



Universidad Autónoma de Querétaro  
Facultad de Informática

“Algoritmo para mejorar la eficiencia de un controlador MPPT  
fotovoltaico basado en un enfoque híbrido  
neuronal-metaheurístico.”

Tesis

Que como parte de los requisitos para obtener el Grado de  
Doctor en Ciencias de la Computación

Presenta:

César Gabriel Villegas Mier.

Dirigido por:

Dr. Juvenal Rodríguez Resendiz.

Querétaro, Qro. a Junio del 2024.

La presente obra está bajo la licencia:  
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

### Usted es libre de:

**Compartir** — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

### Bajo los siguientes términos:



**Atribución** — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



**NoComercial** — Usted no puede hacer uso del material con [propósitos comerciales](#).



**SinDerivadas** — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

**No hay restricciones adicionales** — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

### Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



# Universidad Autónoma de Querétaro

Facultad de Informática

Doctorado en Ciencias

de la Computación

## **“Algoritmo para mejorar la eficiencia de un controlador MPPT fotovoltaico basado en un enfoque híbrido neuronal-metaheurístico.”**

TESIS

Que como parte de los requisitos para obtener el grado de

Doctor en Ciencias de la Computación

Presenta:

**César Gabriel Villegas Mier.**

Dirigido por:

**Dr. Juvenal Rodríguez Resendiz.**

SINODALES

Dr. Juvenal Rodríguez Resendiz.

Presidente

Firma

Dr. José M. Álvarez-Alvarado.

Secretario

Firma

Dra. Diana Margarita Córdova Esparza.

Vocal

Firma

M.S.I. José Alfredo Acuña García.

Suplente

Firma

P.H.D. Ákos Odry.

Suplente

Firma

M.S.I. Jose Alejandro Vargas Diaz

Director de la Facultad

Dr. Manuel Toledano Ayala

Director de Investigación y Posgrado

Centro Universitario

Querétaro, QRO

México.

Junio 2024

# Dedicatoria

*En memoria de todos mis primos, amigos compañeros y familiares muertos en el transcurso de estos años de realización de esta tesis.*

# Agradecimientos

A mis queridos padres, cuyo apoyo inquebrantable y aliento inagotable han sido los cimientos de mi viaje; a mis inspiradores profesores, que encendieron la llama de la curiosidad y me otorgaron el don del conocimiento; a mis queridos hermanos, que han sido mis pilares de fortaleza, siempre a mi lado; y a mis queridos amigos, que han compartido mis triunfos y tribulaciones, ofreciéndome risas y consuelo a partes iguales: dedico este humilde trabajo como testimonio del profundo impacto que cada uno de vosotros ha tenido en la formación de la persona que soy hoy. Al llegar a la cima de este esfuerzo académico, estoy eternamente agradecido por el amor, la sabiduría y la compañía que me han guiado hasta este pináculo.

Además, extiendo mi más profunda gratitud a CONACYT por su invaluable apoyo financiero, que ha sido fundamental para permitirme perseguir mis sueños académicos. Su compromiso con el fomento de la educación y la investigación.

También estoy profundamente agradecido a la Universidad Autónoma de Querétaro, mi estimada alma-mater, por haberme proporcionado los recursos y el entorno estimulante que han alimentado mi crecimiento, como académico y como persona. Esta institución ha sido una cuna de conocimiento e inspiración que me ha moldeado hasta convertirme en la investigadora que he llegado a ser.

## Índice

<b>Abreviaturas y siglas</b>	<b>VII</b>
<b>Resumen en español</b>	<b>VIII</b>
<b>Abstract</b>	<b>IX</b>
<b>Introducción</b>	<b>1</b>
Motivación . . . . .	1
Alcances y Limitaciones . . . . .	1
Importancia o impacto . . . . .	2
Impacto Social . . . . .	2
Impacto Ambiental . . . . .	2
Impacto Económico . . . . .	2
Estructura de la tesis . . . . .	3
<b>Revisión de la literatura</b>	<b>4</b>
Revisión de la literatura . . . . .	4
Algoritmos que utilizan Redes Neuronales . . . . .	4
MPPT usando Aprendizaje Automático Supervisado . . . . .	7
<b>III.- Hipótesis</b>	<b>10</b>
Preguntas de investigación: . . . . .	10
<b>IV.- Objetivos</b>	<b>10</b>
Objetivo principal . . . . .	10
Objetivos específicos . . . . .	10
<b>Bases Teóricas</b>	<b>12</b>
Inteligencia artificial . . . . .	12
¿Que es el aprendizaje automático? . . . . .	12
¿Que son las redes neuronales artificiales? . . . . .	13
Tipos de arquitecturas . . . . .	14
<b>Problemas de Optimización</b>	<b>15</b>
Óptima local vs. Óptima global . . . . .	15
Optimización en el contexto del seguimiento del punto de máxima potencia . . . . .	16
¿Como optimizar aun mas a las redes neuronales? . . . . .	16
¿Que es la optimización de hiper-parámetros en las ANN? . . . . .	17

<b>Algoritmos Meta-heuristicos</b>	<b>18</b>
Utilización de procesos estocásticos en algoritmos meta-heurísticos . . .	19
Algoritmo Optimizador Lobo Gris . . . . .	20
Algoritmo de Optimización por Enjambre de Partículas . . . . .	22
Optimización mediante Algoritmos Genéticos . . . . .	23
<b>Análisis de series de tiempo</b>	<b>24</b>
¿Que son las series de tiempo? . . . . .	24
Series de tiempo lineales . . . . .	24
Series de tiempo no lineales . . . . .	25
La división entrenamiento-prueba-validación . . . . .	25
Métricas estadísticas para la validación de datos . . . . .	26
<b>Sistemas fotovoltaicos</b>	<b>27</b>
Efecto fotovoltaico . . . . .	27
Radiación Solar . . . . .	27
Irradiancia . . . . .	27
Temperatura Ambiental . . . . .	28
Celda Fotovoltaicas . . . . .	28
Inversor fotovoltaico . . . . .	28
Convertidores CC/CC . . . . .	29
Módulo Fotovoltaico . . . . .	29
<b>Modelos de módulos fotovoltaicos</b>	<b>30</b>
Modelo del diodo ideal o simple . . . . .	30
Modelo del diodo ideal o simple . . . . .	30
¿Qué otros modelos existen? . . . . .	31
Condiciones de prueba estándar . . . . .	31
Curvas características . . . . .	32
<b>¿Como optimizar un sistema fotovoltaico?</b>	<b>33</b>
<b>Algoritmos para la Búsqueda del Punto de Máxima Potencia</b>	<b>34</b>
Algoritmo Perturbación & Observación . . . . .	35
Algoritmo Conductancia Incremental . . . . .	36
Redes Neuronales para el seguimiento del punto de máxima potencia . .	37
Aprendizaje Automático para el seguimiento del punto de máxima potencia . . . . .	38

