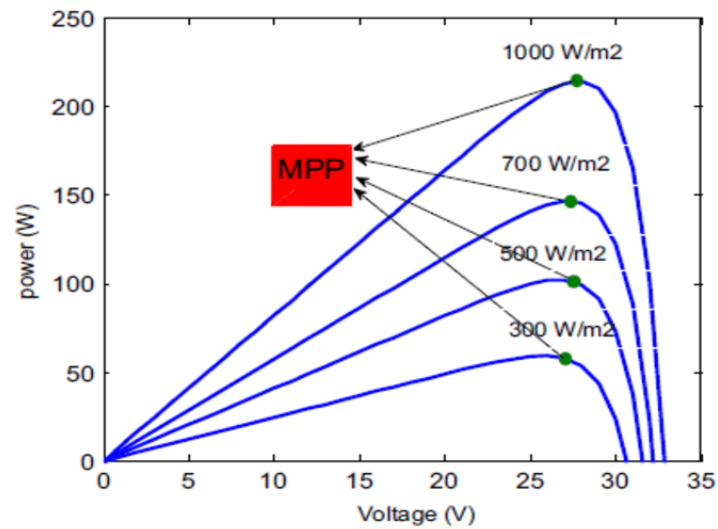


**Il·lustració 11:** Tipos de onda [40].


La potencia que se puede extraer de un generador fotovoltaico depende de la curva I-V. Para obtener una potencia máxima hay que tener en cuenta los diferentes factores que actúan sobre estas instalaciones como la irradiancia, la temperatura o las condiciones ambientales. Por ello, para conseguirlo es necesario un algoritmo de seguimiento del punto de máxima potencia. Este se puede definir como el rendimiento en el punto de máxima potencia  $\eta_{\text{MTTP}}$ , que es el cociente entre la potencia obtenida  $P_r$  y la potencia obtenida idealmente  $P_m$ .

$$\eta_{\text{MTTP}} = \frac{\int_0^t P_r dt}{\int_0^t P_m dt}$$

Para trabajar en el punto de máxima potencia hay que controlar la tensión de funcionamiento del generador, para ello los algoritmos más utilizados son el de perturbación y el de medida, que modifican el incremento de la tensión de funcionamiento y miden el incremento de potencia. Si el incremento medido es positivo, el incremento sigue aumentando y viceversa. Además, hay que tener en cuenta los niveles de irradiancia porque alteran bruscamente las curvas tensión/potencia, y pueden arruinar el cálculo de la potencia máxima.



*Ilustración 12:* Curva de potencia(I-V) del módulo fotovoltaico en función de la irradiancia [41].



*Ilustración 13:* Curva I-V del módulo fotovoltaico en función de la irradiancia [42].

### 2.3.4. Elementos de protección

Para los elementos de protección y cableado hay que tener en cuenta que la instalación consta de dos fases, una de corriente continua y otra de corriente alterna. Para el tramo de CC deberemos utilizar un cable correctamente diseñado y dimensionado para cumplir todas las normas vigentes. En segundo lugar, para el cableado de CA deberemos utilizar un cableado de baja tensión que cumplan los requisitos tanto de la seguridad de uso de la energía eléctrica como la seguridad de las personas.

Por otro lado, en la instalación fotovoltaica más elementos de seguridad son utilizados, como, por ejemplo:

- Varistores que protegen de descargas atmosféricas.
- Conductores de CC capaces de soportar una intensidad del orden de 125% de la intensidad de cortocircuito. Adicionalmente, a estos conductores se les añade unos fusibles de protección.
- En la entrada de los inversores también se instalan unos fusibles de protección.
- Los inversores contarán con un aislamiento galvánico para evitar el paso de corriente continua a la zona de corriente alterna. Aparte estos tienen distintas protecciones frente a cortocircuitos, frecuencia de red no acorde, polaridad invertida o contra tensiones.
- Todo el sistema fotovoltaico estará debidamente protegido con una toma a tierra bien diseñada y sin afectar a zonas de paso de humanos.
- Por último, para prevenir al sistema de hot-spots debidos a sombreados parciales u otras razones, las placas incorporan diodos de by-pass que se activan para desactivar parcial o totalmente la placa.

### 2.3.5. Baterías

Las baterías químicas o acumuladores [13] son dispositivos que convierten energía eléctrica en energía química y la almacenan para posteriormente volver a ser transformada y utilizada en forma de energía eléctrica. Para poder utilizar baterías en un sistema fotovoltaico debemos incluir los reguladores de carga explicados anteriormente.

Además, las baterías tienen tres misiones dentro de la instalación fotovoltaica.


- 1) Almacenar energía eléctrica durante un tiempo.
- 2) Proporcionar una potencia instantánea elevada.
- 3) Fijar la tensión de trabajo que tendrá la instalación fotovoltaica.

Estos dispositivos tienen varios parámetros para que su elección dentro del sistema sea la mejor, estos vienen dados por el fabricante.

- **Eficiencia de carga:** Este parámetro indica la relación entre la energía que utilizamos para cargar la batería y la almacenada realmente.
- **Autodescarga:** Tiempo de descarga de la batería sin ser utilizada.
- **Profundidad de descarga:** Es la cantidad de energía que se obtiene de la batería totalmente cargada durante la descarga. Este parámetro nos puede dar información sobre su vida útil y duración del acumulador.



Por lo tanto, con lo ya explicado el sistema fotovoltaico completo quedaría como se muestra en la ilustración 14.



**Ilustración 14:** Instalación fotovoltaica completa [43].



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

### **3. MÉTODOS DE DETECCIÓN Y DIAGNÓSTICO DE FALLOS EN SISTEMAS FOTOVOLTAICOS.**

Los sistemas fotovoltaicos, como cualquier sistema técnico, pueden experimentar fallos que afectan a su rendimiento y capacidad de generar energía. En esta sección, nos sumergiremos en los métodos y técnicas utilizados para diagnosticar y prevenir fallos en los paneles solares.

Antes de sumergirnos en los métodos de detección y diagnóstico de fallos, es importante familiarizarse con los tipos de fallos más comunes que pueden producirse en las instalaciones fotovoltaicas y determinar en cuáles debemos centrarnos. Además, debemos tener en cuenta el tipo de inspección que vamos a realizar en nuestra instalación.

Detectar y diagnosticar fallos en los sistemas fotovoltaicos es fundamental para garantizar un funcionamiento óptimo y maximizar la generación de energía. Algunos de los fallos más comunes son la degradación de las células solares, acumulación de suciedad o polvo en los paneles, obstrucción de la radiación solar por sombreado parcial, problemas en el sistema de cableado, mal funcionamiento de los inversores, entre otros.

En cuanto a las inspecciones, se pueden llevar a cabo desde diferentes enfoques, como inspecciones visuales para detectar daños físicos en los paneles o en el sistema de montaje, inspecciones termográficas para identificar puntos calientes o desequilibrios en la generación de energía, y análisis de datos para supervisar el rendimiento del sistema a lo largo del tiempo.

En el campo de la detección y el diagnóstico de fallos, se han desarrollado diversas técnicas y herramientas, como el análisis de curvas características, el análisis espectral, el análisis de imágenes, los algoritmos de inteligencia artificial y el aprendizaje automático, entre otros. Estas técnicas permiten identificar y localizar posibles fallos, evaluar su impacto en el rendimiento del sistema y adoptar medidas correctoras a tiempo.

### 3.1.1. TIPOS DE FALLOS EN INSTALACIONES FOTOVOLTAICAS

La degradación de los paneles solares, que hace que disminuya su rendimiento, puede deberse a varios motivos:

- Desprendimiento de alguna parte del panel por avería o daños en el mismo.
- Desgaste del panel debido a la suciedad u otros contaminantes corrosivos que lo dañan.
- Las conexiones eléctricas deficientes también provocan pérdidas de potencia importantes.
- Los inversores también desempeñan un papel importante, ya que cualquier fallo de un inversor puede hacer que el sistema deje de suministrar energía por completo.

Los fallos que nosotros utilizaremos en la detección son los siguientes. No obstante, serán explicados y redactados de mejor forma en el punto 4.2.

- **F1: Fallo completo en uno de los 6 IGBT:** Este fallo es un fallo en el inversor que hace que la conversión de continua a alterna no se produzca correctamente. Esto hace que haya una bajada en el rendimiento.
- **F2: Fallo del sensor monofásico en un 20%:** Un fallo en el sensor monofásico en un 20% hace que no se ajuste bien el valor y se produzcan fallos que bajan el rendimiento.
- **F3: Caídas de tensión intermitentes:** Estas caídas de tensión intermitentes son bastante normales en las redes, no obstante, debemos estar protegidos, ya que esto puede ocasionar grandes daños.
- **F4: Sombreado parcial:** Los sombreados parciales hacen que las placas actúen de sumidero de energía en vez de generadores de energía, esto hará que aumente la temperatura y se puedan ocasionar puntos calientes.
- **F5: Circuito abierto:** Que el sistema se quede en circuito abierto es un escenario bastante negativo, ya que el sistema no será capaz de generar energía, con lo que disminuirá el rendimiento.
- **F6: Reducción en un 20% en el parámetro de ganancia del PI:** El controlador PI es el que hace que los modos de MPPT e IPPT busquen el punto de potencia óptimo para cada caso. En el caso de que ocurra un fallo en el parámetro de ganancia en una reducción del 20% significará que el valor de la potencia esperada también se verá reducido, ya que el parámetro de ganancia actúa como multiplicador.

- **F7: Aumento en un 20% en la constante de tiempo del PI:** En este caso la constante de tiempo lo que influye en el controlador PI es en la cantidad de tiempo que tarda este en reaccionar a los cambios, cuanto mayor sea este, peor se ajustara la potencia extraída al punto de potencia deseado.

Estos fallos pueden provocar un fenómeno llamado "Hot-Spot" o puntos calientes [14]. Los puntos calientes en los paneles solares son una situación en la que una pequeña zona de la superficie del panel solar se calienta más que el resto del panel, esto puede deberse a que la placa haga de sumidero de energía absorbiendo toda la energía generada a su alrededor.

Estos puntos calientes pueden ser perjudiciales para el panel solar porque pueden causar un aumento de temperatura en las células individuales, lo que puede conducir a una disminución de la eficiencia de la conversión de energía solar en electricidad. Si los puntos calientes permanecen durante un periodo de tiempo prolongado, pueden incluso causar la degradación permanente de las células solares y la pérdida de la capacidad de generar energía eléctrica (Ilustración 15). O lo que es peor, un incendio de las placas, pudiendo generar daños materiales a su alrededor.



*Ilustración 15: Fallo de Hot-Spot en placas solares [44].*




*Il·lustració 16: Incendio de un sistema fotovoltaico [45].*

Los fallos en los puntos calientes pueden detectarse mediante inspección visual de los paneles solares, aunque algunos puntos calientes pueden ser difíciles de detectar a simple vista. También pueden utilizarse herramientas de detección por infrarrojos para detectar puntos calientes más sutiles que no son visibles a simple vista.

Para evitar los puntos calientes, se recomienda mantener los paneles solares limpios y libres de obstrucciones que puedan causar sombras parciales, las cuales, hacen que no se active el diodo de by-pass, pero la zona sigue consumiendo en vez de generando energía (Como podemos observar en la ilustración siguiente). Además, deben realizarse inspecciones periódicas de los paneles solares para detectar y resolver cualquier problema en los circuitos eléctricos o en las células individuales que pueda estar causando puntos calientes.

Nosotros nos centraremos en 7 fallos, en concreto los cuales están explicados en el punto 4.2 del documento, ahí explicaremos uno a uno qué fallos son, como afectan al sistema y luego analizaremos mediante gráficas los resultados de la simulación de estos fallos.



*Ilustración 17: Ilustración sombreado parcial [46].*

## 3.2. DIAGNÓSTICO Y DETECCIÓN DE FALLOS

Una vez conocemos los tipos de fallos que pueden ocurrir en una instalación fotovoltaica, debemos centrarnos en que solución debemos poner a estos fallos [15]. Para ello podemos utilizar varios indicadores, los cuales nos mostrarán que algo no está saliendo como esperamos [16]. Los métodos más comunes para detectar fallos son:

- **Inspección visual:** La inspección visual es una de las formas más simples de detectar los fallos, esta consiste en que un experto revise visualmente si hay grietas, suciedad o cualquier tipo de problema en el sistema. No obstante, no es la mejor, ya que esta inspección ocurre una vez ya se ha producido el daño y además no se puede automatizar.
- **Termografía:** Esta técnica consiste en inspeccionar la temperatura del panel solar mediante sensores o cámaras térmicas. Algunos ejemplos de cámaras térmicas son: Bosch Professional GTC 400 C, Hti-Xintai HT-H8, HIKMICRO B20. Un aumento de la temperatura de la placa normalmente supone un fallo, además, con esta tecnología podemos observar la aparición de puntos calientes. La termografía también puede utilizarse para el cableado y los inversores. Sin embargo, este tipo de detección de fallos es muy caro debido al precio de las cámaras térmicas.
- **Rendimiento:** Este método también es muy sencillo, ya que solo consiste en ver el rendimiento y la cantidad de energía que produce y compararla con la que debe producir normalmente. Si esta energía disminuye puede deberse a un fallo en la placa, en los inversores o incluso en el cableado.
- **Estudio eléctrico:** Mediante el estudio de los parámetros eléctricos que nos deja la placa podemos ver que, cuando hay una disminución de potencia que no concuerda con la realidad, puede ser debido a un fallo en nuestra instalación solar. Esto se hace midiendo la tensión y la corriente mediante sensores o mediante la información que tenemos de los dispositivos externos conectados a las placas, no obstante, la información que nos proporcionan estos dispositivos la debemos estudiar bien, debido a que algunos fijan sus valores de entrada a los de salida. Por otro lado, con la reducción de precio de los sensores IoT (Internet of Things), los cuales son pequeños dispositivos diseñados para recopilar y transmitir datos a través de Internet, ha aparecido un nuevo método de medición eléctrica en instalaciones fotovoltaicas. Estos sensores son un componente fundamental de los sistemas IoT, que permiten a los objetos físicos conectarse y comunicarse entre sí, así como con plataformas y aplicaciones basadas en la nube. Estos pueden medir una amplia



gama de variables, como la temperatura, la humedad, la luz, el movimiento, la presión y el sonido, entre otras. Pueden estar integrados en diversos dispositivos, como teléfonos inteligentes, dispositivos para llevar puestos, electrodomésticos y vehículos, o instalarse como dispositivos independientes en hogares, oficinas, fábricas y otros entornos. Los sensores IoT son esenciales para recopilar datos que pueden analizarse y utilizarse para optimizar procesos, mejorar la toma de decisiones y mejorar la experiencia del usuario. Sin embargo, también plantean problemas de privacidad, seguridad y propiedad de los datos, que deben abordarse mediante un diseño, una implementación y una regulación adecuados.

El análisis eléctrico junto a un algoritmo de predicción de fallos es el que utilizaremos nosotros para hacer la detección temprana de posibles fallos que puedan ocasionar un daño irreparable del panel. El motivo de la utilización del estudio eléctrico es porque es el más fácil de evaluar y uno de los más precisos, ya que con tan solo unos sensores y un ordenador podemos hacer estas predicciones.

### **3.3. INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING EN EL ANÁLISIS DE DATOS**

En este apartado profundizaremos en las claves básicas para entender la inteligencia artificial (IA) [17] y el aprendizaje automático [18], así como su aplicación en el campo del análisis de datos. La inteligencia artificial recibe su nombre del hecho de que trata de imitar la inteligencia humana.

La inteligencia artificial es un área de estudio que se centra en el desarrollo de sistemas y programas capaces de realizar tareas que requieren inteligencia humana, como el razonamiento, el aprendizaje y la toma de decisiones. Dentro de la IA, existen varias ramas y enfoques, entre ellos el aprendizaje automático.

El aprendizaje automático es una subdisciplina de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos capaces de aprender y mejorar automáticamente a partir de datos. Estos algoritmos tienen la capacidad de identificar patrones y relaciones ocultas en conjuntos de datos masivos, conocidos como big data [19].

En el campo del mantenimiento predictivo [20], se utilizan técnicas de inteligencia artificial y aprendizaje automático para predecir y prevenir fallos en equipos y sistemas. En el caso concreto del estudio mencionado, se entrena un algoritmo con miles de datos extraídos tanto del funcionamiento normal como de cada una de las averías a estudiar. Estos datos incluyen información relevante como la corriente de salida, la tensión de salida, la tensión continua y otros parámetros importantes.

Una vez entrenado, el algoritmo de aprendizaje automático tiene la capacidad de identificar patrones y anomalías en los paneles solares, lo que facilita la detección temprana de fallos y el mantenimiento predictivo. Además, el aprendizaje automático permite entrenar modelos predictivos y de clasificación, que pueden hacer predicciones y tomar decisiones basadas en nuevos datos de entrada.

Sin embargo, es crucial llevar a cabo una validación exhaustiva y un estudio detallado de los resultados obtenidos para garantizar que el algoritmo se ha entrenado correctamente y determinar cuál de todos los algoritmos disponibles es el más adecuado para el modelo en cuestión.