<b>Metodología</b>	<b>40</b>
Tipo de Investigación . . . . .	40
Fases de la Investigación . . . . .	40
Área de Estudio . . . . .	41
Conjunto de Datos . . . . .	43
<b>Resultados</b>	<b>45</b>
<b>Simulación e implementación de los algoritmos en MATLAB/Simulink</b>	<b>45</b>
<b>Simulación e implementación de los algoritmos en Python</b>	<b>47</b>
Acceso y tratamiento de los datos atmosféricos . . . . .	47
Acceso y tratamiento de los datos atmosféricos . . . . .	47
Análisis de tendencia . . . . .	48
Heatmap y Correlación de Distancia . . . . .	48
Modelado de un panel PV usando el diodo simple . . . . .	52
Experimentos para calcular el MPP usando Aprendizaje Automático . . . . .	53
Bosque Aleatorio Optimizado . . . . .	54
Redes Neuronales MLP . . . . .	56
RNA + Optimización por Lobo Gris . . . . .	59
RNA + Optimización por Algoritmo Genético . . . . .	61
RNA + Optimización por Enjambre de Partículas . . . . .	63
Resultados Numéricos . . . . .	66
Discusión . . . . .	67
<b>Conclusiones</b>	<b>69</b>
Recomendaciones y trabajo futuro . . . . .	70
Uso de Redes neuronales en sistemas embebidos . . . . .	71
. . . . .	72
<b>VIII.- Referencias</b>	<b>74</b>
Publicaciones . . . . .	85
Primer Artículo en revista indexada . . . . .	85
Segundo Artículo en revista indexada . . . . .	86
<b>Apéndice Entregables</b>	<b>87</b>
Carta Aceptación Protocolo . . . . .	87
Firmas de registro de protocolo ante comité de investigación . . . . .	88
Carta liberación de Ingles con + 80 % . . . . .	89
<b>Apéndice Curso de Formación Académica</b>	<b>90</b>



<b>Apéndice Código Matlab/Simulink</b>	<b>91</b>
Modelo de doble diodo . . . . .	91
Perturbacion y Observacion . . . . .	92
Conductancia Incremental . . . . .	93
Código para el acceso y tratamiento de los datos atmosféricos . . . . .	94
Código para el modelado y simulación de un panel PV usando el modelo ideal o simple . . . . .	94
Código para obtener el MPP usando ANN . . . . .	94
Código para obtener el MPP usando ANN + GAO . . . . .	95
Código para obtener el MPP usando ANN + GWO . . . . .	96
Código para obtener el MPP usando ANN + PSO . . . . .	98
Código para Arduino de MPPT usando redes neuronales . . . . .	99

## Índice de figuras

1.	Diagrama de Bloques del controlador neuronal optimizado con Algoritmos Genéticos. . .	4
2.	Perceptron Multicapa. . . . .	14
3.	Diagrama de flujo del algoritmo Optimizador Lobo Gris. . . . .	21
4.	Curva I-V característica de un módulo fotovoltaico. . . . .	33
5.	Diagrama de flujo del algoritmo MPPT de P&O. . . . .	35
6.	Diagrama de flujo del algoritmo MPPT de Conductancia Incremental . . . . .	37
7.	Mapa del Atlas solar de Mexico. Atlas (2022). . . . .	42
8.	Representación gráfica de la metodología. . . . .	44
9.	Simulación de bloques de un sistema PV usando Matlab/Simulink. . . . .	45
10.	Heatmap con los datos de generados por la correlación de distancia. . . . .	49
11.	Distribución de los Datos. . . . .	50
12.	Heatmap con los datos de generados por la correlación de distancia. . . . .	51
13.	Resultados usando Bosque Aleatorio Optimizado. . . . .	55
14.	Resultados usando RNA MLP. . . . .	57
15.	Resultados usando optimización por Lobo Gris. . . . .	60
16.	Resultados usando Optimización por Algoritmo Genético. . . . .	62
17.	Resultados usando Optimización por Enjambre de Partículas. . . . .	64

## Índice de tablas

1.	Revisión de características para algoritmos controladores MPPT utilizando algoritmos híbridos (HIS) NN + metaheurística. . . . .	5
2.	Resultados obtenidos para el dataset 2021 con PV diodo simple, utilizando algoritmos aprendizaje automático y ANN optimizados con meta-heuristicos programados en python. . . . .	66
3.	Resultados obtenidos para el dataset 2022 con PV diodo simple. . . . .	67

## Abreviaturas y siglas

Aquí se encuentra un compendio de las abreviaciones usadas en este trabajo de tesis.

AC	Corriente Alterna
IA	Inteligencia Artificial
SINFA	Sistema de Inferencia Neuro-Difusa Adaptativa
RNA	Redes Neuronales Artificiales
CC	Corriente Continua
SINFAE	Sistema de Inferencia Neuro-Difusa Adaptativa Mejorada
LF	Lógica Difusa
GMPP	Punto de Máxima Potencia Global
IC	Incremento de la Conductancia
EMA	Error Medio Absoluto
EMAP	Error Medio Absoluto Porcentual
AAM	Aprendizaje Automático
MLP	Perceptrón Multicapa
PMP	Punto de Máxima Potencia
SEMP	Seguimiento del Punto de Máxima Potencia
MSE	Error Cuadrático Medio
FV	Fotovoltaica
CVP	Célula Fotovoltaica
SVP	Sistema Fotovoltaico
P&O	Perturbación y Observación
PSO	Optimización por Enjambre de Partículas
CSP	Condiciones de Sombreado Parcial
ER	Energía Renovable
RF	Bosque Aleatorio
RMSE	Error Cuadrático Medio
LA	Aprendizaje Supervisado
MVS	Máquina de Vectores de Soporte
RVM	Regresión de Máquina de Vectores de Soporte
LU	Aprendizaje No Supervisado

## Resumen en español

La creciente demanda de energía eléctrica y la cada vez menor disponibilidad de combustibles fósiles han allanado el camino a las fuentes de energía renovables, emergiendo la energía solar como una de las opciones más populares debido a su naturaleza libre de contaminación, abundante disponibilidad y bajos requisitos de mantenimiento. Este trabajo de tesis explora el potencial de emplear técnicas de seguimiento del punto de máxima potencia (MPPT) basadas en aprendizaje automático (ML) para maximizar la producción de energía en sistemas fotovoltaicos (FV) en condiciones de sombreado parcial.

En este estudio, realizan varias contribuciones a los campos de los sistemas fotovoltaicos y los sistemas basados en ML mediante la introducción de novedosas técnicas para el cálculo de MPP, y la realización de experimentos en condiciones meteorológicas variables. El rendimiento de los algoritmos basados en árbol de decisión (RF), Perceptron de Capa Múltiple (MLP) y la combinación entre redes neuronales y algoritmos de optimización metaheurística (Enjambre de Partículas, Lobo Gris, Genéticos) se validaron y compararon utilizando software desarrollado en Python y Matlab/Simulink.

Los resultados experimentales revelaron que las técnicas de optimización híbridas, neuronal-metaheurísticas, superaron significativamente a los otros algoritmos tradicionales. Con la combinación de redes i Algoritmos genéticos alcanzado un 93.6 % de precisión, Seguida de la ANN+ Optimización de lobo gris con un rango de 93 a 96 %, por último la combinación de ANN + Optimización por enjambre de partículas obtuvo un rango similar del 90 % a 95.4 % de precisión al momento de predecir el MPP. El algoritmo RF optimizado también alcanza un rendimiento muy similar del 93.2 % a 96. %.

Se muestra que la optimización de hiperparámetros es un aspecto crítico del proceso de aprendizaje automático que puede influir significativamente en el rendimiento, la eficacia, la capacidad de generalización y la complejidad de un modelo. Unos hiperparámetros bien ajustados pueden dar lugar a modelos más precisos y fiables que funcionen bien tanto con datos de entrenamiento como con datos no vistos.

**Palabras Clave:** *Aprendizaje Automático, MPPT, Sistemas Fotovoltaicos. Temperatura, Irradiancia, Radiación Solar, Tensión, Corriente, Punto de Máxima Potencia. Algoritmos Híbridos, Redes Neuronales, Optimización Meta-heurística, Algoritmos Genéticos, Lobo Gris, Enjambre de Partículas.*

## Abstract

The increasing demand for electrical power and the decreasing availability of fossil fuels have paved the way for renewable energy sources, with solar energy emerging as one of the most popular options due to its pollution-free nature, abundant availability, and low maintenance requirements. This thesis work explores the potential of employing machine learning (ML)-based maximum power point tracking (MPPT) techniques to maximize energy production in photovoltaic (PV) systems under partial shading conditions.

In this study, they make several contributions to the fields of PV and ML-based systems by introducing novel techniques for calculating MPP. and conducting experiments under varying weather conditions. The performance of algorithms based on decision tree (RF), Multi-Layer Perceptron (MLP) and the combination between neural networks and metaheuristic optimization algorithms (Particle Swarm, Grey Wolf, Genetic) were validated and compared using software developed in Python and Matlab/Simulink. Experimental results revealed that the hybrid neural-metahuristic optimization techniques significantly outperformed the other traditional algorithms. With the combination of Network and Genetic Algorithms achieved 93.6 % accuracy, followed by ANN + Gray Wolf Optimization with a range of 93 to 96 % accuracy, and finally the combination of ANN + Particle Swarm Optimization achieved a similar range of 90 to 95.4 % accuracy in predicting the MPP. The optimized RF algorithm also achieves a very similar performance of 93.2 to 96.0 %.

It shows that hyperparameter optimization is a critical aspect of the machine learning process that can significantly influence the performance, efficiency, generalizability and complexity of a model. Well-tuned hyperparameters can lead to more accurate and reliable models that perform well on both training and unseen data.

**KeyWords:** *Machine Learning, MPPT, Photovoltaic Systems. Temperature, Irradiance, Solar Radiation, Voltage, Current, Maximun Power Point. HYbrid Algorithms, Neural Networks, Meta-heuristic Optimization, Genetic Algorithms, Grey Wolf, Particle Swarm.*

# I.- Introducción

## Motivación

Existe un interés creciente en la intersección entre la optimización de redes neuronales y los sistemas de control aplicados a energías limpias, específicamente en el contexto del Punto de Máxima Potencia (MPPT, por sus siglas en inglés). En años recientes, la formación consolidada en aprendizaje automático e ingeniería eléctrica ha suscitado mi entusiasmo por la posibilidad de aplicar mis habilidades y conocimientos para contribuir al éxito de su empresa.

Mi experiencia en optimización de redes neuronales ha desarrollado en mí una comprensión profunda sobre la importancia de la identificación de la mejor solución dentro de un conjunto de posibilidades. He trabajado con diversos algoritmos de optimización, como el descenso de gradiente, algoritmos genéticos y recocido simulado, con el propósito de mejorar el rendimiento de modelos de aprendizaje automático. Asimismo, mi experiencia en el seguimiento del Punto de Máxima Potencia (MPPT) en sistemas fotovoltaicos (FV) ha fortalecido mi comprensión de los principios fundamentales del MPPT y cómo estos pueden emplearse para extraer la máxima potencia de los paneles FV. He aplicado algoritmos MPPT para rastrear el óptimo global, representando el punto en el cual un panel fotovoltaico genera la máxima potencia, con el objetivo de optimizar la extracción de energía solar.

La perspectiva de aplicar mis habilidades y conocimientos en optimización de redes neuronales y MPPT para contribuir a los objetivos de su organización me resulta particularmente atractiva. Estoy convencido de que mi formación y experiencia me posicionan como un candidato excepcional para este rol y espero tener la oportunidad de profundizar en mis calificaciones durante una eventual entrevista.

## Alcances y Limitaciones

El uso de redes neuronales y algoritmos metaheurísticos para el seguimiento del punto de máxima potencia (MPPT) en sistemas fotovoltaicos (FV) tiene varias ventajas, pero también conlleva ciertas limitaciones. A continuación se analizan el alcance y las limitaciones del uso de estos enfoques para el MPPT.

**Alcance:**  
Mejora del rendimiento del seguimiento: Las redes neuronales pueden aprender relaciones complejas y no lineales entre las variables de entrada y salida, lo que permite modelar y predecir con mayor precisión el punto de máxima potencia (MPP) en condiciones variables. Los algoritmos metaheurísticos, como la Optimización por Enjambre de Partículas (PSO) y el Optimizador Lobo Gris (GWO), pueden buscar el espacio de soluciones de forma eficiente y eficaz, mejorando el rendimiento del seguimiento en comparación con los métodos MPPT tradicionales como Perturbar y Observar (P&O) o Conductancia Incremental (IC).

**Limitaciones:**

**Complejidad y coste computacional:** Las redes neuronales y los algoritmos metaheurísticos pueden ser más complejos e intensivos desde el punto de vista computacional que los métodos MPPT tradicionales.

Esta mayor complejidad puede ser un problema en sistemas con recursos limitados o en aplicaciones en tiempo real, donde es crucial un cálculo rápido y eficiente.

Datos de entrenamiento y sobreajuste: Las redes neuronales necesitan datos de entrenamiento suficientes y representativos para lograr un buen rendimiento. Unos datos de entrenamiento insuficientes o sesgados pueden dar lugar a un sobreajuste y a una mala generalización en condiciones reales. Adquirir datos de entrenamiento de alta calidad puede ser un reto, y entrenar una red neuronal también puede llevar mucho tiempo.

## **Importancia o impacto**

En esta sección se explica la importancia del trabajo, sus beneficios potenciales y sus impactos social, ambiental, y económico.

### **Impacto Social**

El impacto social de los nuevos algoritmos MPPT (seguimiento del punto de máxima potencia) puede ser significativo, ya que pueden aumentar en gran medida la eficiencia y, por tanto, la viabilidad económica de los sistemas fotovoltaicos (FV). Esto puede conducir a una mayor adopción de la energía solar, lo que puede tener varios beneficios sociales, como reducir la dependencia de los combustibles fósiles, disminuir la contaminación atmosférica y las emisiones de gases de efecto invernadero, y aumentar el acceso a la electricidad en zonas remotas o subdesarrolladas. Además, los avances en la tecnología MPPT también pueden crear nuevas oportunidades de empleo en la industria de las energías renovables. Sin embargo, es importante tener en cuenta el ciclo de vida completo de la tecnología, incluido el impacto medioambiental de la fabricación y eliminación de los sistemas fotovoltaicos, para garantizar un impacto positivo global.