En resumen, la inteligencia artificial y el aprendizaje automático son potentes herramientas en el análisis de datos y el mantenimiento predictivo. Estas técnicas permiten extraer conocimiento

y tomar decisiones basadas en grandes volúmenes de datos, mejorando la eficiencia y la precisión de los procesos en diversos campos, entre ellos el de la energía solar.



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

## 4. DISEÑO DEL ALGORITMO

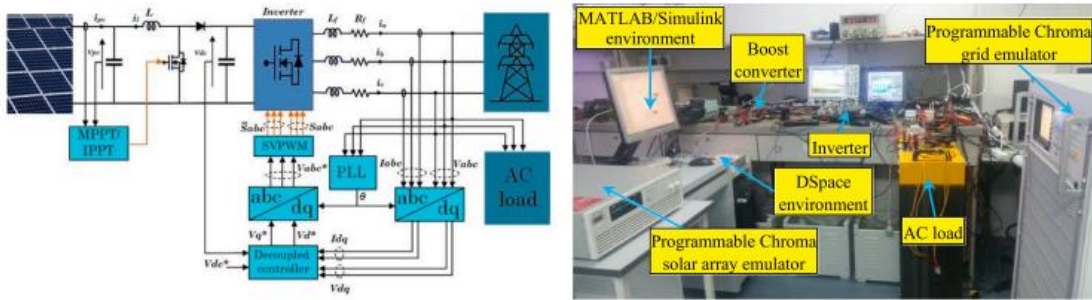
En este punto vamos a explicar cómo hemos diseñado el algoritmo de detección de fallos mediante Matlab. Para ello, en primer lugar, cogimos los datos que nos proporcionó el artículo [21] (en este sitio web [22]). Esos datos se extraen de un modelo de una placa simulada con elementos externos que vamos a explicar en el apartado 4.1. Esta simulación se ejecuta durante 15 segundos, en cada modo de funcionamiento. Lo que hacen en el artículo es añadir aleatoriamente cada fallo a partir del segundo 8 de la simulación, así se obtienen unos datos lo más parecido a la realidad. Así seremos capaz de obtener todos los valores desde el funcionamiento normal (F0L) hasta el fallo 7 (F7L). Luego de esto interpretaremos los datos y los trataremos para posteriormente incluirlos en el Classification Learner de Matlab, el cual nos creará el algoritmo de detección.

### 4.1. MODELO DEL SISTEMA FOTOVOLTAICO

Este modelo representa un sistema fotovoltaico conectado a la red, como se muestra en la figura [18]. Para simular la salida del panel fotovoltaico, se utiliza el emulador de arreglo solar programable Chroma 62150 H-1000S, el cual permite simular las variaciones de las condiciones ambientales. Asimismo, se emplea el emulador de corriente alterna Chroma 61511 para simular la red. El control y la adquisición de datos se llevan a cabo mediante el uso de un DSpace 1104.

En el artículo se detalla que se utilizan los métodos de control VOC (Control Orientado por Voltaje) y SPWM (Modulación de Ancho de Pulso de Vector Espacial) para regular la potencia reactiva y activa de la señal. Además, se implementa un control de lazo PLL y se introduce una carga de corriente alterna como medida de protección contra fallos inyectados en el sistema.

Por otra parte, el artículo menciona el uso de dos métodos de seguimiento de puntos de potencia: MPPT (seguimiento del punto de máxima potencia) e IPPT (seguimiento del punto de potencia intermedia). Nosotros vamos a comparar los resultados obtenidos de un método y de otro para observar las diferencias y así poder comprobar que el funcionamiento de los algoritmos es el correcto. No obstante, lo que tiene más sentido es aplicar el MPPT, ya que este logra extraer el máximo rendimiento al panel solar, que es lo que estamos buscando en todo momento.



*Il·lustració 18: Modelo del sistema fotovoltaico [1].*

## 4.2. ANÁLISIS DE LOS DATOS OBTENIDOS


A partir del montaje mencionado anteriormente, se generan ocho tipos de vectores (F0L/F0M, F1L/F1M, F2L/F2M, F3L/F3M, F4L/F4M, F5L/F5M, F6L/F6M, F7L/F6M), los cuales contienen una serie de parámetros. En total, cada señal tiene alrededor de 150,000 valores. Para nuestro análisis, hemos seleccionado los siguientes parámetros:

- Ipv (Corriente de salida)
- Vpv (Tensión de salida)
- Vdc (Tensión en continua)
- Iabc (Corriente de fase)
- If (Frecuencia de la corriente)
- Vabc (Tensión de fase)
- Vf (Frecuencia de la tensión)
- Tiempo

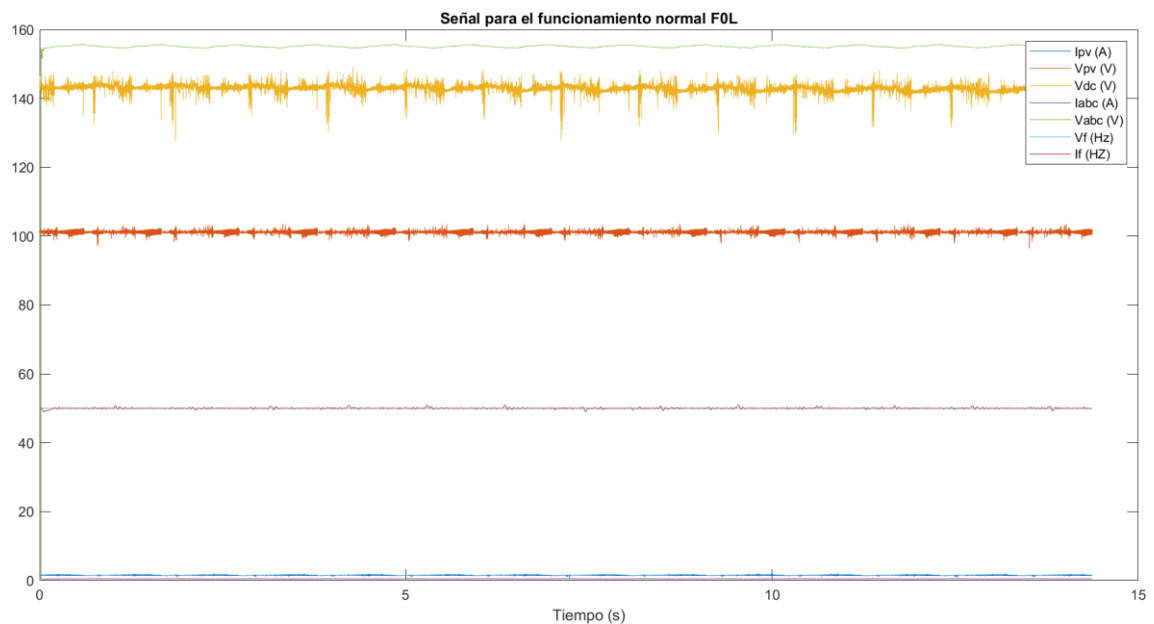
En la siguiente sección, compararemos las gráficas correspondientes a cada tipo de fallo. Esto nos permitirá tener una idea de cómo deberían lucir estas gráficas y evaluar si el Classification Learner está desempeñando un buen trabajo en su tarea de clasificación.

### 4.2.1. Comportamiento normal del sistema

Inicialmente, debemos examinar nuestros datos sin ninguna anomalía, para lo cual utilizaremos la función "plot" en Matlab. Esperamos que el comportamiento de la señal sin fallos fluctúe ligeramente, pero siempre dentro del mismo rango de funcionamiento, es decir, sin cambios abruptos. Estos valores serán aquellos en los que el panel solar se mantendrá la mayor parte del tiempo y serán bastante cercanos a los valores esperados proporcionados por el fabricante.



*Ilustración 19: Comportamiento normal del sistema fotovoltaico F0M.*



*Ilustración 20: Comportamiento normal del sistema fotovoltaico F0L.*


Al analizar las gráficas, podemos observar que son bastante parecidas, pero con varios cambios de valores. Por ejemplo, en la gráfica del MPPT vemos que la tensión y la corriente de salida son más elevadas, esto se debe a que el punto de máxima potencia busca maximizar la relación de estos dos para obtener una mayor potencia. Por otro lado, vemos como la tensión de continua es más elevada en el método IPPT. En cuanto a las formas de las señales, la técnica de MPPT tiene un poco más de ruido, esto se debe a la constante búsqueda del punto de máxima potencia que hace fluctuar más los valores. Con esta información podemos intuir que los predictores serán un poco más precisos para el MPPT debido a lo susceptible que es ante los fallos.




Estas señales son las que el modelo utilizará para distinguir entre el comportamiento sin fallas y el comportamiento con fallas.

#### 4.2.2. Fallo completo en uno de los seis IGBT (F1)

Ahora nos centraremos en identificar los cambios que se producen entre cada tipo de fallo y el comportamiento normal, este fallo lo resaltaremos con un estilo de línea discontinua y con mayor grosor que las otras señales. Empezaremos por F1 y analizaremos los valores que difieren del comportamiento normal. Para ello, utilizaremos la función "plot" del entorno Matlab y visualizaremos las discrepancias. Este fallo consiste en la pérdida total de uno de los IGBT [23] del inversor que convierte la corriente continua en corriente alterna, como resultado, el IGBT afectado no puede realizar su función de conmutación y amplificación de las señales eléctricas, lo que repercute negativamente en la conversión de la energía solar en corriente alterna.



*Ilustración 21: Comportamiento del sistema con el fallo 1 (F1M).*




*Ilustración 22: Comportamiento del sistema con el fallo 1 (F1L).*

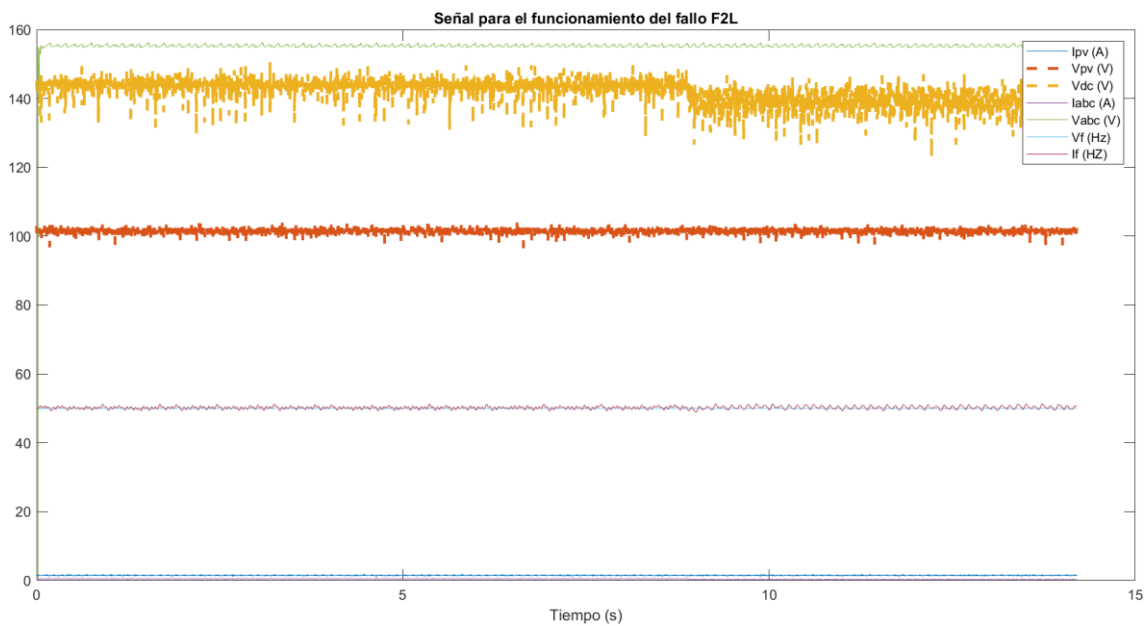
A partir de estas gráficas podemos extraer bastante información. En primer lugar, podemos ver como un fallo en un IGBT es un fallo grave para el método MPPT, ya que, todos sus valores caen a 0 incluso se vuelven negativos, lo que significa que el sistema absorbe energía y esto puede dañar el panel. Por otro lado, podemos ver que en el método IPPT no hay tanto problema y solo se distorsiona la señal de la tensión de continua (Naranja), por lo tanto, podemos concluir que será mucho más fácil de detectar el fallo con el método de máxima potencia.

### 4.2.3. Fallo del sensor monofásico en un 20% (F2)

A continuación, exploraremos todas las señales obtenidas de la simulación de un fallo de sensor monofásico con una tasa del 20% (Figura 21). Un fallo del sensor monofásico del 20% se refiere a un problema o mal funcionamiento del sensor utilizado para medir con precisión la corriente o la tensión en un sistema monofásico. Este fallo indica que el sensor presenta una desviación del 20% en sus mediciones en comparación con el valor real o esperado.



*Ilustración 23: Comportamiento del sistema con el fallo 2 (F2M).*




*Ilustración 24: Comportamiento del sistema con el fallo 2 (F2L).*

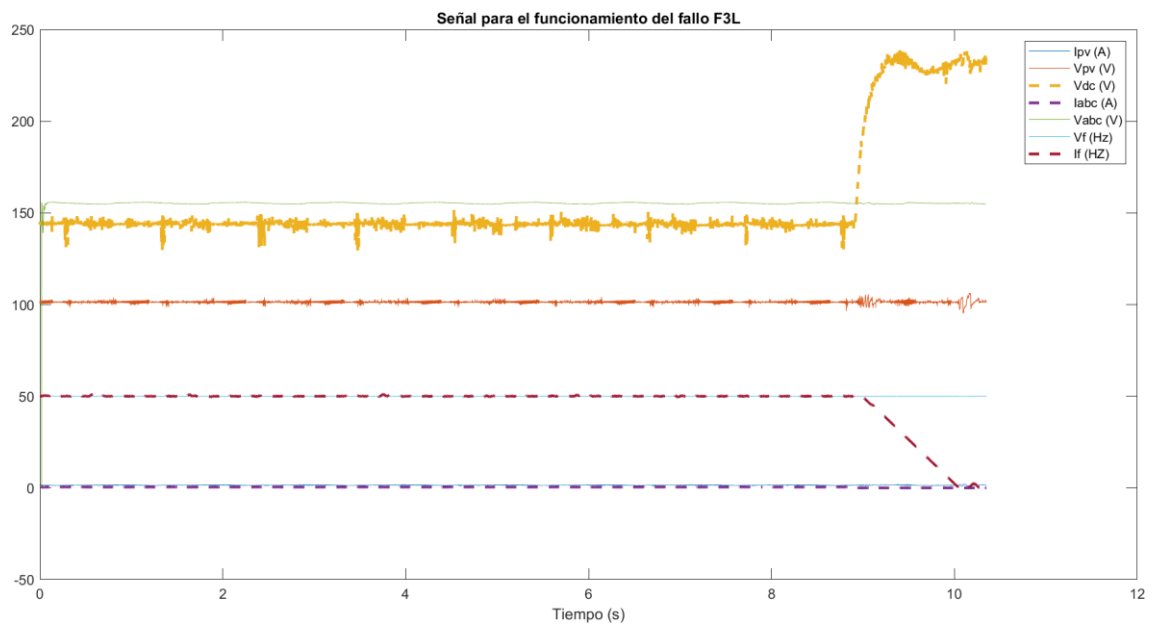
Los resultados de este fallo nos muestran que no hay mucha diferencia entre el método MPPT y el IPPT. Vemos como la tensión de continua (color naranja) cae unos pocos voltios cuando ocurre el error en ambas gráficas, la única diferencia observable es que la tensión de salida (color rojo) del método de máxima potencia cae unos voltios del valor de funcionamiento normal. Con esto también podemos concluir que este fallo será más detectable en este método.

#### 4.2.4. Caídas de tensión intermitentes (F3)

Las caídas de tensión intermitentes [24] pueden generar diversos efectos adversos como una interrupción de suministro, inestabilidad del sistema, daños en el equipo o pérdida de productividad. Lo que esperamos aquí es que las caídas de tensión cambien mucho el panorama de todas las señales volviendo loco al sistema. En la siguiente gráfica vamos a mostrar lo que ocurre.



*Ilustración 25: Comportamiento del sistema para el fallo 3 (F3M).*




*Ilustración 26: Comportamiento del sistema para el fallo 3 (F3L).*


Al analizar el fallo 3, con las gráficas anteriores, podemos ver que el fallo aporta el mismo comportamiento a ambos métodos, no obstante, vemos como la simulación del MPPT se para mucho antes que la del IPPT, esto puede ser un factor determinante a la hora de la detección de este fallo. En cuanto a las señales, vemos como en los dos métodos la tensión de continua (Naranja) se dispara cuando se produce la caída de tensión intermitente. También vemos como la frecuencia de la corriente (Morado) y la corriente alterna (Azul oscuro) caen a 0 A.

#### 4.2.5. Entre 10% y 20% de sombreado parcial no homogéneo (F4)

Este tipo de fallo es muy común en las instalaciones fotovoltaicas, más aún, cuando se trata de instalaciones que se encuentran cerca de objetos como instalaciones de un barco (los cuales tienen muchos mástiles que entorpecen la luz solar), instalaciones en ciudades que pueden tener edificios cerca o que les pueden caer varios tipos de objeto como hojas de árboles o contaminación humana. Ahora veremos qué tipo de señales genera este tipo de sombreado.



*Ilustración 27: Comportamiento del sistema ante sombreado parcial (F4M).*



**Ilustración 28:** Comportamiento del sistema ante sombreado parcial (F4L).


A simple vista, la tensión de salida (Rojo) para el método IPPT se reduce de 100 V a 80 V, lo que representa una disminución considerable del rendimiento de la placa. También podemos ver una bajada en las corrientes (Azul oscuro y Morado) de salida respecto a valor en el funcionamiento normal en ambos métodos, estando la corriente alterna (Morado) en 0,5 A durante toda la simulación. Estas bajadas de rendimiento harán que los fallos sean bastante detectables.

#### 4.2.6. Circuito abierto de la matriz fotovoltaica en un 15% (F5)


Un circuito abierto significa que hay una interrupción o desconexión en el circuito eléctrico del campo fotovoltaico, lo que impide el flujo normal de corriente eléctrica. En este caso, el error indica que aproximadamente el 15% del conjunto fotovoltaico presenta este fallo.

Cuando se produce un circuito abierto en el conjunto fotovoltaico, los paneles solares afectados no pueden generar electricidad de forma eficiente o, en algunos casos, no generan electricidad en absoluto. Esto puede deberse a conexiones sueltas, cables dañados, defectos en los paneles solares o cualquier otro problema que interrumpa el flujo de corriente.

Es importante detectar y solucionar este tipo de fallos en el panel fotovoltaico, ya que pueden afectar significativamente a la eficiencia y el rendimiento generales del sistema solar.



*Ilustración 29: Comportamiento del sistema ante el fallo 5 (F5M).*




*Ilustración 30: Comportamiento del sistema ante el fallo 5 (F5L).*

Podemos observar que, tras el fallo, tanto la corriente de salida trifásica (Morado) como la tensión de salida (Rojo) disminuyen hasta cero en los dos métodos. Aunque la tensión se recupera y vuelve a su nivel anterior, las corrientes no lo hacen y en el caso de máxima potencia la tensión vuelve a caer a 0 V. Además, se produce una caída significativa de la tensión continua (Naranja), que pasa de 140 V a 120 V. Esta avería concreta provoca cambios drásticos en el sistema.


#### 4.2.7. Parámetro de ganancia del controlador PI con una reducción del 20% (F6)

En el contexto del controlador PI [25] utilizado en el MPPT (seguimiento del punto de máxima potencia) o IPPT (seguimiento del punto de potencia incremental) del convertidor Boost, esto implica que el valor de la ganancia del controlador se reduce en un 20% respecto a su valor original. La ganancia del controlador es un parámetro que determina cómo responde el controlador a las variaciones de la señal de entrada y ajusta la señal de salida en consecuencia. En este caso, una reducción del 20% en el parámetro de ganancia puede afectar a la capacidad del regulador para optimizar el seguimiento del punto de máxima potencia o la potencia incremental del sistema de paneles solares.



*Ilustración 31: Comportamiento del sistema ante el fallo 6 (F6M).*



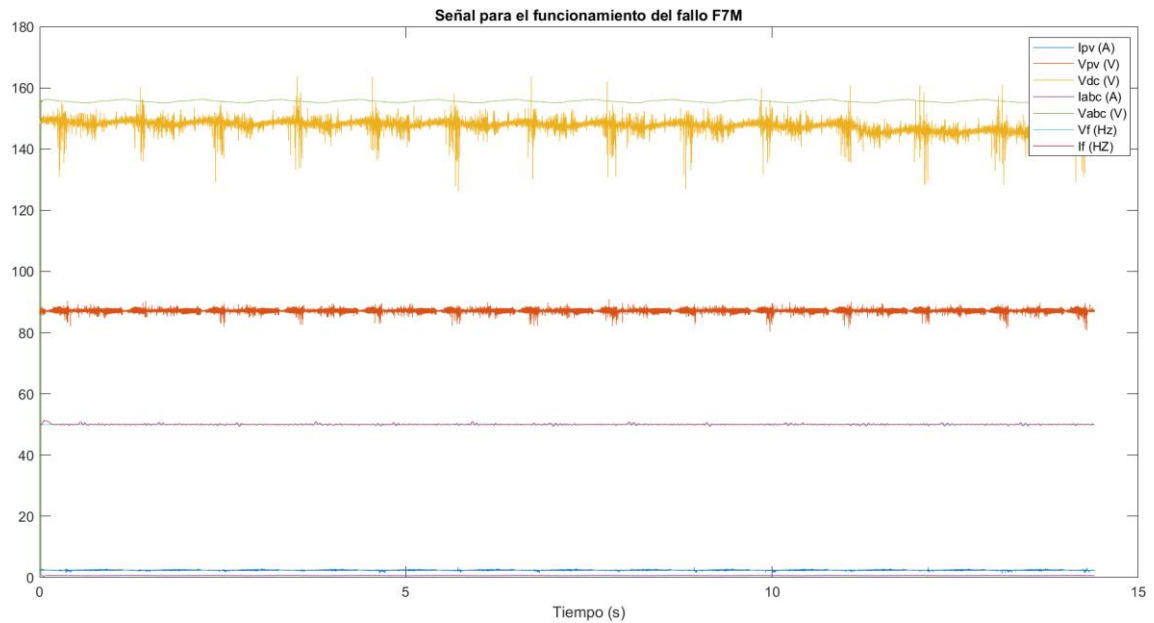


*Ilustración 32: Comportamiento del sistema ante el fallo 6 (F6L).*

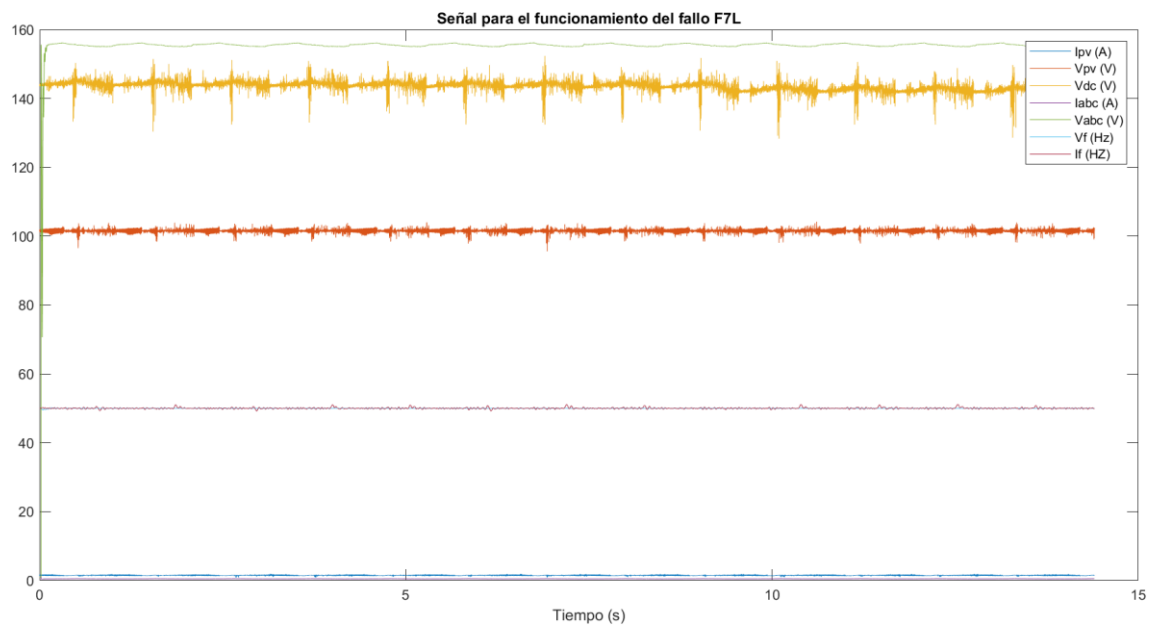
A simple vista solo podemos observar un ligero cambio al final de la gráfica, donde la tensión de continua (Naranja) fluctúa un poco extraña y se eleva un poco, esto ocurre tanto en el método MPPT como en el método IPPT. A raíz de esta observación somos capaces de decir que este fallo va a ser complicado de predecir y de detectar, ya que el algoritmo tendrá que ver los patrones ocultos de las señales.

#### **4.2.8. Parámetro de constante de tiempo del controlador PI con un aumento del 20% (F7)**

El aumento de este parámetro indica que el tiempo de respuesta del controlador es mayor, esto desemboca en que no consiga un buen control y nunca consiga llegar al punto de máxima potencia, reduciendo así la eficiencia del sistema fotovoltaico. Ahora vamos a ver qué tipo de datos genera este fallo.



**Ilustración 33:** Comportamiento normal del sistema ante el fallo 7 (F7M).



**Ilustración 34:** Comportamiento normal del sistema ante el fallo 7 (F7L).

Por último, tenemos el fallo 7 donde a simple vista no se puede observar ningún cambio respecto al funcionamiento normal en ninguno de los métodos. Hemos analizado una a una las señales y tampoco se observa ningún cambio significativo. Con esto podemos concluir que los fallos en el controlador PI tanto en el parámetro de ganancia como en el parámetro de constante de tiempo van a ser difíciles de predecir para nuestro modelo. No obstante, podemos estar un poco aliviados, ya que este fallo solo afecta al rendimiento y no ocasionan ningún daño en la placa, lo que deja intacta la seguridad del sistema y del personal.



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

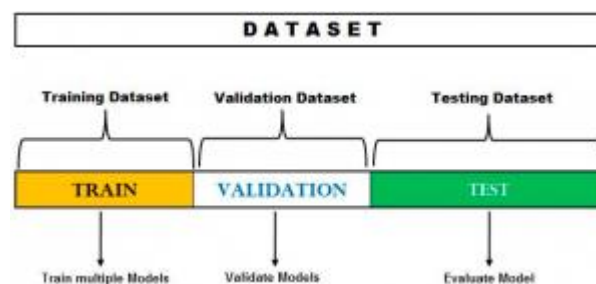


Escola Tècnica Superior d'Enginyeria del Disseny

## 5. ENTRENAMIENTO Y RESULTADOS

Tras obtener y analizar los datos, es hora de entrenar el algoritmo de Machine Learning para evaluar su eficacia y seleccionar el mejor algoritmo. Para ello, combinaremos verticalmente todas las variables (desde el comportamiento normal hasta el fallo 7) para crear una matriz con 9 columnas. Estas columnas incluirán todas las variables, así como el tiempo. Además, añadiremos una última columna que etiquetará el tipo de fallo que se produce en cada momento. De esta forma, tendremos una matriz compacta que contendrá todas las variables relevantes y las etiquetas de fallo correspondientes.

Por otro lado, para el entrenamiento utilizaremos el método de “Holdout Validation” [26] el cual consiste en separar los datos en tres etapas: la etapa de entrenamiento, la etapa de validación y la etapa de Test. Este tipo de entrenamiento es muy utilizado cuando se tiene una cantidad de datos lo suficientemente grande y se hace así, ya que, la parte de validación se utiliza para ajustar los hiperparámetros del modelo y la parte de prueba para hacer una evaluación de forma imparcial. En nuestro caso escogemos este método, puesto que tenemos columnas de más 1 millón de datos (150.000 por 8).



*Ilustración 35: Representación de la “Holdout Validation” [48].*

Nuestra división contiene los siguientes porcentajes de entrenamiento, validación, test:


- Entrenamiento: 55%
- Validación: 30%
- Test: 15%

Ahora el siguiente paso es ver una a una, cuál es la técnica más eficiente para nuestros datos, en la validación.

## 5.1. VALIDACIÓN DE LOS DATOS

### 5.1.1.1. Árboles de decisión

Esta técnica de aprendizaje automática está, compuesta por nodos y ramas, los cuales se van dividiendo cada vez más. Estas divisiones son caminos por los cuales se dividen las características, es decir, se va preguntando todo el rato si tiene una característica o no hasta que se llega a un resultado. Esta técnica se denomina así debido a su alta similitud a un árbol que tiene muchas ramas (ilustración 36) [27].



*Ilustración 36: Estructura del árbol de decisiones [49].*

Nosotros hemos utilizado tres modelos: el árbol fino, el árbol medio, el árbol grueso y el árbol optimizado. Esta tabla muestra los resultados:

Técnica (IPPT)	Precisión (Validación)
Árbol Fino	92,4 %
Árbol Medio	86,0 %
Árbol Grueso	66,4 %
Árbol Optimizado	97,1 %

*Tabla 1: Precisión de los árboles de decisión (MPPT).*

Técnica (IPPT)	Precisión (Validación)
Árbol Fino	71,4 %
Árbol Medio	60,6 %
Árbol Grueso	39,1 %
Árbol Optimizado	97,1 %

*Tabla 2: Precisión de los árboles de decisión (IPPT).*

A continuación, mostraremos las matrices de confusión de cada una de las técnicas utilizadas, ya que es la más representativa en estos casos. El método de árbol fino lleva este nombre debido a que la amplitud del árbol es más fina, los dos siguientes árboles se irán ensanchando progresivamente, de ahí su nombre “medio” y “grosso”. Posteriormente, analizaremos una por una las características de las técnicas y los fallos que tienen.

0	86.9%	0.3%	0.0%	22.8%		0.0%	0.1%	0.1%
1	0.4%	96.9%	0.0%	0.0%		0.6%		7.5%
2		0.0%	98.3%		0.0%	0.8%		0.2%
3	12.3%	0.1%	0.0%	76.5%		0.0%	0.1%	0.0%
4	0.0%		0.0%	0.0%	100.0%	0.0%		0.0%
5		0.3%	1.2%			91.4%		9.8%
6	0.4%	0.0%		0.6%			99.8%	0.0%
7	0.0%	2.3%	0.4%	0.0%		7.2%		82.4%

*Ilustración 37: Matriz de confusión del Árbol Fino (MPPT).*

True Class	0	71.9%	0.4%	0.8%	1.3%		4.7%	7.2%	3.8%
	1	3.5%	81.0%	5.6%	0.5%		0.1%	2.5%	5.8%
	2	4.8%	5.0%	84.4%	2.1%		1.2%	5.9%	5.0%
	3	6.4%	4.1%	4.2%	86.0%		7.2%	15.1%	10.3%
	4	0.0%	0.1%	0.1%	0.6%	100.0%		0.1%	0.0%
	5	9.4%	1.7%	2.7%	2.6%		85.6%	10.9%	4.2%
	6	1.3%	1.7%	0.9%	3.6%		0.9%	45.5%	13.2%
	7	2.7%	6.1%	1.3%	3.3%		0.2%	12.9%	57.7%

*Il·lustració 38: Matriz de confusió del Àrbol Fino (IPPT).*

Como podemos observar en la matriz de confusión, y habíamos comentado anteriormente, vemos como el fallo 4 (sombreado parcial) es el más fácil de detectar porque su tensión de salida se veía reducido en 20 V. Esto el árbol de decisión fino ha sabido captarlo perfectamente para los dos métodos. Por otro lado, vemos como los fallos 6 y 7 (los relacionados con el controlador PI) son los que más le cuesta captar para el método de IPPT. Por lo contrario, en el método de máxima potencia, al depender mucho del controlador del PI para buscar constantemente este punto, estos fallos los detecta mucho más fácil. Por lo general, vemos que podemos detectar mucho más fácil los fallos en el método MPPT.

True Class	0	80.5%	0.3%	0.0%	34.6%			0.3%	0.1%
	1	0.3%	95.9%	0.1%	0.2%		0.0%		6.3%
	2			96.7%		0.0%			1.1%
	3	18.6%	0.1%	0.0%	64.7%			0.3%	0.0%
	4	0.0%	0.0%	0.0%		99.9%			0.2%
	5		0.4%	2.7%		0.0%	100.0%		30.9%
	6	0.6%	0.0%		0.5%			99.4%	0.0%
	7	0.0%	3.3%	0.5%	0.0%				61.5%

*Il·lustració 39: Matriz de confusió del Àrbol Medio (MPPT).*

True Class	0	81.6%	0.3%	11.5%			0.0%	9.5%	5.5%
	1	0.7%	92.5%	8.7%	0.6%		0.1%	4.4%	20.6%
	2	2.2%	2.6%	57.5%	0.0%		0.1%	8.9%	9.1%
	3	4.6%	0.0%	8.9%	99.3%		0.1%	15.5%	9.2%
	4	0.0%	0.3%	0.1%		100.0%	0.0%	0.1%	
	5	4.6%	0.1%	5.1%	0.0%		99.7%	14.7%	5.1%
	6	2.5%	0.2%	1.7%	0.0%		0.1%	35.9%	9.9%
	7	3.8%	3.9%	6.4%			0.0%	11.0%	40.6%

*Ilustración 40: Matriz de confusión del Árbol Medio (IPPT).*

Como podemos observar aquí ocurre prácticamente lo mismo que en el método del árbol fino, pero con la variación de que este método es menos preciso.