### **Impacto Ambiental**

El impacto ambiental del MPPT dependería de la implementación y aplicación específicas del algoritmo. En general, los algoritmos MPPT pueden ayudar a aumentar la eficiencia y el rendimiento global de los paneles solares, lo que puede tener un impacto positivo en el medio ambiente al reducir la cantidad de energía que es necesario generar a partir de fuentes no renovables. Además, al mejorar la eficiencia de los paneles solares, los algoritmos MPPT pueden ayudar a reducir el coste global y la huella de los sistemas de energía solar, lo que también puede tener un impacto positivo en el medio ambiente. Sin embargo, es importante señalar que el impacto del MPPT en el medio ambiente dependerá del algoritmo específico y de su aplicación, así como del contexto más amplio en el que se utilice.

### **Impacto Económico**

El optimizar sistemas fotovoltaicos usando MPPT, puede suponer un ahorro de costos para los usuarios particulares y para las empresas que utilizan energía solar, como también para empresas de servicios



públicos (PEMEX, CFE) que generan electricidad a partir de energía solar. Además, los algoritmos MPPT pueden ayudar a reducir el coste global de la energía solar, haciéndola más competitiva frente a otras formas de generación de energía.

## **Estructura de la tesis**

Se estructura de la siguiente manera: Capítulo Introducción, una introducción al tema, su importancia, la hipótesis objetivos y objetivos específicos, además de presentar la contribución que se pretende conseguir con este artículo. El Capítulo Bases Teóricas, se encuentran las bases teóricas, una breve introducción a la RNA, el aprendizaje automático y nomenclaturas utilizadas por los sistemas de energía solar fotovoltaica. El Capítulo Revisión de la literatura, es la revisión de literatura sobre antecedentes y estado del arte sobre los trabajos cuyas características describen el controlador MPPT que utilizan RNA. El capítulo Metodología describe la metodología seguida para lograr el objetivo principal de esta tesis. En este capítulo, se define el área de estudio y cómo están conformados los datasets, se detalla la metodología para la separación de los datos y la predicción del MPPT usando algoritmos de Machine Learning. El capítulo de Resultados presenta los hallazgos obtenidos a partir de la implementación de los métodos descritos, mostrando el desempeño y la precisión de los modelos utilizados. Por último, el capítulo de Conclusiones resume los puntos clave de la investigación, discute las implicaciones de los resultados y sugiere posibles direcciones para futuros trabajos.

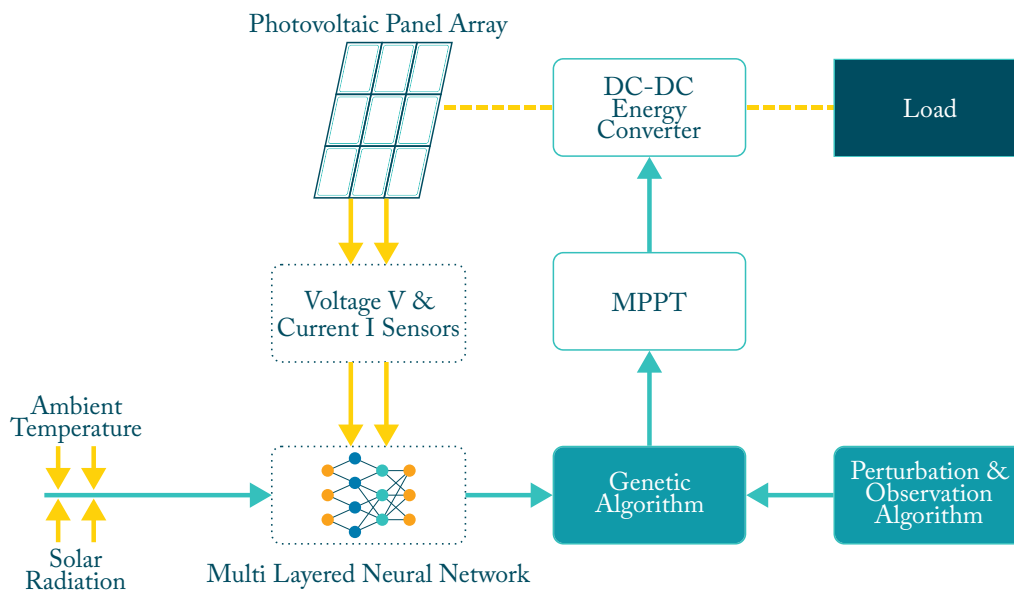
## II.- Antecedentes y Estado del Arte

En esta sección se incluye una recopilación sobre los trabajos de antecedentes y del estado del arte sobre optimización de sistemas fotovoltaicos MPPT, que incluyen ANN, ANN + logica difusa, o ANN + algoritmos de optimización metaheurísticos.

### Revisión de la literatura

Los Sistemas Inteligentes Híbridos (SIH) amalgaman múltiples algoritmos o técnicas previamente discutidos. Estas técnicas, que sirven como componentes integrales de un método de resolución de problemas o se asignan para realizar una tarea específica, a menudo se mejoran mediante la adición de uno o más algoritmos metaheurísticos o de optimización. El objetivo principal de esta mejora es aumentar el rendimiento de las redes neuronales artificiales (RNA) o afinar los parámetros de entrada Ostheimer, Chowdhury, y Iqbal (2021).

La Figura 1 ilustra la arquitectura general de un controlador de seguimiento del punto de máxima potencia (MPPT) que emplea un algoritmo de RNA, optimizado mediante un algoritmo genético (GA) para refinar los parámetros de entrada, complementado con un algoritmo de P&O.



**Figura 1**

*Diagrama de Bloques del controlador neuronal optimizado con Algoritmos Genéticos.*

### Algoritmos que utilizan Redes Neuronales

A continuación se presenta un compendio de diferentes autores que han usado las ANN combinados con otros algoritmos metaheurísticos para el seguimiento del MPP:

**Cuadro 1**

*Revisión de características para algoritmos controladores MPPT utilizando algoritmos híbridos (HIS) NN + metaheurística.*

Referencia	Tipo	Eficiencia %	Algoritmo-Metaheurístico	Arquitectura	Sistema de Inferencia
Manikandan y Selvaperumal (2020)	EANFIS+PSO	94 %	Particle Swarm	–	Modelo Sugeno
Farzaneh (2019)	FA-ANFIS-P&O	–	Algoritmo de luciérnagas modificado	–	Takagi-Sugeno
Andrew-Cotter y cols. (2019)	ANFIS-PSO	97 %	Particle Swarm	RLSE	Takagi-Sugeno-Kang
Vincheh y cols. (2014)	Híbrido (Fuzzy+NN+GA)	–	Genético	MLP	–
Ngan y Tan (2016)	Híbrido (NN+PSO)	92.7–99.7 %	Particle Swarm	MLP	–
Chen y Wang (2019)	Híbrido (NN+SMC)	96.2 %	Secuencial Monte-Carlo	MLFF	–
M. N. Ali y cols. (2021)	Híbrido (ANN+GA)	–	Genético	MLP	–
Rahman y Islam (2020)	Híbrido (ANN+PSO)	99.89 %	Particle Swarm	FFBP	–
Priyadarshi y cols. (2020)	ANFIS-PSO	98.35 %	Particle Swarm	MFNN	Mamdani max-min
Prasad y cols. (2016)	Híbrido (ANN+GA+BR)	85 %	Genético	Regulación Bayesiana	–

En trabajo de Manikandan2020 et al. Manikandan y Selvaperumal (2020), han elaborado un algoritmo de Sistema de Inferencia Neuro-Fuzzy Adaptativo Mejorado (EANFIS), en sinergia con la Optimización por Enjambre de Partículas (PSO), para el control del Seguimiento del Punto de Máxima Potencia (MPPT) en sistemas fotovoltaicos autónomos (SAPV). En particular, este sistema integra un inversor de fuente Quasi-Z (qZSI) y un motor sin escobillas (BLCD). El algoritmo, desarrollado utilizando la caja de herramientas Matlab, incorpora G&T como entradas y se rige por dos reglas de inferencia. Para emular diversas condiciones ambientales, se utilizaron materiales como arena, polvo y ceniza.