True Class	0	66.4%		0.0%				0.6%	0.2%
	1	0.3%		26.1%		0.7%			28.0%
	2			69.4%		0.1%			0.8%
	3	32.7%		0.0%				0.8%	0.1%
	4	0.0%		0.0%		74.1%			0.1%
	5	0.1%		4.2%		25.1%		10.3%	23.3%
	6	0.6%						88.4%	0.0%
	7	0.0%		0.4%		0.1%			47.6%

*Ilustración 41: Matriz de confusión para el Árbol Grueso (MPPT).*



True Class	0		0.3%	21.4%		0.0%	19.6%	
	1		40.8%	3.8%		0.0%	9.4%	
	2		46.7%	7.7%		0.1%	10.0%	
	3		9.7%	36.7%		0.0%	12.2%	
	4		0.2%		100.0%		0.0%	
	5		0.2%	8.3%	0.0%	99.9%	9.8%	
	6		0.2%	14.4%		0.0%	19.6%	
	7		1.8%	7.7%		0.0%	19.3%	

*Ilustración 42: Matriz de confusión para el Árbol Grueso (IPPT).*

Esta matriz nos muestra como el árbol grueso no es para nada una buena opción a utilizar con nuestros datos, ya que se deja bastantes fallos sin predecir en los dos métodos.

Por último, vamos a ver como sale el árbol optimizado. Este se diferencia de los otros en que utiliza métodos de optimización para mejorar su rendimiento, esto reduce la complejidad y mejora la generalización del árbol, haciendo como hemos visto en la tabla 1 que la precisión aumente notablemente.

True Class	0	98.9%	0.2%	0.0%	1.5%		0.0%	0.1%	0.0%
	1	0.2%	98.7%	0.0%	0.0%	0.0%	0.4%		0.4%
	2	0.0%	0.0%	99.1%		0.0%	0.6%		0.1%
	3	0.7%	0.1%	0.0%	98.2%		0.0%	0.1%	0.0%
	4			0.0%		100.0%			0.0%
	5	0.0%	0.4%	0.7%	0.0%		98.0%		0.9%
	6	0.1%	0.0%		0.3%		0.0%	99.8%	0.0%
	7	0.0%	0.5%	0.2%	0.0%	0.0%	1.0%	0.0%	98.6%

*Ilustración 43: Matriz de confusión del Árbol de decisión Optimizado (MPPT).*

0	97.1%	0.2%	0.6%	0.6%	0.0%	1.3%	0.1%	0.2%
1	0.2%	96.8%	0.5%	0.5%		0.2%	0.4%	1.1%
2	0.6%	0.7%	97.3%	1.0%		0.5%	0.4%	0.4%
3	0.4%	0.5%	0.5%	95.4%		0.8%	0.5%	0.4%
4	0.0%	0.0%	0.0%	0.0%	100.0%	0.0%	0.0%	0.0%
5	1.3%	0.2%	0.4%	1.1%		96.9%	0.1%	0.1%
6	0.1%	0.5%	0.2%	0.8%	0.0%	0.1%	96.8%	1.8%
7	0.2%	1.1%	0.4%	0.5%		0.1%	1.6%	96.0%

*Ilustración 44: Matriz de confusión del Árbol de decisión Optimizado (IPPT).*

## 5.1.2. Análisis discriminante

Este tipo de análisis se basa en la discriminación de los datos para clasificar, y existen de dos tipos: lineal y cuadrático [28]. Obviamente, el lineal se ajustará peor que el cuadrático, ya que este último es más flexible por su naturaleza. No obstante, este tipo de análisis no va a tener mucha eficiencia para nuestros datos.

Técnica (MPPT)	Precisión (Validación)
Lineal	52,4 %
Cuadrático	78,1 %

*Tabla 3: Precisión de los análisis discriminantes (MPPT).*

Técnica (IPPT)	Precisión (Validación)
Lineal	43,2 %
Cuadrático	62,1 %

*Tabla 4: Precisión de los análisis discriminantes (IPPT).*

Como podemos observar, estas técnicas no captan bien los parámetros internos de nuestros datos, con lo que tienen una precisión bastante baja. Aun así, vamos a analizar sus matrices de confusión.

0	28.7%		1.6%	15.3%	0.2%		27.7%	15.4%
1	22.8%	91.9%	8.0%	15.1%	0.1%		1.9%	9.5%
2	1.4%		58.6%	12.1%	0.1%	0.0%	0.1%	17.0%
3	15.4%		2.2%	14.9%	0.2%	0.0%	11.6%	2.0%
4	0.2%			1.0%	94.0%	1.2%	8.2%	0.0%
5	10.1%	8.1%	12.0%	13.7%	0.3%	98.7%	0.3%	10.5%
6	11.0%		0.1%	13.8%	5.1%	0.0%	50.1%	5.9%
7	10.2%		17.4%	14.1%	0.1%	0.0%	0.2%	39.7%

*Il·lustració 45: Matriz de confusió para el análisis discriminante lineal (MPPT).*

0	41.4%	9.8%	12.3%	0.0%	0.1%		15.8%	14.6%
1	5.6%	21.3%	14.1%	0.0%	0.0%	0.0%	14.0%	15.0%
2	6.9%	13.4%	34.5%	0.3%	1.3%	0.0%	6.3%	21.0%
3	4.9%	14.7%	9.9%	99.0%	0.0%	0.0%	8.4%	12.7%
4	0.0%	0.0%	0.0%		98.2%		0.0%	0.0%
5	5.1%	12.1%	8.1%		0.4%	99.9%	4.8%	11.4%
6	14.8%	13.4%	10.0%	0.5%	0.0%		29.0%	10.7%
7	21.2%	15.2%	11.1%	0.1%	0.0%	0.1%	21.6%	14.5%

*Il·lustració 46: Matriz de confusió para el análisis discriminante lineal (IPPT) ¡Error! No se encuentra el origen de la referencia..*

En la misma línea que los apartados anteriores, vemos como los fallos más difíciles de detectar son los fallos 6 y 7 para el método IPPT, y para el método MPPT será el F3, ya que tiene muy pocos datos de simulación. Y los fallos que obtienen mayor precisión son el 4 y 5. Esto era fácil de intuir debido al análisis previo de las gráficas.

0	66.8%	0.1%	0.0%	22.8%		0.1%	0.7%	0.1%
1	2.2%	94.9%	0.1%	3.1%		0.4%		27.2%
2		0.7%	95.9%	2.0%		1.2%		0.3%
3	30.6%	0.2%	0.0%	55.4%		0.2%	1.0%	0.0%
4		1.1%	0.1%	2.4%	100.0%	1.2%		
5	0.0%	1.5%	3.6%	3.3%		95.3%		23.2%
6	0.3%	0.3%		8.6%		0.9%	98.4%	0.0%
7	0.1%	1.4%	0.4%	2.3%		0.8%		49.1%

*Il·lustració 47: Matriz de confusió para el análisis discriminante cuadrático (MPPT).*

0	56.1%	0.9%	2.9%	2.5%		0.3%	1.6%	3.4%
1	1.6%	69.3%	5.4%	3.0%		0.4%	6.7%	17.5%
2	7.6%	7.6%	78.0%	2.0%		0.4%	3.1%	18.2%
3	7.7%	5.9%	2.9%	84.4%		0.3%	16.4%	12.0%
4					100.0%	1.8%		
5	9.7%	1.1%	2.7%	1.5%		96.1%	12.6%	6.7%
6	3.7%	2.3%	3.4%	4.3%		0.3%	40.7%	9.5%
7	13.7%	12.9%	4.7%	2.3%		0.4%	18.9%	32.7%

*Il·lustració 48: Matriz de confusió para el análisis discriminante cuadrático (IPPT).*

Aquí podemos observar que hay una mejor precisión en general, pero el patrón sigue siendo el mismo, ya que detecta los mismos fallos que las técnicas anteriores, a excepción del gran aumento en la precisión del método de máxima potencia del fallo 3.

### 5.1.3. Clasificador Naive Bayes

Este tipo de clasificadores se denomina Naive Bayes [29], debido a, la palabra en inglés naive (ingenuo), ya que, asume que todas las variables son independientes entre sí y porque aplica los teoremas de Bayes basado en las probabilidades, donde se calcula la probabilidad a prior y la

probabilidad condicional. Aquí solo vamos a utilizar una técnica de clasificación que es “Gaussian Naive Bayes”.

Técnica (MPPT)	Precisión (Validación)
Gaussian	77,7 %

*Tabla 5: Precisión de los clasificadores Naives Gaussiano (MPPT)*

Técnica (IPPT)	Precisión (Validación)
Gaussian	57,7 %

*Tabla 6: Precisión de los clasificadores Naives Gaussiano (IPPT).*

Aquí observamos como el clasificador Gaussiano no es demasiado preciso y nos da solo un porcentaje de precisión menor al de otros métodos.

True Class	0	1	2	3	4	5	6	7
0	65.5%	0.1%	0.0%	36.6%		0.0%	0.6%	0.1%
1	3.5%	84.2%	0.0%	5.2%		1.9%		26.4%
2		1.5%	97.2%	2.6%		0.1%		0.9%
3	29.9%	3.1%	0.0%	35.2%		0.8%	1.6%	0.0%
4		0.5%	0.1%	4.0%	100.0%	1.0%		
5	0.1%	8.8%	2.1%	5.1%		96.0%		24.0%
6	0.8%	0.5%		8.3%		0.1%	97.8%	0.0%
7	0.2%	1.4%	0.5%	3.0%	0.0%	0.1%		48.6%

*Ilustración 49: Matriz de confusión para el clasificador “Gaussian Naive Bayes” (MPPT).*

True Class	0	1	2	3	4	5	6	7
0	50.2%	3.2%	3.5%	1.3%		0.3%	4.0%	6.6%
1	2.1%	57.0%	7.3%	1.3%		0.3%	6.7%	14.0%
2	3.6%	8.4%	75.1%	1.5%		0.4%	6.6%	33.8%
3	9.7%	6.7%	2.5%	91.2%		0.2%	15.2%	10.6%
4					100.0%	2.6%		
5	8.7%	2.8%	2.3%	1.4%		95.8%	12.8%	7.3%
6	7.1%	5.4%	4.0%	1.7%		0.2%	36.9%	6.5%
7	18.5%	16.6%	5.3%	1.6%		0.2%	17.8%	21.1%

*Ilustración 50: Matriz de confusión para el clasificador “Gaussian Naive Bayes” (IPPT).*

Podemos seguir observando como siguen siendo más o menos las mismas matrices de confusión, obteniendo el mayor porcentaje de predicción en el fallo 4 y 5 y el menor en el 6 y 7 en el caso del IPPT, mientras que en el método de máxima potencia los fallos 4 y 6 son los que con más precisión se predicen.

#### 5.1.4. Nearest Neighbor Classifier

Nearest Neighbor Classifier o clasificadores de vecinos cercanos [30] se basa en la idea de clasificar las características con las más parecidas. Es decir, si hay algún fallo con los datos descritos en ese instante, los que están al lado a una distancia 'k' seguramente tengan el mismo tipo de fallo, y así va valorando sucesivamente los fallos mediante ponderaciones. Esta técnica de computación tiene bastantes ventajas, ya que es bastante simple y efectiva. También tiene una gran capacidad de adaptarse a las características no lineales. Veremos como las mejores precisiones para nuestros datos se hallan en este apartado.

Aquí vamos a encontrar varios tipos de técnicas también: Fine KNN, Medium KNN, Cubic KNN, Weighted KNN.

Técnica (MPPT)	Precisión (Validación)
Fine KNN	98,9 %
Medium KNN	97,8 %
Cubic KNN	97,0 %
Weighted KNN	98,5 %

*Tabla 7: Precisión de las técnicas de KNN (MPPT)*

Técnica (IPPT)	Precisión (Validación)
Fine KNN	98,00 %
Medium KNN	96,1 %
Cubic KNN	94,9 %
Weighted KNN	97,2 %

*Tabla 8: Precisión de las técnicas de KNN (IPPT).*

Como podemos observar, esta técnica es la más adecuada para nuestros datos y para nuestra aplicación. No obstante, excepto la técnica Fine KNN, estas técnicas son un poco costosas, computacionalmente hablando, de todas formas, no influye en que estas sean nuestras mejor propuestas. A continuación, vamos a analizar cada una de las matrices de confusión.

True Class	0	98.4%	0.4%	0.0%	1.8%	0.0%	0.0%	0.2%	0.1%
	1	0.4%	98.2%	0.0%	0.2%		0.3%	0.0%	0.8%
	2		0.0%	99.1%		0.0%	0.7%		0.0%
	3	1.0%	0.1%	0.0%	97.2%		0.1%	0.1%	0.0%
	4		0.0%	0.0%		99.9%	0.0%		0.0%
	5	0.0%	0.2%	0.8%	0.1%	0.0%	98.8%		0.1%
	6	0.2%	0.0%	0.0%	0.7%	0.0%	0.0%	99.7%	0.0%
	7	0.1%	0.9%	0.1%	0.0%	0.0%	0.2%	0.0%	99.0%

*Ilustración 51: Matriz de confusión para Fine KNN (MPPT).*

True Class	0	98.2%	0.2%	0.1%	0.1%		0.2%	0.1%	0.2%
	1	0.2%	97.9%	0.2%	0.1%		0.1%	0.2%	0.1%
	2	1.1%	1.0%	99.0%	1.3%		0.8%	0.5%	0.6%
	3	0.0%	0.2%	0.3%	95.1%		0.2%	2.0%	0.4%
	4					100.0%			
	5	0.1%	0.1%	0.1%	0.4%		98.6%	0.2%	0.0%
	6	0.1%	0.3%	0.1%	2.4%		0.1%	96.2%	0.6%
	7	0.2%	0.3%	0.1%	0.7%		0.0%	0.8%	98.0%

*Ilustración 52: Matriz de confusión para Fine KNN (IPPT).*

Esta matriz de confusión nos muestra como hasta ahora es uno de los mejores modelos debido a su gran precisión. Como ya hemos comentado, el fallo 4 siempre es el más fácil de detectar. No obstante, este método detecta con peor precisión el fallo 3 en los dos métodos.

True Class	0	95.9%	0.6%	0.0%	3.1%	0.1%	0.1%	0.3%	0.1%
	1	0.8%	96.3%	0.1%	0.5%	0.0%	0.4%	0.0%	1.0%
	2	0.0%	0.1%	97.9%	0.0%	0.1%	0.9%		0.1%
	3	2.8%	0.3%	0.0%	94.7%	0.0%	0.1%	0.3%	0.0%
	4		0.0%	0.0%		99.7%	0.0%	0.0%	0.0%
	5	0.1%	0.7%	1.7%	0.3%	0.0%	97.9%		0.2%
	6	0.4%	0.0%	0.0%	1.4%	0.1%	0.0%	99.4%	0.0%
	7	0.1%	1.9%	0.3%	0.0%	0.0%	0.6%	0.0%	98.6%

*Il·lustració 53: Matriz de confusión para Medium KNN (MPPT).*

True Class	0	96.0%	0.4%	0.1%	0.1%		0.2%	0.3%	0.4%
	1	0.4%	95.6%	0.2%	0.3%		0.2%	0.4%	0.2%
	2	2.4%	2.6%	99.0%	2.7%		1.5%	1.0%	1.2%
	3	0.1%	0.4%	0.2%	90.4%		0.4%	3.0%	0.7%
	4					100.0%			
	5	0.4%	0.2%	0.3%	0.8%		97.2%	0.4%	0.1%
	6	0.2%	0.4%	0.0%	4.5%		0.2%	92.9%	1.0%
	7	0.5%	0.5%	0.1%	1.3%		0.2%	2.0%	96.5%

*Il·lustració 54: Matriz de confusión para Medium KNN (IPPT).*



True Class	0	94.8%	0.7%	0.0%	4.2%	0.1%	0.1%	0.5%	0.1%
	1	0.8%	95.2%	0.1%	0.6%	0.0%	0.6%	0.0%	1.5%
	2	0.0%	0.1%	97.3%	0.0%	0.1%	1.2%		0.2%
	3	3.5%	0.3%	0.0%	92.8%	0.0%	0.1%	0.4%	0.0%
	4	0.0%	0.0%	0.0%	0.0%	99.7%	0.0%	0.0%	0.0%
	5	0.1%	1.0%	2.1%	0.3%	0.0%	97.2%		0.2%
	6	0.6%	0.0%	0.0%	2.0%	0.1%	0.0%	99.2%	0.0%
	7	0.2%	2.6%	0.4%	0.1%	0.0%	0.7%	0.0%	98.0%

*Ilustración 55: Matriz de confusión para Cubic KNN (MPPT).*

True Class	0	95.0%	0.5%	0.2%	0.1%		0.3%	0.4%	0.6%
	1	0.5%	94.7%	0.3%	0.4%		0.3%	0.4%	0.3%
	2	2.5%	2.9%	98.5%	3.1%		1.6%	1.1%	1.4%
	3	0.2%	0.5%	0.3%	87.1%		0.6%	4.0%	1.1%
	4					100.0%			
	5	0.5%	0.3%	0.4%	1.2%		96.5%	0.7%	0.1%
	6	0.4%	0.4%	0.1%	6.0%		0.4%	90.7%	1.4%
	7	0.8%	0.7%	0.2%	2.0%		0.3%	2.7%	95.0%

*Ilustración 56: Matriz de confusión para Cubic KNN (IPPT).*

True Class	0	97.8%	0.5%	0.0%	2.5%	0.0%	0.0%	0.3%	0.1%
	1	0.4%	97.7%	0.1%	0.3%	0.0%	0.3%	0.0%	0.9%
	2	0.0%	0.0%	98.8%	0.0%	0.1%	0.7%		0.1%
	3	1.5%	0.2%	0.0%	96.2%	0.0%	0.1%	0.2%	0.0%
	4		0.0%	0.0%		99.8%	0.0%		0.0%
	5	0.0%	0.4%	0.9%	0.1%	0.0%	98.5%		0.1%
	6	0.2%	0.0%	0.0%	0.9%	0.0%	0.0%	99.5%	0.0%
	7	0.1%	1.2%	0.2%	0.0%	0.0%	0.3%	0.0%	98.8%

*Ilustración 57: Matriz de confusión para Weighted KNN (MPPT).*

True Class	0	97.2%	0.3%	0.1%	0.1%		0.2%	0.2%	0.3%
	1	0.2%	96.7%	0.1%	0.2%		0.2%	0.3%	0.2%
	2	1.7%	1.8%	99.3%	1.9%		1.3%	0.7%	1.0%
	3	0.1%	0.3%	0.2%	93.9%		0.3%	2.6%	0.5%
	4					100.0%			
	5	0.2%	0.2%	0.1%	0.4%		97.8%	0.3%	0.0%
	6	0.2%	0.3%	0.0%	2.7%		0.2%	94.7%	0.8%
	7	0.3%	0.4%	0.1%	0.7%		0.1%	1.2%	97.2%

*Ilustración 58: Matriz de confusión para Weighted KNN (IPPT).*

Todas estas matrices nos muestran que esta técnica identifica de igual forma a cada fallo (algunas con más precisión, otras con menos), ya que el fallo 4 es identificado en todas casi al 100% y el fallo 7 es lo más difícil de predecir.

Ahora que ya hemos entrenado todos los métodos solo nos queda testarlos, en el siguiente apartado veremos los resultados de la simulación de los test con los datos que separamos para la parte de Test.

## 5.2. TEST DE LOS ALGORITMOS

En este apartado utilizaremos la parte de los datos que hemos reservado para el Test. La diferencia entre estas dos fases radica en el propósito que quieren obtener. En la fase de validación el propósito es ajustar y seleccionar los hiperparámetros del modelo, es decir, aquí el modelo va probando diferentes configuraciones de los parámetros para lograr la combinación óptima de estos. Por otra parte, la parte de prueba se utiliza para evaluar el modelo, cuyos parámetros ya han sido encontrados anteriormente, con unos datos los cuales no han sido metidos en la fase de entrenamiento, esto hará que esta evaluación sea de forma imparcial.

La idea de disponer de conjuntos separados de validación y prueba es garantizar que el modelo no esté demasiado ajustado a los datos de validación y que pueda generalizarse bien a datos nuevos y desconocidos. La parte de validación se utiliza para tomar decisiones internas sobre el modelo, mientras que la parte de prueba proporciona una estimación imparcial y realista del rendimiento del modelo en situaciones reales.

### 5.2.1. Árbol de decisiones (Test)

Vamos a seguir el mismo orden anterior empezando por los árboles de decisión. A continuación, mostraremos la tabla y las matrices de confusión.

Técnica (MPPT)	Precisión (Test)
Árbol Fino	92,5 %
Árbol Medio	86,2 %
Árbol Grueso	66,4 %
Árbol Optimizado	99,2 %

*Tabla 9: Precisión de los árboles de decisión (MPPT)(Test).*

Técnica (IPPT)	Precisión (Test)
Árbol Fino	71,4 %
Árbol Medio	57,4 %
Árbol Grueso	39,1 %
Árbol Optimizado	97,8 %

*Tabla 10: Precisión de los árboles de decisión (IPPT)(Test).*

0	86.9%	0.3%	0.0%	22.8%		0.0%	0.1%	0.1%
1	0.4%	96.9%	0.0%	0.0%		0.6%		7.5%
2		0.0%	98.3%		0.0%	0.8%		0.2%
3	12.3%	0.1%	0.0%	76.5%		0.0%	0.1%	0.0%
4	0.0%		0.0%	0.0%	100.0%	0.0%		0.0%
5		0.3%	1.2%			91.4%		9.8%
6	0.4%	0.0%		0.6%			99.8%	0.0%
7	0.0%	2.3%	0.4%	0.0%		7.2%		82.4%

*Il·lustració 59: Matriz de confusión para Árbol Fino (MPPT)(Test).*

0	77.9%	0.5%	0.5%	11.9%		4.5%	7.0%	3.8%
1	2.8%	74.3%	1.8%	4.2%		0.1%	2.6%	4.6%
2	4.1%	7.6%	94.6%	5.8%		1.2%	5.9%	5.3%
3	4.0%	6.7%	0.8%	57.0%		7.3%	15.1%	9.6%
4	0.0%	0.1%	0.0%	0.3%	100.0%		0.1%	0.0%
5	7.8%	3.6%	0.4%	11.6%		85.9%	11.1%	3.9%
6	1.1%	1.7%	0.9%	4.4%		0.8%	45.3%	13.5%
7	2.3%	5.5%	1.0%	4.8%		0.2%	13.0%	59.3%

*Il·lustració 60: Matriz de confusión para Árbol Fino (IPPT)(Test).*

True Class	0	80.5%	0.3%	0.0%	34.6%			0.3%	0.1%
	1	0.3%	95.9%	0.1%	0.2%		0.0%		6.3%
	2			96.7%		0.0%			1.1%
	3	18.6%	0.1%	0.0%	64.7%			0.3%	0.0%
	4	0.0%	0.0%	0.0%		99.9%			0.2%
	5		0.4%	2.7%		0.0%	100.0%		30.9%
	6	0.6%	0.0%		0.5%			99.4%	0.0%
	7	0.0%	3.3%	0.5%	0.0%				61.5%

*Ilustración 61: Matriz de confusión Árbol Medio (MPPT)(Test).*

True Class	0	74.8%	0.2%	11.5%				6.6%	18.1%
	1	0.8%	93.0%	9.0%	0.5%			10.6%	17.2%
	2	2.9%	2.6%	57.5%	0.0%			10.1%	0.0%
	3	4.2%	0.1%	8.7%	99.3%			14.7%	
	4	0.0%	0.3%	0.1%		100.0%		0.1%	
	5	4.2%	0.1%	5.1%	0.0%		100.0%	12.3%	
	6	3.2%	0.2%	1.8%	0.0%			28.1%	2.9%
	7	9.8%	3.4%	6.4%	0.0%			17.6%	61.8%

*Ilustración 62: Matriz de confusión Árbol Medio (IPPT)(Test).*

True Class	0	66.4%		0.0%				0.6%	0.2%
	1	0.3%		26.1%		0.7%			28.0%
	2			69.4%		0.1%			0.8%
	3	32.7%		0.0%				0.8%	0.1%
	4	0.0%		0.0%		74.1%			0.1%
	5	0.1%		4.2%		25.1%		10.3%	23.3%
	6	0.6%						88.4%	0.0%
	7	0.0%		0.4%		0.1%			47.6%

*Il·lustració 63: Matriz de confusión Árbol Grueso (MPPT)(Test).*

True Class	0			0.3%	21.4%		0.0%	19.6%	
	1			40.8%	3.8%		0.0%	9.4%	
	2			46.7%	7.7%		0.1%	10.0%	
	3			9.7%	36.7%		0.0%	12.2%	
	4			0.2%		100.0%		0.0%	
	5			0.2%	8.3%	0.0%	99.9%	9.8%	
	6			0.2%	14.4%		0.0%	19.6%	
	7			1.8%	7.7%		0.0%	19.3%	

*Il·lustració 64: Matriz de confusión Árbol Grueso (IPPT)(Test).*

0	98.9%	0.2%	0.0%	1.5%		0.0%	0.1%	0.0%
1	0.2%	98.7%	0.0%	0.0%	0.0%	0.4%		0.4%
2	0.0%	0.0%	99.1%		0.0%	0.6%		0.1%
3	0.7%	0.1%	0.0%	98.2%		0.0%	0.1%	0.0%
4			0.0%		100.0%			0.0%
5	0.0%	0.4%	0.7%	0.0%		98.0%		0.9%
6	0.1%	0.0%		0.3%		0.0%	99.8%	0.0%
7	0.0%	0.5%	0.2%	0.0%	0.0%	1.0%	0.0%	98.6%

*Ilustración 65: Matriz de confusión Árbol Optimizado (MPPT)(Test).*

0	97.1%	0.2%	0.6%	0.6%	0.0%	1.3%	0.1%	0.2%
1	0.2%	96.8%	0.5%	0.5%		0.2%	0.4%	1.1%
2	0.6%	0.7%	97.3%	1.0%		0.5%	0.4%	0.4%
3	0.4%	0.5%	0.5%	95.4%		0.8%	0.5%	0.4%
4	0.0%	0.0%	0.0%	0.0%	100.0%	0.0%	0.0%	0.0%
5	1.3%	0.2%	0.4%	1.1%		96.9%	0.1%	0.1%
6	0.1%	0.5%	0.2%	0.8%	0.0%	0.1%	96.8%	1.8%
7	0.2%	1.1%	0.4%	0.5%		0.1%	1.6%	96.0%

*Ilustración 66: Matriz de confusión Árbol Optimizado (IPPT)(Test).*

Ahora ya podemos validar que los test han salido como esperábamos. Los valores de las técnicas que tenían precisión baja se han mantenido igual o incluso han bajado, mientras que el árbol optimizado ha aumentado su precisión, asegurándonos aún más que es un muy buen modelo para utilizar en ambos métodos.

### 5.2.2. Análisis discriminante (Test)

En segundo lugar, vamos a ver como sale el entrenamiento del análisis discriminante lineal y cuadrático.



Técnica (MPPT)	Precisión (Test)
Linear	52,3 %
Cuadrático	78,1 %

*Tabla 11: Precisión de análisis discriminante (MPPT)(Test).*

Técnica (IPPT)	Precisión (Test)
Linear	43,1 %
Cuadrático	62,0 %

*Tabla 12: Precisión de análisis discriminante (IPPT)(Test).*

True Class	0	65.5%	0.1%	0.0%	36.6%	0.0%	0.6%	0.1%	
	1	3.5%	84.2%	0.0%	5.2%	1.9%		26.4%	
	2		1.5%	97.2%	2.6%	0.1%		0.9%	
	3	29.9%	3.1%	0.0%	35.2%	0.8%	1.6%	0.0%	
	4		0.5%	0.1%	4.0%	100.0%	1.0%		
	5	0.1%	8.8%	2.1%	5.1%		96.0%	24.0%	
	6	0.8%	0.5%		8.3%		0.1%	97.8%	0.0%
	7	0.2%	1.4%	0.5%	3.0%	0.0%	0.1%		48.6%

*Ilustración 67: Matriz de confusión Análisis Discriminante Linear (MPPT)(Test).*

True Class	0	41.4%	9.8%	12.3%	0.0%	0.1%		15.8%	14.6%
	1	5.6%	21.3%	14.1%	0.0%	0.0%	0.0%	14.0%	15.0%
	2	6.9%	13.4%	34.5%	0.3%	1.3%	0.0%	6.3%	21.0%
	3	4.9%	14.7%	9.9%	99.0%	0.0%	0.0%	8.4%	12.7%
	4	0.0%	0.0%	0.0%		98.2%		0.0%	0.0%
	5	5.1%	12.1%	8.1%		0.4%	99.9%	4.8%	11.4%
	6	14.8%	13.4%	10.0%	0.5%	0.0%		29.0%	10.7%
	7	21.2%	15.2%	11.1%	0.1%	0.0%	0.1%	21.6%	14.5%

*Ilustración 68: Matriz de confusión Análisis Discriminante Linear (IPPT)(Test).*



0	66.8%	0.1%	0.0%	22.8%		0.1%	0.7%	0.1%
1	2.2%	94.9%	0.1%	3.1%		0.4%		27.2%
2		0.7%	95.9%	2.0%		1.2%		0.3%
3	30.6%	0.2%	0.0%	55.4%		0.2%	1.0%	0.0%
4		1.1%	0.1%	2.4%	100.0%	1.2%		
5	0.0%	1.5%	3.6%	3.3%		95.3%		23.2%
6	0.3%	0.3%		8.6%		0.9%	98.4%	0.0%
7	0.1%	1.4%	0.4%	2.3%		0.8%		49.1%

*Il·lustració 69: Matriz de confusió del Análisis Discriminante cuadrático (MPPT)(Test).*

0	56.1%	0.9%	2.9%	2.5%		0.3%	1.6%	3.4%
1	1.6%	69.3%	5.4%	3.0%		0.4%	6.7%	17.5%
2	7.6%	7.6%	78.0%	2.0%		0.4%	3.1%	18.2%
3	7.7%	5.9%	2.9%	84.4%		0.3%	16.4%	12.0%
4					100.0%	1.8%		
5	9.7%	1.1%	2.7%	1.5%		96.1%	12.6%	6.7%
6	3.7%	2.3%	3.4%	4.3%		0.3%	40.7%	9.5%
7	13.7%	12.9%	4.7%	2.3%		0.4%	18.9%	32.7%

*Il·lustració 70: Matriz de confusió del Análisis Discriminante cuadrático (IPPT)(Test).*

La tabla nos muestra como aquí ha disminuido la precisión de los métodos, esto nos indica que estos algoritmos no son demasiado buenos para una utilización práctica real en ninguno de los dos métodos.

### 5.2.3. Clasificador Naives Bayes (Test)

Seguidamente, vamos a ver los resultados de los test en los métodos de Naive Bayes.



Técnica (MPPT)	Precisión (Test)
Gaussian	77,7 %

*Tabla 13: Precisión de los clasificadores Naives Bayes (MPPT)(Test).*

Técnica (MPPT)	Precisión (Test)
Gaussian	57,8 %

*Tabla 14: Precisión de los clasificadores Naives Bayes (IPPT)(Test).*

True Class	0	65.5%	0.1%	0.0%	36.6%	0.0%	0.6%	0.1%	
	1	3.5%	84.2%	0.0%	5.2%	1.9%		26.4%	
	2		1.5%	97.2%	2.6%	0.1%		0.9%	
	3	29.9%	3.1%	0.0%	35.2%	0.8%	1.6%	0.0%	
	4		0.5%	0.1%	4.0%	100.0%	1.0%		
	5	0.1%	8.8%	2.1%	5.1%		96.0%	24.0%	
	6	0.8%	0.5%		8.3%		0.1%	97.8%	0.0%
	7	0.2%	1.4%	0.5%	3.0%	0.0%	0.1%		48.6%

*Ilustración 71: Matriz de confusión para "Gaussian Naive Bayes" (MPPT)(Test).*

True Class	0	51.1%	3.3%	3.6%	1.2%		0.2%	4.0%	6.9%
	1	2.2%	56.5%	7.3%	1.4%		0.2%	6.5%	13.0%
	2	3.6%	8.2%	74.9%	1.9%		0.3%	6.5%	35.9%
	3	9.4%	6.9%	2.6%	91.3%		0.2%	15.4%	10.1%
	4					100.0%	2.6%		
	5	8.4%	2.9%	2.4%	1.5%		96.0%	13.0%	7.1%
	6	6.9%	5.7%	3.9%	1.5%		0.2%	36.5%	6.1%
	7	18.3%	16.6%	5.3%	1.2%		0.2%	18.1%	20.9%

*Ilustración 72: Matriz de confusión para "Gaussian Naive Bayes" (IPPT)(Test).*

En este caso, tanto la validación como el test salen muy parecidos, obteniendo una precisión no muy alta.

## 5.2.4. Nearest Neighbor Classifier (Test)

A continuación, podemos ver los resultados del test para las técnicas de KNN. Cabe recordar que la precisión de estas será más alta debido a que ya han sido entrenadas.

Técnica (MPPT)	Precisión (Test)
Fine KNN	99,2 %
Medium KNN	98,3 %
Cubic KNN	97,7 %
Weighted KNN	98,9 %

*Tabla 15: Precisión de los clasificadores KNN (MPPT)(Test).*

Técnica	Precisión
Fine KNN	98,4 %
Medium KNN	97,0 %
Cubic KNN	96,0 %
Weighted KNN	97,7 %

*Tabla 16: Precisión de los clasificadores KNN (IPPT)(Test).*

Abajo vamos a mostrar las matrices de confusión de todas las técnicas de KNN, como podemos ver en la tabla anterior, la técnica Fine KNN sigue siendo la más precisa de todas.