El rendimiento del algoritmo propuesto se comparó con el de otros algoritmos preexistentes, como el de Perturbar y Observar (P&O), con una eficiencia del 80 %, y el MPPT de Red Neuronal Artificial (ANN), que mostró una eficiencia del 87 %. En particular, los resultados revelaron que el algoritmo propuesto demostró una impresionante eficiencia máxima del 94 %".

Farzaneh et al. Farzaneh (2019) presentan un algoritmo híbrido para el seguimiento del punto de máxima potencia (MPPT), que combina un sistema de inferencia neurofuzzy adaptativo (ANFIS) y un sistema de perturbación y observación (P&O) en la etapa inicial, seguido de la incorporación de la optimización de Firefly modificada (MFA) en la etapa posterior. El método propuesto procesa diversos niveles de irra-

diancia (G) como entradas a través de ANFIS, produciendo una salida óptima. Esta salida se suministra al algoritmo P&O, que busca el Punto de Máxima Potencia (MPP) global.

Cotter et al. Andrew-Cotter y cols. (2019) En su trabajo, los investigadores proponen un algoritmo para el seguimiento del punto de máxima potencia (MPPT) que emplea un sistema de inferencia neurofuzzy adaptativo (ANFIS) integrado con la optimización por enjambre de partículas (PSO). El objetivo es optimizar las funciones de pertenencia y minimizar el error del algoritmo de mínimos cuadrados. El ANFIS propuesto emplea el sistema Takagi-Sugeno-Kang con una estructura de cinco capas y selecciona cuatro reglas para las funciones de pertenencia. Para encontrar el óptimo global y evitar el estancamiento, el algoritmo utiliza PSO, asegurando así la estabilidad y garantizando la convergencia. Los resultados, simulados en Matlab/Simulink, mostraron un tiempo de respuesta superior al de un algoritmo convencional (P&O) y se probaron con varios niveles de corriente (I).

Vincheh et al. Vincheh y cols. (2014) en su estudio, los investigadores proponen un algoritmo de control basado en principios neurodifusos. Los datos se entrenaron en una red neuronal artificial (RNA) de tres capas con 25 neuronas y se optimizaron utilizando un algoritmo genético (AG).

Este algoritmo dio como resultado un seguimiento acelerado del tiempo transitorio y una variación insignificante de la potencia de salida en estado estacionario, proporcionando así un seguimiento preciso del punto de máxima potencia (MPP) que responde a los cambios en las condiciones meteorológicas y en la carga del convertidor. En consecuencia, la eficiencia del controlador MPPT experimentó una mejora sustancial.

Ngan et al. Ngan y Tan (2016) desarrollaron un algoritmo MPPT utilizando RNA híbrida + PSO para encontrar el pico global (GP) en presencia de varios picos locales (LP). El rendimiento de este algoritmo se comparó con el de un algoritmo de enjambre clásico. El algoritmo se probó tanto en Matlab como en simulaciones de hardware y se obtuvieron resultados de eficiencia muy similares entre sí. Sin embargo, cuando se probó en condiciones de sombreado parcial presentó algunas diferencias.

Chen et al. Chen y Wang (2019) presentan una metodología para calcular el Punto de Máxima Potencia Global (GMPP) que aprovecha el método de Monte-Carlo Secuencial (SMC) en combinación con un método de Conductancia Incremental (InC), posteriormente refinado mediante una Red Neuronal Artificial (RNA). La RNA se encarga de controlar las alteraciones de la tensión (V) y la corriente (I), así como la irradiancia (G), prediciendo así el GMPP. El algoritmo SMC gestiona la transición no lineal de la tensión cuando el tamaño del escalón es variable. La RNA se entrenó con 500 muestras de datos, y los resultados de la simulación sugieren que el algoritmo destaca en la identificación del GMPP en condiciones de sombreado parcial.

Ali et al. M. N. Ali y cols. (2021) emplean un enfoque algorítmico doble para la identificación del punto de máxima potencia (MPP). Inicialmente, el método de Lógica Difusa (FL), utilizado junto con el Algoritmo Genético (GA) y la Optimización por Enjambre de Partículas (PSO), demuestra un rendimiento satisfactorio en condiciones de baja irradiancia (G) y alta temperatura (T) en comparación con los métodos tradicionales de Perturbar y Observar (P&O) y Conductancia Incremental (InC). Posteriormente, se desplegó una Red Neuronal Artificial (RNA) en conjunción con GA, con 28 nodos en la capa oculta y utilizando un algoritmo de entrenamiento de descenso de gradiente. Este último algoritmo demostró una eficacia superior a los tradicionales P&O e InC en condiciones de alta irradiancia (G) y baja temperatura

(T). Basándose en estos resultados, el autor propone un enfoque sinérgico de los dos algoritmos para optimizar el rendimiento del sistema fotovoltaico. Los resultados indican que la combinación de GA, ANN y FL extrae la máxima energía del sistema.

Rahman et al. Rahman y Islam (2020) los autores de este estudio proponen un algoritmo MPPT (seguimiento del punto de máxima potencia) que utiliza un enfoque híbrido que combina redes neuronales artificiales (RNA) con la optimización por enjambre de partículas (PSO). Esta técnica se analizó en condiciones de sombreado parcial y se comparó con el algoritmo PSO fundamental. En este contexto, la RNA obtiene los datos de irradiancia de varios sensores; sin embargo, los posibles fallos de estos sensores podrían resultar problemáticos para los sistemas operativos. Los autores proponen eludir estos problemas relacionados con los sensores examinando exclusivamente la curva corriente-

Priyadarshi et al. Priyadarshi y cols. (2020) proponen un novedoso método híbrido que combina un algoritmo neurodifuso adaptativo con la optimización por enjambre de partículas (PSO). Una ventaja clave de este algoritmo es que elimina la necesidad de sensores para determinar la irradiancia (G) y la temperatura (T). Este enfoque mejora la capacidad de seguimiento de la potencia fotovoltaica, reduce el tiempo de cálculo del error cuadrático medio (RMSE) y evita la necesidad de derivar para identificar los parámetros mencionados. Funciona eficazmente en condiciones de sombreado uniforme, no uniforme y cambiante.

Prasad et al. Prasad y cols. (2016) introducen dos algoritmos distintos. El algoritmo inicial es un sistema híbrido que combina una Red Neuronal Artificial (RNA) con la Regulación Bayesiana (RB), mientras que el segundo algoritmo fusiona Algoritmos Genéticos (AG) con RNA. Estos resultados se compararon posteriormente con un método estándar de Perturbar y Observar (P&O).

En el primer caso, se emplea la RB para localizar los puntos de máxima potencia (MPP) con temperaturas (T) y niveles de irradiancia (G) variables. En el segundo caso, la RNA se entrena utilizando datos derivados del proceso de optimización GA. Los resultados demuestran una eficiencia del 87 % para el controlador de seguimiento del punto de máxima potencia (MPPT) y un error porcentual absoluto medio (MAPE) de aproximadamente 0,00842099 %. El autor sugiere la utilización de un conjunto de datos mayor para el entrenamiento con el fin de minimizar aún más el error.

Todas las simulaciones presentadas se ejecutaron utilizando el toolbox Matlab/Simulink para ANN.

## **MPPT usando Aprendizaje Automático Supervisado**

En esta subsección se hace una revisión sobre los artículos y trabajos que utilizan algoritmos de ML como RF, SVM, para encontrar el MPP en sistemas solares PV.

Shareef et al. Shareef, Mutlag, y Mohamed (2017), se introduce un enfoque novedoso para mejorar el rendimiento del seguimiento del punto de máxima potencia (MPPT), que emplea un modelo de bosque aleatorio (RF). La capacidad distintiva del modelo RF para discernir las relaciones no lineales entre las variables predictoras, tales como la irradiancia y la temperatura, le permite identificar con precisión el punto de máxima potencia. Se construye un seguidor basado en RF para 25 módulos fotovoltaicos SolarTIFSTF-120P6, con una potencia pico de 3 kW, utilizando dos sensores de alta velocidad. Para ello, se modela un sistema fotovoltaico completo utilizando 300.000 muestras de datos y se simula con el paquete MATLAB/SIMULINK. Posteriormente, el MPPT basado en RF propuesto se prueba en

condiciones ambientales reales durante un periodo de 24 días para confirmar su precisión y respuesta dinámica. La respuesta del modelo MPPT basado en RF se valida además mediante la comparación con algoritmos de redes neuronales artificiales y sistemas de inferencia neurofuzzy adaptativos. Los resultados demuestran que la técnica MPPT propuesta presenta una mejora significativa en comparación con otras técnicas. Además, el modelo RF supera con éxito la prueba de Bland-Altman, con una tasa de aceptabilidad superior al 95 por ciento.

Mahesh2022 et al. Mahesh, Meyyappan, y Alla (2022) se centra en un algoritmo de aprendizaje automático (ML) diseñado para el seguimiento óptimo del punto de máxima potencia (MPPT) en un sistema fotovoltaico (FV) aislado. Dadas las características dinámicas de las condiciones meteorológicas, la producción de energía de los sistemas fotovoltaicos sigue un patrón no lineal. No existe un método definitivo para gestionar eficazmente estos datos no lineales, lo que hace especialmente beneficiosa la aplicación de metodologías de ML para operar el sistema FV en su punto de máxima potencia (MPP). Este estudio propone una estrategia que aprovecha el algoritmo ML de regresión del árbol de decisión (DT) para identificar el MPP de un sistema FV. Los datos derivados de las especificaciones técnicas del módulo fotovoltaico se emplearon para entrenar y probar el DT. Estos algoritmos pronostican la potencia máxima disponible y la tensión correspondiente del módulo para una cantidad determinada de irradiancia y temperatura. El ciclo de trabajo del convertidor elevador se determinó utilizando estos valores predichos. Se realizaron simulaciones para un panel solar de 10 W con una corriente de cortocircuito de 0,62 A y una tensión de circuito abierto de 21,50 V a una irradiancia de 1000 W/m<sup>2</sup> y una temperatura de 25°C. Los resultados de la simulación indican que el método propuesto conduce al panel fotovoltaico a operar en el MPP predicho por DTs, mostrando un rendimiento mejorado en comparación con topologías existentes como  $\beta - MPPT$ , búsqueda de cuco, y redes neuronales artificiales. El algoritmo propuesto mejora la eficiencia en más de un 93,93 % en condiciones estacionarias a pesar de las fluctuaciones de irradiancia y temperatura.

Gonzalez-Castano et al. Gonzalez-Castano y cols. (2021) los autores proponen un método MPPT que utiliza máquinas de vectores soporte (SVM). La implementación de SVM pretende mejorar la velocidad de seguimiento eliminando las oscilaciones cerca del MPP. Para lograrlo se controla la tensión de entrada del convertidor CC-CC mediante un mecanismo de doble bucle, en el que el bucle interno se basa en el control pasivo de la corriente. La estructura MPPT propuesta se confirma mediante una verificación hardware-in-the-loop. Se emplea un simulador de alta velocidad en tiempo real, junto con un controlador de señal digital (DSC), para modelar el sistema fotovoltaico y aplicar las estrategias de control, respectivamente. La estrategia propuesta se caracteriza por su baja complejidad y es ejecutable en un DSC comercial de bajo coste (TI 28069M). El rendimiento del MPPT propuesto se presenta bajo perfiles experimentales, desafiando al sistema con variaciones en la irradiancia solar y la temperatura a través del panel. Además, el rendimiento del método propuesto se compara con el método P&O utilizado tradicionalmente bajo pruebas rigurosas, con la intención de demostrar la superioridad de la estrategia propuesta.

Mahesh et al Venkata Mahesh, Meyyappan, y Alla (2023) proponen un algoritmo novedoso para el seguimiento del MPP de un panel fotovoltaico, empleando un algoritmo de regresión de máquina de vectores soporte (SVM). En primera instancia Utilizaron los parámetros técnicos del panel PV para

generar datos para entrenar y probar el modelo SVM. Después el algoritmo estima la potencia máxima del panel fotovoltaico y la tensión correspondiente para unas condiciones de irradiación y temperatura especificadas. El ciclo de trabajo del convertidor elevador, correspondiente a la potencia máxima, se calculó utilizando estos valores predichos. Los resultados de la simulación indican que la estrategia de control propuesta induce al panel solar a operar muy cerca del MPP predicho. El algoritmo SVM logra una eficiencia de seguimiento del MPP superior al 94 % para el sistema solar fotovoltaico, incluso en condiciones climáticas variables durante el funcionamiento en estado estable. Además, se realizó un análisis comparativo contra los algoritmos existentes, para corroborar la capacidad de eficiencia del algoritmo propuesto.

### **III.- Hipótesis**

Un algoritmo basado en neuro-control y algoritmos heurísticos, logra una eficiencia del MPPT de 94 %, contemplando la T, G, V, I, como entradas y bajo condiciones ambientales cambiantes y de sombreado parcial comparado con modelos convencionales.