True Class	0	98.4%	0.4%	0.0%	1.8%	0.0%	0.0%	0.2%	0.1%
	1	0.4%	98.2%	0.0%	0.2%		0.3%	0.0%	0.8%
	2		0.0%	99.1%		0.0%	0.7%		0.0%
	3	1.0%	0.1%	0.0%	97.2%		0.1%	0.1%	0.0%
	4		0.0%	0.0%		99.9%	0.0%		0.0%
	5	0.0%	0.2%	0.8%	0.1%	0.0%	98.8%		0.1%
	6	0.2%	0.0%	0.0%	0.7%	0.0%	0.0%	99.7%	0.0%
	7	0.1%	0.9%	0.1%	0.0%	0.0%	0.2%	0.0%	99.0%

*Ilustración 73: Matriz de confusión Fine KNN (MPPT)(Test).*

True Class	0	98.2%	0.2%	0.1%	0.1%		0.2%	0.1%	0.2%
	1	0.2%	97.9%	0.2%	0.1%		0.1%	0.2%	0.1%
	2	1.1%	1.0%	99.0%	1.3%		0.8%	0.5%	0.6%
	3	0.0%	0.2%	0.3%	95.1%		0.2%	2.0%	0.4%
	4					100.0%			
	5	0.1%	0.1%	0.1%	0.4%		98.6%	0.2%	0.0%
	6	0.1%	0.3%	0.1%	2.4%		0.1%	96.2%	0.6%
	7	0.2%	0.3%	0.1%	0.7%		0.0%	0.8%	98.0%

*Il·lustració 74: Matriz de confusión Fine KNN (IPPT)(Test).*

True Class	0	95.9%	0.6%	0.0%	3.1%	0.1%	0.1%	0.3%	0.1%
	1	0.8%	96.3%	0.1%	0.5%	0.0%	0.4%	0.0%	1.0%
	2	0.0%	0.1%	97.9%	0.0%	0.1%	0.9%		0.1%
	3	2.8%	0.3%	0.0%	94.7%	0.0%	0.1%	0.3%	0.0%
	4		0.0%	0.0%		99.7%	0.0%	0.0%	0.0%
	5	0.1%	0.7%	1.7%	0.3%	0.0%	97.9%		0.2%
	6	0.4%	0.0%	0.0%	1.4%	0.1%	0.0%	99.4%	0.0%
	7	0.1%	1.9%	0.3%	0.0%	0.0%	0.6%	0.0%	98.6%

*Il·lustració 75: Matriz de confusión Medium KNN (MPPT)(Test).*



True Class	0	96.0%	0.4%	0.1%	0.1%		0.2%	0.3%	0.4%
	1	0.4%	95.6%	0.2%	0.3%		0.2%	0.4%	0.2%
	2	2.4%	2.6%	99.0%	2.7%		1.5%	1.0%	1.2%
	3	0.1%	0.4%	0.2%	90.4%		0.4%	3.0%	0.7%
	4					100.0%			
	5	0.4%	0.2%	0.3%	0.8%		97.2%	0.4%	0.1%
	6	0.2%	0.4%	0.0%	4.5%		0.2%	92.9%	1.0%
	7	0.5%	0.5%	0.1%	1.3%		0.2%	2.0%	96.5%

*Il·lustració 76: Matriz de confusión Medium KNN (IPPT)(Test).*

True Class	0	94.8%	0.7%	0.0%	4.2%	0.1%	0.1%	0.5%	0.1%
	1	0.8%	95.2%	0.1%	0.6%	0.0%	0.6%	0.0%	1.5%
	2	0.0%	0.1%	97.3%	0.0%	0.1%	1.2%		0.2%
	3	3.5%	0.3%	0.0%	92.8%	0.0%	0.1%	0.4%	0.0%
	4	0.0%	0.0%	0.0%	0.0%	99.7%	0.0%	0.0%	0.0%
	5	0.1%	1.0%	2.1%	0.3%	0.0%	97.2%		0.2%
	6	0.6%	0.0%	0.0%	2.0%	0.1%	0.0%	99.2%	0.0%
	7	0.2%	2.6%	0.4%	0.1%	0.0%	0.7%	0.0%	98.0%

*Il·lustració 77: Matriz de confusión Cubic KNN (MPPT)(Test).*

True Class	0	94.9%	0.4%	0.2%	0.1%		0.3%	0.3%	0.5%
	1	0.5%	95.2%	0.5%	0.5%		0.3%	0.4%	0.3%
	2	2.5%	2.5%	98.1%	2.8%		1.7%	1.1%	1.5%
	3	0.2%	0.5%	0.4%	87.4%		0.7%	4.0%	1.2%
	4					100.0%			
	5	0.5%	0.3%	0.4%	1.3%		96.3%	0.5%	0.1%
	6	0.4%	0.4%	0.2%	5.8%		0.5%	91.1%	1.5%
	7	0.9%	0.6%	0.2%	2.1%		0.2%	2.6%	94.9%

*Ilustración 78: Matriz de confusión Cubic KNN (IPPT)(Test).*

True Class	0	97.8%	0.5%	0.0%	2.5%	0.0%	0.0%	0.3%	0.1%
	1	0.4%	97.7%	0.1%	0.3%	0.0%	0.3%	0.0%	0.9%
	2	0.0%	0.0%	98.8%	0.0%	0.1%	0.7%		0.1%
	3	1.5%	0.2%	0.0%	96.2%	0.0%	0.1%	0.2%	0.0%
	4		0.0%	0.0%		99.8%	0.0%		0.0%
	5	0.0%	0.4%	0.9%	0.1%	0.0%	98.5%		0.1%
	6	0.2%	0.0%	0.0%	0.9%	0.0%	0.0%	99.5%	0.0%
	7	0.1%	1.2%	0.2%	0.0%	0.0%	0.3%	0.0%	98.8%

*Ilustración 79: Matriz de confusión Weighted KNN (MPPT)(Test).*

True Class	0	97.1%	0.3%	0.1%	0.1%		0.2%	0.2%	0.2%
	1	0.2%	96.6%	0.2%	0.2%		0.2%	0.3%	0.1%
	2	1.7%	1.8%	99.2%	2.2%		1.4%	0.8%	1.1%
	3	0.1%	0.4%	0.2%	94.0%		0.3%	2.6%	0.5%
	4					100.0%			
	5	0.3%	0.1%	0.2%	0.4%		97.8%	0.3%	0.0%
	6	0.2%	0.3%	0.1%	2.4%		0.2%	94.7%	0.9%
	7	0.4%	0.4%	0.1%	0.7%		0.1%	1.1%	97.1%

*Ilustración 80: Matriz de confusión Weighted KNN (IPPT)(Test).*

Analizando los datos que nos aportan las matrices de confusión de todas estas técnicas, corroboramos que estamos ante las mejores técnicas de todas las que hemos probado, ya sea para IPPT o para MPPT, en particular el método “Fine KNN” tiene una gran precisión en los dos modos. Todos los algoritmos están por encima del 90 % y esto nos hace ver que son las mejores opciones para la utilización en la práctica. Estas técnicas son las únicas que permiten predecir con un porcentaje muy alto los fallos 6 y 7 en el caso de IPPT y el fallo 3 en el caso de MPPT, así pues, podemos decir que son la que mejor han encontrado sus patrones ocultos.



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny



## 6. PRESUPUESTO

A continuación, presento mi presupuesto estimado para el desarrollo del algoritmo de inteligencia artificial para la detección y diagnóstico preventivo de placas fotovoltaicas mediante Matlab. Este presupuesto se basa en los servicios y costos del proyecto, los cuales lo detallan los siguientes factores:

- Costos de materiales y suministros
- Recursos humanos
- Licencias y software
- Otros gastos

El presupuesto total vendrá dado por la suma de todos los factores que han hecho posible el proyecto. En los siguientes puntos trataremos el valor de cada factor individualizado y por último sumaremos todos los costos para hacer un presupuesto final.

### 6.1. COSTOS DE MATERIALES Y SUMINISTROS

Esta sección es la sección que menos involucra en el diseño del algoritmo, ya que, en nuestro caso, hemos cogido los datos de una base de datos cuyo experimento ya estaba hecho, esto hace que se reduzca en gran cantidad el valor del presupuesto. No obstante, en este apartado podemos incluir el costo de la computadora que estemos utilizando, debido a que es el único material que hemos utilizado. En mi caso esta computadora es un HP Notebook Intel(R) Core (TM) i5-7200U CPU @ 2.50GHz 2.70 GHz. Este ordenador tiene ya un tiempo, así que vamos a suponer la mitad de su valor de compra.

Recursos de materiales y suministros	Cantidad (ud)	Coste Unitario (€/ud)	Coste Total (€)
Ordenador	1	239,5	239,5
<b>Total</b>			239,5

*Tabla 17: Presupuesto de recursos materiales.*

## 6.2. RECURSOS HUMANOS

Esta sección es la más costosa en nuestro caso, ya que nuestro trabajo requiere de muchas horas de diseño, las cuales son bastante caras, por el hecho de que son horas de trabajo de ingenieros. Aquí podemos encontrar dos gastos, el gasto del ingeniero y el del ingeniero supervisor, el cual será más caro debido a que es el que se encarga de dirigir y guiar al ingeniero. Además, es el responsable del proyecto, es decir, es el que tiene que responder ante cualquier situación adversa.

Por otro lado, las horas las hemos cuantificado por los créditos (cada crédito son 25h), así pues, las horas totales del ingeniero han sido 300. No obstante, las horas de ingeniero supervisor se han estimado en 20. En la tabla que vemos a continuación podemos encontrar los presupuestos de esta sección.

Recursos Humanos	Cantidad (h)	Coste Unitario (€/h)	Coste Total (€)
Ingeniero supervisor	20	32,5	650
Ingeniero	300	15,8	4.740
<b>Total</b>			5.390

*Tabla 18: Presupuesto de recursos humanos.*

### 6.3. LICENCIAS Y SOFTWARE

Esta es la segunda parte más importante de nuestro presupuesto, y esto es debido a las licencias de Matlab y Microsoft Office. Estas dos son nuestras herramientas principales y con las cuales no podríamos haber hecho nada. Hemos escogido los precios para uso particular, cabe recalcar que Matlab tiene paquetes de herramientas (Toolbox) que añade valor a este presupuesto. La siguiente tabla muestra el valor anual de las licencias, las cuales son el presupuesto de este apartado.

Licencias y software	Cantidad (ud)	Coste Unitario (€/ud)	Coste Total (€)
Matlab	1	119	119
Machine learning toolbox	1	35	35
Microsoft Office Personal	1	69	69
<b>Total</b>			223

*Tabla 19: Presupuesto de licencias y software.*

### 6.4. OTROS

En esta sección se incluyen gastos relacionados con el transporte, comida y adversidades que se hayan tenido. En este proyecto se van a incluir los transportes para las reuniones, tanto la comida que se utilizó en cada reunión. Esta parte del presupuesto es la menos relevante, ya que para este proyecto no ha habido reuniones presenciales.

Otros	Cantidad (ud)	Coste Unitario (€/ud)	Coste Total (€)
Trayectos	2	5	10
<b>Total</b>			10

*Tabla 20: Presupuesto de gastos varios.*

## 6.5. PRESUPUESTO FINAL

El presupuesto final es la suma de todas las partes añadiendo el impuesto sobre el valor añadido (IVA) correspondiente que habrá que sumar para obtener el presupuesto total del proyecto.

<b>Cote total del proyecto</b>	
<b>Costos de Materiales y Suministros</b>	239,5 €
<b>Recursos Humanos</b>	5390 €
<b>Licencias y software</b>	223 €
<b>Otros</b>	10 €
<b>Sub-Total</b>	5.862,5 €
<b>IVA (21 %)</b>	1.231,125 €
<b>Total Presupuestado</b>	7.093,63 €

*Tabla 21: Presupuesto total del proyecto.*



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

## 7. CONCLUSIONES Y POSIBLES MEJORAS

### 7.1. CONCLUSIONES

Tras analizar diferentes modelos de predicción de fallos, podemos concluir que la técnica de clasificación más eficaz en general es el método K Nearest Neighbours (KNN), con una precisión de hasta el 99,2% en el modo de MPPT y de 98,4% para IPPT. Dentro de esta técnica, el modelo Fino destaca como el mejor predictor de fallos, debido principalmente a su menor valor k en comparación con otros modelos, que permite clasificar mejor los parámetros y las características ocultas que tiene nuestra señal.

El enfoque KNN se basa en comparar la similitud de los parámetros actuales con los parámetros de sus vecinos más próximos. Esta técnica es eficaz para detectar cambios significativos en los valores de los vecinos más próximos, lo que indica la presencia de un fallo.

Además, también se observa que el árbol de decisión optimizado es una opción muy robusta, con una precisión del 99,2% (MPPT) y 97,1% (IPPT). Esta técnica es muy eficaz gracias a su capacidad para optimizar los cálculos de los parámetros y mejorar la calidad de las predicciones.

En cambio, el enfoque del árbol de decisión amplio no es eficaz como predictor en este caso, ya que abarca demasiados parámetros a la vez, lo que no es óptimo dadas nuestras circunstancias. Por otra parte, el análisis discriminante lineal tampoco es un buen predictor, puesto que es poco flexible ante las numerosas características de nuestro problema.

En cuanto a los fallos, los fallos F4, F5 y F3 son los más fáciles de detectar, ya que sus valores se alteran significativamente cuando se producen fallos. Esto es muy beneficioso, por el hecho de que estos fallos son problemáticos y pueden causar daños irreversibles o incluso incendios en la instalación. Por ejemplo, F4 implica un sombreado parcial, lo que representa un alto riesgo de daños en la placa y la posibilidad de un incendio. Sin embargo, los fallos relacionados con los parámetros del controlador PI, es decir, F6 y F7, son los más difíciles de diagnosticar. Esto es de esperar, ya que sus gráficos difieren muy poco del funcionamiento normal. Sin embargo, este tipo de fallo solo provoca una reducción de la eficiencia y no puede causar daños al sistema fotovoltaico, por lo que se considera un problema menor.

Cabe mencionar que hay métodos que no se han podido utilizar debido al coste computacional, esto es un punto para mejorar, ya que se puede utilizar una computadora más potente o incluso un manejo de los datos diferente.

En conclusión, podemos decir que el diseño y análisis de nuestro proyecto ha sido bastante exitoso y se han conseguido desarrollar métodos bastante precisos. A pesar de su coste computacional y coste de diseño, esta es una solución muy conveniente para incluir en los sistemas fotovoltaicos para prevenir daños irreparables. También podemos concluir que esta implementación logra una mejora de rendimiento y eficiencia en la tecnología de la energía solar, y es una opción muy a tener en cuenta en instalaciones fotovoltaicas costosas, las cuales tiene que tener una gran protección debido a su gran costo.

## 7.2. FUTURAS MEJORAS

- **técnicas más avanzadas:** Se podría hacer un estudio con técnicas más avanzadas, aunque computacionalmente más costosas. En este caso habría que hacer un estudio para utilizar técnicas lo suficientemente precisas, pero controlando el coste computacional.
- **Sistema de alertas y notificaciones:** Otra opción de mejora es implementar un sistema de alertas para cuando se recaude la información de un sistema fotovoltaico y surja un fallo poder enviar un operario rápidamente. Esto evitaría muchos fallos y es una de las mejoras más económicas que surgen del proyecto.
- **Integrar sensores térmicos:** Una muy buena opción es añadir cámaras térmicas u otro tipo de sensores que nos den más información sobre las celdas solares y el porcentaje de precisión pueda incrementar. Esta propuesta es menos económica, pero puede aumentar significativamente la precisión de los algoritmos.
- **Realizar análisis en tiempo real:** Esta solución puede venir en conjunto con el sistema de alarma y notificaciones para así poder incrementar el tiempo de respuesta ante cualquier fallo. Esto puede reducir los costes de reparación y daños, ya que, una rápida intervención ante un fallo grave evita daños irreversibles o posibles incendios.
- **Implementar mantenimiento proactivo:** Esto consiste en desarrollar un algoritmo que estudie y analice patrones y tendencias para que prediga cuando una placa va a tener un fallo la placa y para que informe sobre cuánto tiempo de vida útil le queda al panel solar. Esto hace que se pueda reemplazar la placa cuando se considere que ya no es lo suficientemente eficiente para nuestro sistema.

Esto son tan solo unos cuantos campos de mejora de este proyecto, pero hay muchos más y puede haber muchas combinaciones con otras tecnologías o aplicaciones en otro campo. Este proyecto demuestra que es muy importante investigar en energías renovables y que aún hay mucho margen de mejora y aún más con la creciente capacidad computacional y los últimos desarrollos en inteligencia artificial.





## 8. MANUAL DEL USUARIO

### 8.1. OBTENCIÓN DE LOS DATOS

En primer lugar, vamos a extraer los datos proporcionados por el artículo [1]. Para ello debemos incluir en Matlab estos comandos. La extracción de los datos se hace de igual forma para IPPT que para MPPT, con la única diferencia que hay que poner el nombre de los archivos según el modo ('F0L.mat' para IPPT, 'F0M.mat' para MPPT). Una vez extraído los datos de los ficheros mat debemos guardar cada variable correspondiente a su nombre como mostramos a continuación.

```
%% En primer lugar, borramos todas las variables para evitar posibles
%%fallos
clear all;
clc, close all;
%% En segundo, lugar cargamos los datos .mat a las variables Datos0, 1....
% Esta forma de cargar los datos es la misma que para MPPT solo cambiando
% la L por la M.
Datos0 = load('F0L.mat');
Datos1 = load('F1L.mat');
Datos2 = load('F2L.mat');
Datos3 = load('F3L.mat');
Datos4 = load('F4L.mat');
Datos5 = load('F5L.mat');
Datos6 = load('F6L.mat');
Datos7 = load('F7L.mat');
%% En tercer lugar, extraemos de las variables Datos, cada señal
Tiempo0 = Datos0.F0L.Time;
Tiempo1 = Datos1.F1L.Time;
Tiempo2 = Datos2.F2L.Time;
Tiempo3 = Datos3.F3L.Time;
Tiempo4 = Datos4.F4L.Time;
Tiempo5 = Datos5.F5L.Time;
Tiempo6 = Datos6.F6L.Time;
Tiempo7 = Datos7.F7L.Time;
Ipv0 = Datos0.F0L.Ipv;
Ipv1 = Datos1.F1L.Ipv;
Ipv2 = Datos2.F2L.Ipv;
Ipv3 = Datos3.F3L.Ipv;
Ipv4 = Datos4.F4L.Ipv;
Ipv5 = Datos5.F5L.Ipv;
Ipv6 = Datos6.F6L.Ipv;
Ipv7 = Datos7.F7L.Ipv;
Vpv0 = Datos0.F0L.Vpv;
Vpv1 = Datos1.F1L.Vpv;
Vpv2 = Datos2.F2L.Vpv;
Vpv3 = Datos3.F3L.Vpv;
Vpv4 = Datos4.F4L.Vpv;
Vpv5 = Datos5.F5L.Vpv;
Vpv6 = Datos6.F6L.Vpv;
Vpv7 = Datos7.F7L.Vpv;
```



```
Vdc0 = Datos0.F0L.Vdc;  
Vdc1 = Datos1.F1L.Vdc;  
Vdc2 = Datos2.F2L.Vdc;  
Vdc3 = Datos3.F3L.Vdc;  
Vdc4 = Datos4.F4L.Vdc;  
Vdc5 = Datos5.F5L.Vdc;  
Vdc6 = Datos6.F6L.Vdc;  
Vdc7 = Datos7.F7L.Vdc;  
Iabc0 = Datos0.F0L.Iabc;  
Iabc1 = Datos1.F1L.Iabc;  
Iabc2 = Datos2.F2L.Iabc;  
Iabc3 = Datos3.F3L.Iabc;  
Iabc4 = Datos4.F4L.Iabc;  
Iabc5 = Datos5.F5L.Iabc;  
Iabc6 = Datos6.F6L.Iabc;  
Iabc7 = Datos7.F7L.Iabc;  
Vabc0 = Datos0.F0L.Vabc;  
Vabc1 = Datos1.F1L.Vabc;  
Vabc2 = Datos2.F2L.Vabc;  
Vabc3 = Datos3.F3L.Vabc;  
Vabc4 = Datos4.F4L.Vabc;  
Vabc5 = Datos5.F5L.Vabc;  
Vabc6 = Datos6.F6L.Vabc;  
Vabc7 = Datos7.F7L.Vabc;  
If0 = Datos0.F0L.If;  
If1 = Datos1.F1L.If;  
If2 = Datos2.F2L.If;  
If3 = Datos3.F3L.If;  
If4 = Datos4.F4L.If;  
If5 = Datos5.F5L.If;  
If6 = Datos6.F6L.If;  
If7 = Datos7.F7L.If;  
Vf0 = Datos0.F0L.Vf;  
Vf1 = Datos1.F1L.Vf;  
Vf2 = Datos2.F2L.Vf;  
Vf3 = Datos3.F3L.Vf;  
Vf4 = Datos4.F4L.Vf;  
Vf5 = Datos5.F5L.Vf;  
Vf6 = Datos6.F6L.Vf;  
Vf7 = Datos7.F7L.Vf;
```

Una vez guardadas todas las variables con sus respectivos nombres, el siguiente paso es crear etiquetas para cada fallo y concatenarlas horizontalmente en una matriz para cada fallo. Por último, uniremos todas las matrices de todos los fallos verticalmente y crearemos una matriz con todos datos relevantes que serán los que incluyamos en la aplicación del Classification Learner.



```
%% En cuarto lugar creamos las etiquetas de cada fallo
Vector0(1:length(Ipv0)) = 0;
Vector1(1:length(Ipv1)) = 1;
Vector2(1:length(Ipv2)) = 2;
Vector3(1:length(Ipv3)) = 3;
Vector4(1:length(Ipv4)) = 4;
Vector5(1:length(Ipv5)) = 5;
Vector6(1:length(Ipv6)) = 6;
Vector7(1:length(Ipv7)) = 7;
% Ahora creamos las matrices de todas las variables y la etiqueta de cada
%fallo
y0 = [Tiempo0 Ipv0 Vpv0 Vdc0 Iabc0 Vabc0 Vf0 If0 Vector0'];
y1 = [Tiempo1 Ipv1 Vpv1 Vdc1 Iabc1 Vabc1 Vf1 If1 Vector1'];
y2 = [Tiempo2 Ipv2 Vpv2 Vdc2 Iabc2 Vabc2 Vf2 If2 Vector2'];
y3 = [Tiempo3 Ipv3 Vpv3 Vdc3 Iabc3 Vabc3 Vf3 If3 Vector3'];
y4 = [Tiempo4 Ipv4 Vpv4 Vdc4 Iabc4 Vabc4 Vf4 If4 Vector4'];
y5 = [Tiempo5 Ipv5 Vpv5 Vdc5 Iabc5 Vabc5 Vf5 If5 Vector5'];
y6 = [Tiempo6 Ipv6 Vpv6 Vdc6 Iabc6 Vabc6 Vf6 If6 Vector6'];
y7 = [Tiempo7 Ipv7 Vpv7 Vdc7 Iabc7 Vabc7 Vf7 If7 Vector7'];
% Por ultimo, concatenamos todos los vectores verticalmente
y = vertcat(y0, y1, y2, y3, y4, y5, y6, y7);
```

## 8.2. VISUALIZACIÓN DE LAS SEÑALES

Esta primera parte es igual para los dos modos y para todos los fallos, y solo se centra en quitar la variable de tiempo para poder incluir los datos en la función 'plot()'.

```
%% Preparación de los datos para la visualización
y0_a = [Ipv0 Vpv0 Vdc0 Iabc0 Vabc0 Vf0 If0];
y1_a = [Ipv1 Vpv1 Vdc1 Iabc1 Vabc1 Vf1 If1];
y2_a = [Ipv2 Vpv2 Vdc2 Iabc2 Vabc2 Vf2 If2];
y3_a = [Ipv3 Vpv3 Vdc3 Iabc3 Vabc3 Vf3 If3];
y4_a = [Ipv4 Vpv4 Vdc4 Iabc4 Vabc4 Vf4 If4];
y5_a = [Ipv5 Vpv5 Vdc5 Iabc5 Vabc5 Vf5 If5];
y6_a = [Ipv6 Vpv6 Vdc6 Iabc6 Vabc6 Vf6 If6];
y7_a = [Ipv7 Vpv7 Vdc7 Iabc7 Vabc7 Vf7 If7];
```

Ahora visualizamos cada fallo de la misma forma que antes, el código es el mismo par ambos modos:

```
%% Analisis de la señal de F1
h = plot(Tiempo1, y1_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf (Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F1M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C1 = h(1);
C2 = h(2);
C3 = h(3);
C4 = h(4);
C7 = h(7);
% Cambiar el diseño de línea solo para las columnas
set(C1, 'LineWidth', 2, 'LineStyle', '--');
set(C2, 'LineWidth', 2, 'LineStyle', '--');
set(C3, 'LineWidth', 2, 'LineStyle', '--');
set(C4, 'LineWidth', 2, 'LineStyle', '--');
set(C7, 'LineWidth', 2, 'LineStyle', '--');
%% Analisis de la señal de F2
h = plot(Tiempo2, y2_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf (Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F2M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C2 = h(2);
C3 = h(3);
% Cambiar el diseño de línea solo para las columnas
set(C2, 'LineWidth', 2, 'LineStyle', '--');
set(C3, 'LineWidth', 2, 'LineStyle', '--');
```



```
%% Analisis de la señal de F3
h = plot(Tiempo3, y3_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf
(Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F3M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C3 = h(3);
C4 = h(4);
C7 = h(7);
% Cambiar el diseño de línea solo para las columnas
set(C3, 'LineWidth', 2, 'LineStyle', '--');
set(C4, 'LineWidth', 2, 'LineStyle', '--');
set(C7, 'LineWidth', 2, 'LineStyle', '--');
%% Analisis de la señal de F4
h = plot(Tiempo4, y4_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf
(Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F4M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C1 = h(1);
C2 = h(2);
C4 = h(4);
% Cambiar el diseño de línea solo para las columnas
set(C1, 'LineWidth', 2, 'LineStyle', '--');
set(C2, 'LineWidth', 2, 'LineStyle', '--');
set(C4, 'LineWidth', 2, 'LineStyle', '--');

%% Analisis de la señal de F5
h = plot(Tiempo5, y5_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf
(Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F5M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C1 = h(1);
C2 = h(2);
C3 = h(3);
C4 = h(4);
C7 = h(7);
% Cambiar el diseño de línea solo para las columnas
set(C1, 'LineWidth', 2, 'LineStyle', '--');
set(C2, 'LineWidth', 2, 'LineStyle', '--');
set(C3, 'LineWidth', 2, 'LineStyle', '--');
set(C4, 'LineWidth', 2, 'LineStyle', '--');
set(C7, 'LineWidth', 2, 'LineStyle', '--');
```

```
% Analisis de la señal de F6
h = plot(Tiempo6, y6_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf
(Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F6M')
xlabel('Tiempo (s)');
% Obtener el objeto de línea correspondiente cada columna
C3 = h(3);
% Cambiar el diseño de línea solo para las columnas
set(C3, 'LineWidth', 2, 'LineStyle', '--');
% Analisis de la señal de F7
h = plot(Tiempo7, y7_a);
legend('Ipv (A)', 'Vpv (V)', 'Vdc (V)', 'Iabc (A)', 'Vabc (V)', 'Vf
(Hz)', 'If (HZ)');
title('Señal para el funcionamiento del fallo F6M')
xlabel('Tiempo (s)');
```

Lo que hemos hecho con estas señales es graficarlas mediante el comando plot() y obtener en la variable 'h' cada gráfica de cada señal. A partir de eso, después, mediante el comando set, podemos incluirle nosotros los cambios que queramos para que se muestre más gorda la línea y se diferencie de las otras. Cabe recordar que este código vale para ambos métodos, solo habría que cambiar la L por la M en la obtención de los datos.

### 8.3. CLASSIFICATION LEARNER

En primer lugar, tenemos que abrir la aplicación de Matlab “Classification Learner” en el apartado de app’s.

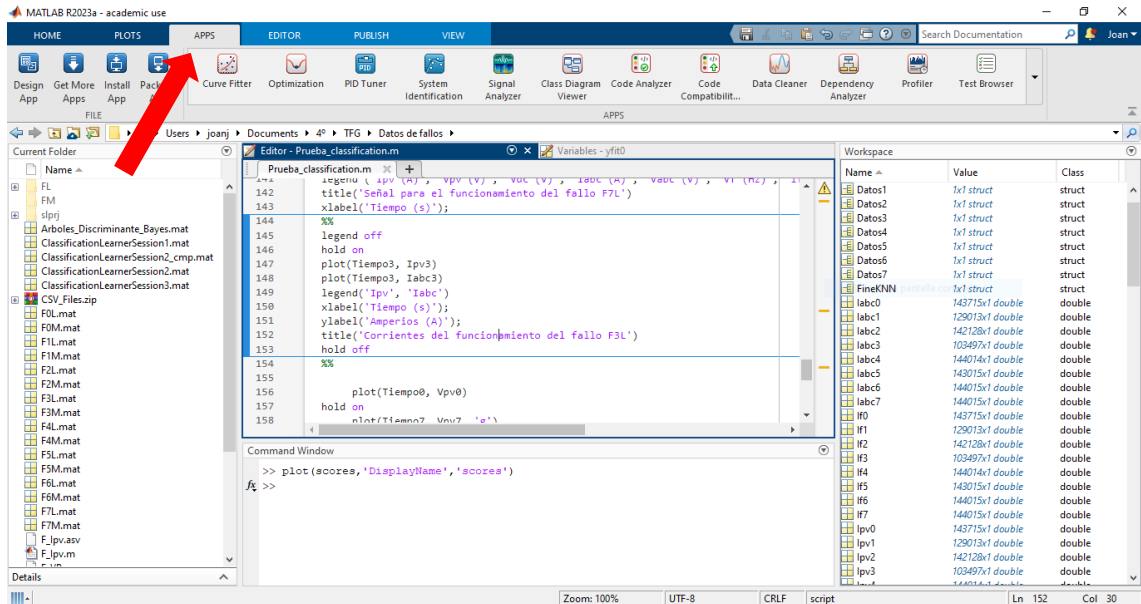


Ilustración 81: Apartado de app’s.

El siguiente paso es incluir nuestros datos en la aplicación. Esto se hace dándole al botón de “New Season” y luego darle al botón de “From Workspace”.

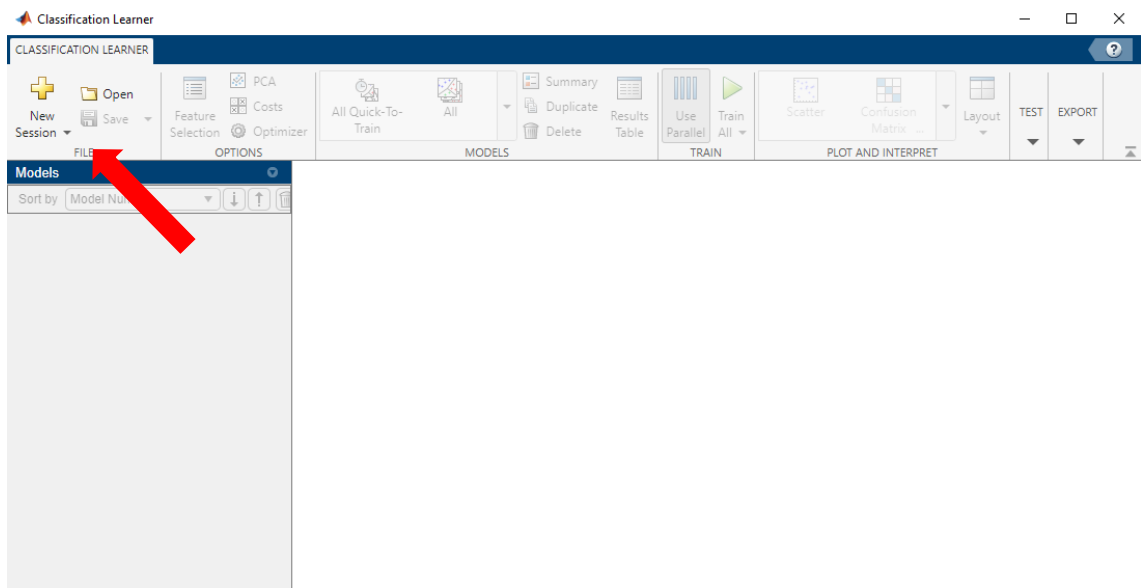
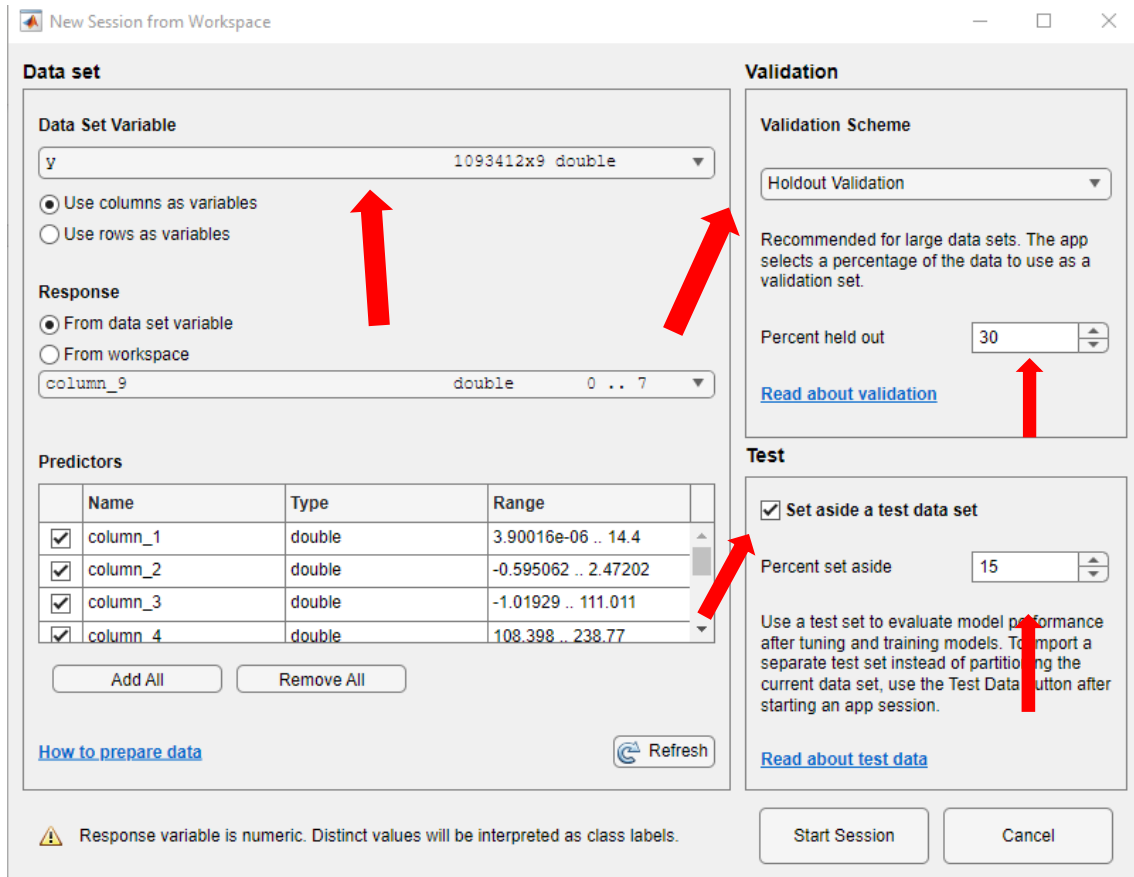


Ilustración 82: Introducir los datos en el Classification Learner.