#### **Preguntas de investigación:**

- ¿Qué variables afectan directamente el funcionamiento del controlador MPPT?
- ¿Qué algoritmo o arquitectura RNA y algoritmo heurístico es el más adecuado para realizar un control preciso y un mejor MPPT?
- ¿Cómo afecta la complejidad del algoritmo híbrido al rendimiento del sistema PV?
- ¿Cuáles son las condiciones de implementación de un controlador híbrido neuronal?
- ¿Cómo afectan las condiciones ambientales (cambios de temperatura, radiación, sombreado) al controlador MPPT y al sistema PV?

### **IV.- Objetivos**

#### **Objetivo principal**

Diseñar e implementar un algoritmo heurístico de búsqueda del MPPT combinado con la técnica de neuro-control para obtener un rendimiento del 94 % en condiciones cambiantes de clima y de sombreado parcial.

#### **Objetivos específicos**

Los objetivos específicos de este proyecto son los siguientes:

- Implementar y simular un circuito de conversión DC-DC, que junto a las variables de tensión y corriente, añadiendo también las variables de temperatura y radiación/irradiancia, funcione como interfaz entre la carga y el controlador neuronal híbrido para el seguimiento del punto máximo de potencia.
- Realizar una selección de los algoritmos MPPT más influyentes y comprender su funcionamiento y características principales.
- Determinar las características de la red neuronal artificial y algoritmo heurístico que se usará para la implementación del controlador híbrido en la plataforma.



- Aplicar y programar los algoritmos desarrollados a la simulación del circuito de sistema PV.
- Evaluar y simular el desempeño del controlador híbrido para diferentes condiciones de operación del módulo PV. De los resultados obtenidos, comparar la salida de mi controlador híbrido con los del estado del arte para la validación de la hipótesis.

# Bases Teóricas

## Inteligencia artificial

La Inteligencia Artificial (IA) es un campo multidisciplinario que abarca desde la informática, la biología, las matemáticas y la lingüística, entre otras disciplinas. Se refiere a la capacidad de una máquina o un programa informático para aprender, razonar, percibir, comprender conceptos complejos, comunicarse y tomar decisiones de forma similar a la inteligencia humana. La premisa fundamental de la IA es crear máquinas capaces de realizar tareas que normalmente requerirían inteligencia humana, como el reconocimiento de imágenes, el reconocimiento del habla o de patrones, la toma de decisiones o el procesamiento del lenguaje natural Hussain, Dhimish, Titarenko, y Mather (2020); Rabinowitz y cols. (2018).

En el ámbito de nuestro futuro, la IA está a punto de tener un impacto transformador. Puede revolucionar nuestra forma de vivir, trabajar e interactuar. Desde los coches auto-conducidos hasta los asistentes personales inteligentes, las aplicaciones de la IA forman parte cada vez más de nuestra vida cotidiana. La influencia de la IA se extiende a todos los sectores, incluida la sanidad, donde ayuda en el diagnóstico y la atención al paciente; las finanzas, donde impulsa el comercio algorítmico y la evaluación de riesgos; la fabricación, donde mejora la automatización; y la educación, donde personaliza el aprendizaje.

Cada región del mundo percibe la IA de forma diferente. Por ejemplo, en Estados Unidos y Europa, la IA suele verse como un avance tecnológico que puede impulsar el crecimiento económico, pero también suscita preocupación por la automatización del empleo y la privacidad. Mientras tanto, en Asia, sobre todo en China, la IA se considera un componente fundamental para el desarrollo futuro, con importantes inversiones en investigación y aplicaciones de IA. En muchos países en desarrollo, la IA ofrece oportunidades únicas para un rápido desarrollo y para superar las etapas tradicionales de industrialización.

Sin embargo, a medida que la IA sigue evolucionando, conlleva consideraciones éticas, sociales y legales que deben abordarse. Cuestiones como el uso justo y transparente de los datos, el potencial de desplazamiento de puestos de trabajo y el uso responsable de la IA en la toma de decisiones son temas de debate permanente. A pesar de estos retos, los beneficios potenciales de la IA son enormes y prometen un futuro en el que las máquinas puedan aumentar las capacidades humanas, agilizar las operaciones y permitir nuevos descubrimientos.

## ¿Que es el aprendizaje automático?

El aprendizaje automático es un subcampo de la inteligencia artificial (IA) que implica el desarrollo de algoritmos y modelos estadísticos que permiten a los ordenadores aprender de los datos, sin ser programados explícitamente. El aprendizaje automático es una forma de lograr la IA Angra y Ahuja (2017); Kelleher, Mac Namee, y D'Arcy (2015); Taye (2023).

Existen diversas modalidades de aprendizaje automático, siendo las principales el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo.

En el aprendizaje supervisado, un algoritmo se entrena con un conjunto de datos etiquetados, donde se conoce previamente el resultado deseado. El algoritmo aprende a realizar predicciones basadas en los datos de entrada al identificar patrones presentes en la información Taye (2023).

En contraste, el aprendizaje no supervisado implica que un algoritmo se entrena con un conjunto de datos sin etiquetas, donde el resultado deseado no está previamente conocido. El algoritmo se esfuerza por descubrir patrones o estructuras intrínsecas en los datos de forma autónoma Taye (2023).

El aprendizaje por refuerzo, por otro lado, implica que un agente aprende a tomar decisiones interactuando con un entorno y recibiendo recompensas o penalizaciones por sus acciones Taye (2023).

Los algoritmos y modelos de aprendizaje automático se aplican en una amplia variedad de tareas, tales como reconocimiento de imágenes, procesamiento del lenguaje natural, detección de objetos, control automático, entre otras. Su aplicación se extiende ampliamente en la industria, destacando su uso en vehículos autónomos, detección de fraudes, sistemas de recomendación, y en numerosos campos más Angra y Ahuja (2017).

Cabe destacar que el aprendizaje automático ha experimentado un notable avance en los últimos años, siendo crucial para el desarrollo de tecnologías emergentes y soluciones innovadoras en diversos dominios.

## ¿Que son las redes neuronales artificiales?

Las Redes Neuronales Artificiales (RNA) derivan su denominación y conceptualización de las intrincadas redes de células neuronales presentes en el cerebro humano, una estructura que puede albergar centenas de billones de estas células especializadas, conocidas como neuronas, las cuales están interrelacionadas mediante sinapsis. Las áreas receptoras de estímulos de las neuronas son denominadas dendritas, mientras que las áreas transmisoras de impulsos se identifican como axones.

Un impulso neural o mensaje puede ser iniciado por cualquier célula y transmitido a través de los axones, alcanzando otras dendritas mediante el proceso sináptico. Cuando una serie de impulsos alcanza las áreas dendríticas de una neurona, se incrementa la probabilidad de que la neurona en foco genere un impulso a lo largo de sus axones. A medida que los impulsos se trasladan de una neurona a otra, son modulados por la potencia sináptica de las interconexiones para integrar información local Taye (2023).

Consecuentemente, el cerebro humano se configura como una estructura de procesamiento de información paralela y distribuida, compuesta por elementos de procesamiento capaces de realizar operaciones de procesamiento de información localizadas. La magnitud considerable de neuronas, así como la elevada densidad de interconexiones, constituyen elementos cruciales del notable poder de procesamiento cerebral. Las Redes Neuronales Artificiales son conceptualizadas y nombradas en base a este procedimiento neurobiológico Kelleher y cols. (2015).