A continuació, nos apareixerà una ventana en la qual deberem de introduir nostra senyal. En primer lloc, en la secció “Data Set” deberem seleccionar el desplegable i afegir la variable ‘y’ que conté nostra senyal. En segon lloc, nos tenem que ir directament al apartat de “Validation” en el qual seleccionarem la tècnica de “Holdout Validation” en el desplegable y pondrem 30 en el apartat de “percent held out”. En tercer lloc, en la part de “Test” marcarem la casilla de “Set aside a test data” y pondrem un percentatge de 15 en el apartat de “Percent set aside”. Por últim, iniciarem la sessió amb el botó “Start Session”.



**Data set**

Data Set Variable: y (1093412x9 double)

Use columns as variables  
 Use rows as variables

**Response**

From data set variable  
 From workspace

column\_9 (double 0 .. 7)

**Predictors**

	Name	Type	Range
<input checked="" type="checkbox"/>	column_1	double	3.90016e-06 .. 14.4
<input checked="" type="checkbox"/>	column_2	double	-0.595062 .. 2.47202
<input checked="" type="checkbox"/>	column_3	double	-1.01929 .. 111.011
<input checked="" type="checkbox"/>	column_4	double	108.398 .. 238.77

Add All Remove All Refresh

[How to prepare data](#)

**Validation**

Validation Scheme: Holdout Validation

Recommended for large data sets. The app selects a percentage of the data to use as a validation set.

Percent held out: 30

[Read about validation](#)

**Test**

Set aside a test data set

Percent set aside: 15

Use a test set to evaluate model performance after tuning and training models. To import a separate test set instead of partitioning the current data set, use the Test Data button after starting an app session.

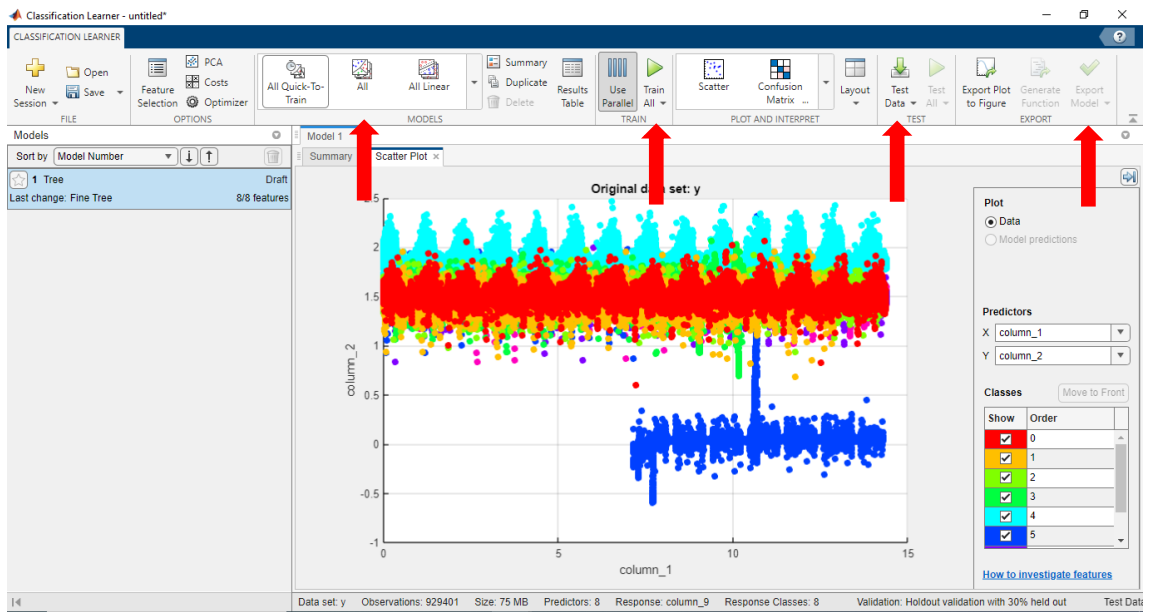
[Read about test data](#)

Start Session Cancel

⚠ Response variable is numeric. Distinct values will be interpreted as class labels.

**Il·lustració 83:** Ventana de nueva sesión “New Season”.

El últim pas es entrenar a los modelos que queramos, en el apartat “models” y darle al botón “Train”, hacer el test de los datos de cada técnica utilizada con el botón “Test” y después exportar el modelo al Workspace con el botón “Export Model” para poder utilizarlo como una función.



*Il·lustració 84: Cómo utilizar la aplicación Classification Learner.*



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

## 9. PLIEGO DE CONDICIONES

### 9.1. OBJETO

La finalidad del pliego de condiciones es establecer de forma clara y detallada los requisitos, especificaciones, alcance y condiciones necesarias para llevar a cabo un determinado proyecto u obra. Su principal objetivo es proporcionar una guía precisa a las partes interesadas, ya sean contratistas, proveedores o colaboradores, sobre las características y normas que deben cumplirse en el desarrollo del proyecto. De esta forma, se busca garantizar la calidad, eficiencia y consistencia en la ejecución de la obra, asegurando que todas las partes involucradas tengan un entendimiento común de lo que se espera alcanzar. El pliego de condiciones también puede incluir aspectos relacionados con los costes, el calendario, los métodos de trabajo y las responsabilidades de cada parte, proporcionando una base sólida para el éxito de la planificación y gestión del proyecto.

### 9.2. CONDICIONES DE LOS MATERIALES

En este apartado vamos a explicar que dispositivos se han utilizado para la simulación del sistema solar, este sistema se compone de varias partes, es por ello qué vamos a explicarlas una a una a continuación.

- **Simulador del panel solar:** Esta simulación se hace mediante el dispositivo Programable Chroma 62150H-1000S solar array emulator.
- **Simulador de red (de corriente alterna):** Esta simulación se realiza con el dispositivo Programable AC source Chroma 61,511 el cual simula la corriente de red.
- **Controlador:** Este dispositivo, aparte de controlar la tensión de salida, también va a recoger los datos, por ello vamos a implementar el entorno DSpace 1104.
- **Carga:** Para proteger al sistema ante los fallos que le vamos a incluir debemos utilizar una AC load.
- **Convertidor:** El convertidor va a ser un convertidor Boost.
- **Programa del algoritmo:** El algoritmo se ha desarrollado con el programa MATLAB R2023a con la versión de estudiantes.

Cabe recalcar que debemos comprobar la calidad de estos dispositivos periódicamente para evitar fallos no deseados y para poder asegurar el buen comportamiento del sistema.

### 9.3. CONTROL DE LA EJECUCIÓN

A continuación, vamos a detallar los pasos que debemos seguir en la ejecución del algoritmo.

- En primer lugar, debemos hacer la simulación de todos los datos.
- En segundo lugar, debemos cargar los datos y agruparlos de forma correcta como viene dado en el manual del usuario.
- El siguiente paso es abrir la aplicación Classification Learner e introducir estos datos que hemos preprocesado.
- A continuación, debemos validar y testear el algoritmo en la misma aplicación que antes.
- Por último, debemos exportar el modelo en el formato que nosotros queramos para su posterior utilización.

La correcta utilización de los datos y los resultados obtenidos deben ser comprobados constantemente para que no haya ningún tipo de error en el algoritmo.

### 9.4. PRUEBAS DE SERVICIO

Para una posible implementación en la vida real de estos algoritmos debemos seguir varios pasos.

En primer lugar, debemos medir todos los parámetros con los que hemos entrenado el modelo, que en nuestro caso son  $y = [I_{pv}, V_{pv}, V_{dc}, I_{abc}, I_f, V_{abc}, V_f]$ . A partir de aquí debemos extraer estos datos y meterlos en el algoritmo ya entrenado.

A continuación, lo que debemos hacer es comprobar si existe algún tipo de fallo y cuál es este. Esto se puede comprobar mediante el mismo programa de Matlab el cual nos dará un valor que es una 'etiqueta' que nosotros le hemos puesto, así pues, para el comportamiento normal nos dará el valor de '0' y para cada fallo nos dará su número asociado '1,2,3... 7' que cualquier operario de la planta pueda hacer el correcto mantenimiento de la placa.

Finalmente, podrás hacer la comprobación con otros datos o incluso implementarlo de forma que esté implementado en tiempo real.



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria del Disseny

## 10. BIBLIOGRAFÍA

- [1]: Rappaport, P. (1959). *The photovoltaic effect and its utilization*. *Solar Energy*, 3(4), 8-18.
- [2]: Rasero, C. M. (2011). Energía solar fotovoltaica. Energía solar fotovoltaica, situación actual, 4.
- [3]: Fraas, L. M., & Fraas, L. M. (2014). History of solar cell development. *Low-cost solar electric power*, 1-12.
- [4]: Easton, R. L., & Votaw, M. J. (1959). Vanguard I IGY satellite (1958 beta). *Review of Scientific Instruments*, 30(2), 70-75.
- [5]: Abram, R. A., Rees, G. J., & Wilson, B. L. H. (1978). Heavily doped semiconductors and devices. *Advances in Physics*, 27(6), 799-892.
- [6]: Maloberti, F., Uriza, E. J. S., & Coronado, D. A. C. (2015). Revisión teórica electrónica y física de un transistor de efecto de campo de unión pn. *Revista Ciencia, Innovación y Tecnología*, 2, 61-69.
- [7]: Yang, Y. T., Ekinci, K. L., Huang, X. M. H., Schiavone, L. M., Roukes, M. L., Zorman, C. A., & Mehregany, M. (2001). Monocrystalline silicon carbide nanoelectromechanical systems. *Applied Physics Letters*, 78(2), 162-164.
- [8]: Deb, D., & Brahmabhatt, N. L. (2018). Review of yield increase of solar panels through soiling prevention, and a proposed water-free automated cleaning solution. *Renewable and Sustainable Energy Reviews*, 82, 3306-3313.
- [9]: Ruiz, L., Beristáin, J., Sosa, I., & Hernández, J. (2010). Estudio del algoritmo de seguimiento de punto de máxima potencia perturbar y observar. *Revista de ingeniería eléctrica, electrónica y computación*, 8(1), 17-23.
- [10]: Abella, J. S. P., Reyes, J. S. T., & Mora, J. A. H. (2009). Desarrollo de un regulador de carga para sistemas fotovoltaicos aplicando instrumentación virtual. *Ingeniería*, 14(2), 13-18.
- [11]: Caceres Samaniego, P. A., & Mamani Villca, N. Diseño de un regulador de carga PWM para instalaciones fotovoltaicas (Doctoral dissertation).
- [12]: Abella, M. A. (2005). *Sistemas fotovoltaicos*. SAPT Publicaciones Técnicas, SL.
- [13]: Copetti, J. B., & Macagnan, M. H. (2007, November). Baterias em sistemas solares fotovoltaicos. In *Congresso Brasileiro de Energia Solar-CBENS*.
- [14]: García E, Quiles E, Zotovic-Stanisic R, Gutiérrez SC. Predictive Fault Diagnosis for Ship Photovoltaic Modules Systems Applications. *Sensors*. 2022; 22(6):2175
- [15]: de la Cruz Gómez, F. (2012). *Guía de mantenimiento de instalaciones fotovoltaicas*. Ediciones Experiencia.
- [16]: Leloux, J., Narvarte Fernandez, L., & Trebosc, D. (2012). Detección automática de fallos de operación en instalaciones fotovoltaicas domésticas. *Ies*.
- [17]: Boden, M. A. (2017). *Inteligencia artificial*. Turner.
- [18]: Zhou, Z. H. (2021). *Machine learning*. Springer Nature.
- [19]: Camargo-Vega, J. J., Camargo-Ortega, J. F., & Joyanes-Aguilar, L. (2015). Conociendo big data. *Revista Facultad de Ingeniería*, 24(38), 63-77.
- [20]: Sánchez-Gómez, A. M. (2017). *Técnicas de mantenimiento predictivo: metodología de aplicación en las organizaciones*.

[21]: Guichi, A., Talha, A., Berkouk, E. M., Mekhilef, S., & Gassab, S. (2018). A new method for intermediate power point tracking for PV generator under partially shaded conditions in hybrid system. *Solar Energy*, 170, 974-987.

[22]: Sitio web de la base de datos: "<https://data.mendeley.com/datasets/n76t439f65/1>"

[23]: Baodong, B., & Dezhi, C. (2013, February). Inverter IGBT loss analysis and calculation. In 2013 IEEE International Conference on Industrial Technology (ICIT) (pp. 563-569). IEEE.

[24]: Seymour, J., & Horsley, T. (2005). Los siete tipos de problemas en el suministro eléctrico. *APC Legendary Reliability*.

[25]: Molano, C. A. C., Daza, J. A. C., Hueso, R. B., Suarez, O. J., & Garcia, A. P. (2021). Diseño De Controladores Clásicos E Inteligentes Para Regular El Voltaje De Entrada A Un Inversor En Un Sistema Fotovoltaico. *Ingeniería e Innovación*.

[26]: Yadav, S., & Shukla, S. (2016, February). Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In 2016 IEEE 6th International conference on advanced computing (IACC) (pp. 78-83). IEEE.

[27]: Sempere, J. (2014). Aprendizaje de árboles de decisión. Universidad Politécnica de Valencia, Valencia.

[28]: Huberty, C. J. (1975). Discriminant analysis. *Review of Educational Research*, 45(4), 543-598.

[29]: Leung, K. M. (2007). Naive bayesian classifier. *Polytechnic University Department of Computer Science/Finance and Risk Engineering*, 2007, 123-156.

[30]: Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.



## 10.1. BIBLIOGRAFÍA DE ILUSTRACIONES

[31]: Ilustración 1: <https://www.drewexmachina.com/2018/03/17/vanguard-1-the-little-satellite-that-could/>

[32]: Ilustración 2: [https://www.researchgate.net/figure/The-Photovoltaic-Effect-in-a-Solar-Cell\\_fig4\\_281857950](https://www.researchgate.net/figure/The-Photovoltaic-Effect-in-a-Solar-Cell_fig4_281857950)

[33]: Ilustración (3,4): <https://ecoinventos.com/wp-content/uploads/2018/02/Tipos-de-paneles-solares.jpg>

[34]: Ilustración 5: <https://www.archiexpo.com/prod/first-solar/product-87503-1541886.html>

[35]: Ilustración 6: <https://www.nrel.gov/>

[36]: Ilustración 7: <https://www.ecosistemasdelsureste.com/news/componentes-principales-de-una-instalacion-solar-fotovoltaica/>

[37]: Ilustración 8: <https://www.pveducation.org/pvcdrom/solar-cell-operation/fill-factor>

[38]: Ilustración 9: <https://madridcamper.com/reguladores-solares-y-accesorios-de-montaje/414-regulador-maximizador-15a-victron.html>

[39]: Ilustración 10: <https://www.prostarsolar.net/es/como-funciona-el-regulador-de-carga-solar-pwm.html>

[40]: Ilustración 11: <https://www.kstar.com/indexproblem/17355.jhtml>

[41]: Ilustración 12: [https://www.researchgate.net/figure/The-power-curve-of-the-PV-module-for-varying-irradiance-34-As-weather-plays-a-major\\_fig1\\_331951296](https://www.researchgate.net/figure/The-power-curve-of-the-PV-module-for-varying-irradiance-34-As-weather-plays-a-major_fig1_331951296)

[42]: Ilustración 13: <https://www.seaward.com/gb/support/solar/faqs/00797-how-does-temperature-and-irradiance-affect-i-v-curves/>

[43]: Ilustración 14: <https://blog.hipowercr.com/que-es-y-como-funciona-un-sistema-hibrido-de-energia-solar>

[44]: Ilustración 15: <https://www.monsolar.com/blog/placas-solares-baratas-8-fallos-criticos/>

[45]: Ilustración 16: <https://citsolar.mx/por-que-es-importante-el-mantenimiento-en-los-sistemas-fotovoltaicos/>

[46]: Ilustración 17: <https://canalsolar.com.br/diodos-de-bypass-e-hot-spots-dos-modulos-fotovoltaicos/>

[48]: Ilustración 30: <https://vitalflux.com/hold-out-method-for-training-machine-learning-model/>

[49]: Ilustración 31: <https://www.feedingthemachine.ai/arboles-de-decision-en-regresion-machine-learning/>

Ilustración (19-29), (32-86): Imágenes extraídas manualmente desde Matlab.