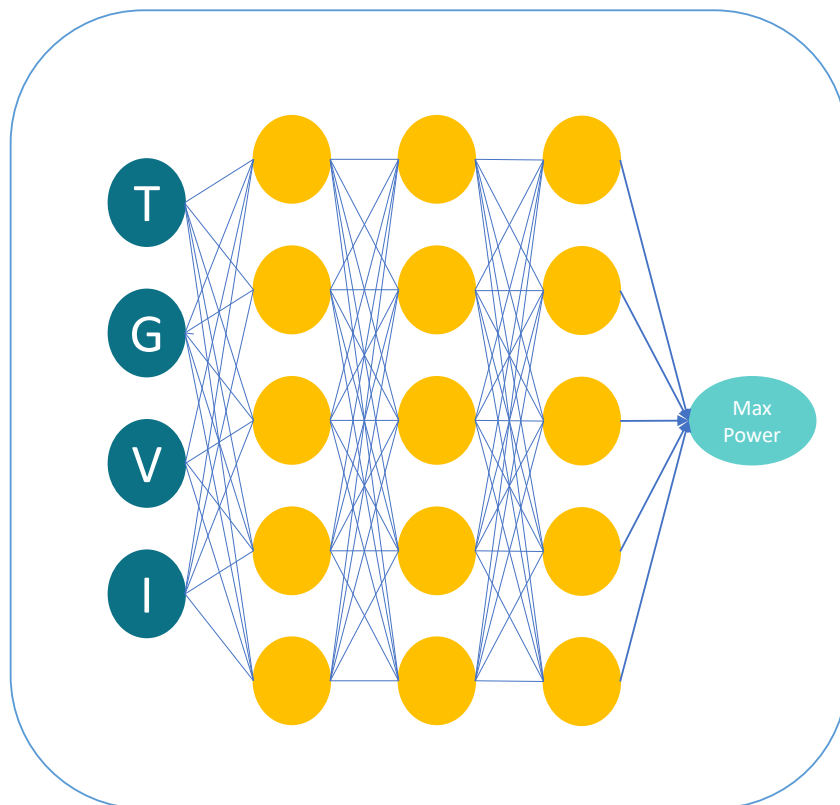
Estas se caracterizan por su arquitectura paralela compuesta por neuronas con un alto grado de conexiones y un largo grado de retroalimentación. Los datos de entrada pueden venir del mundo de afuera o de otras neuronas dentro de la misma red. Es multiplicada por su peso  $w$  ( $w_1, w_2, \dots, w_n$ ) análogo a la fuerza sináptica de la red biológica. Las entradas pesadas son sumadas para producir la cantidad llamada *net*.

La neurona actúa en esta *net* y usa una función de transferencia no lineal  $f$  para calcular su salida. A veces, se agrega un término de sesgo a la suma antes de pasar a través de la función de transferencia de

la neurona para producir la salida. El resultado calculado se envía a lo largo de las conexiones de salida a las celdas objetivo por la línea. Se envía el mismo valor de salida a lo largo de todas las conexiones de salida.

En la Figura 2 se observa un ejemplo de una red neuronal, está compuesta por 3 partes bien diferenciadas: capa de entrada, capas ocultas y capa de salida. Esta red posee 4 entradas, dos capas ocultas y dos salidas.

## Multilayer Artificial Neural Network



**Figura 2**  
*Perceptron Multicapa.*

### **Tipos de arquitecturas**

La configuración de conexiones, patrones o estructuras dentro de una Red Neuronal Artificial (RNA) se define como su arquitectura, determinada por la disposición de las neuronas agrupadas en unidades conocidas como capas. La RNA, en su conjunto, se compone de estas capas.

En los modelos fundamentales, se identifican tres capas principales: la capa de entrada, la capa o capas ocultas y, finalmente, la capa de salida. La capa de entrada es el punto de recepción de los datos, que

pueden provenir de sensores captando señales del entorno. La capa de salida representa la respuesta a todos los procesos sinápticos internos de la red y puede actuar como un efector en el contexto de un sistema robótico. La capa oculta desempeña la función de llevar a cabo los procesos, como cálculos y correcciones, que representan el entorno a modelar Larranaga y Inza (2021).

Desde una perspectiva estructural, se distinguen las redes monocapa (SLNN), conformadas por una única capa de neuronas, y las redes multicapa (MLNN), que constan de múltiples nodos distribuidos en diversas capas. Las MLNN, en función del flujo de datos, pueden ser unidireccionales (feedforward), donde la información se desplaza en una sola dirección, y redes recurrentes (RNN) o feedforward, en las que la información puede fluir en cualquier dirección, incluso de la capa de salida a la de entrada Zador (2019).

El cálculo de los pesos en una RNA no es una tarea trivial. En términos generales, la única solución disponible es la aproximación mediante el método de prueba y error. Sin embargo, para casos específicos, como se detalla a continuación, se han desarrollado algunas aproximaciones. Para determinar el número total de pesos en una RNA multicapa feedforward de una sola capa, se puede utilizar la siguiente definición:

$$\text{Numero de entradas} \times \text{tamaño de la capa oculta} + \text{tamaño de la capa oculta} \times \text{tamaño de la capa de salida} \quad (1)$$

Existen otros métodos para cada arquitectura en particular, que deben investigarse antes de cualquier aplicación. Karsoliya (2012).

## Problemas de Optimización

La optimización es el proceso de encontrar la mejor solución entre un conjunto de posibles soluciones a un problema. La "mejor" solución viene determinada por una función de optimización o función de coste, que asigna un valor a cada posible solución. El objetivo de la optimización es encontrar la solución que dé como resultado el valor más alto para la función de optimización (o el valor más bajo para una función de coste) Dominico y Parpinelli (2021).

La optimización puede realizarse para una amplia gama de problemas, como modelos de aprendizaje automático, sistemas de control, logística y muchos otros campos. Hay muchos algoritmos de optimización que pueden utilizarse para encontrar la mejor solución, como el descenso de gradiente, los algoritmos genéticos, el recocido simulado y muchos otros Morales-Enciso y Branke (2015).

### Óptima local vs. Óptima global

Un óptimo local es un punto del espacio de búsqueda de un problema en el que un algoritmo de optimización ha determinado que ningún punto vecino tiene un valor mejor para la función de optimización.

Es la "mejor" solución entre los puntos cercanos, pero puede que no sea la mejor solución global para todo el problema.

Por otro lado, un óptimo global es la mejor solución entre todas las soluciones posibles de un problema. Es el punto en el espacio de búsqueda de un problema que tiene el valor más alto para la función de optimización, o el valor más bajo para una función de coste. Es la solución óptima para todo el problema, a diferencia de un óptimo local, que sólo es óptimo entre los puntos cercanos a él en el espacio de búsqueda Cano, Alfaro, Gomez, y Duarte (2022); Dominico y Parpinelli (2021); Morales-Enciso y Branke (2015).

## **Optimización en el contexto del seguimiento del punto de máxima potencia**

En el contexto del seguimiento del punto de máxima potencia (MPPT) para sistemas fotovoltaicos (PVS), los óptimos locales y los óptimos globales significan puntos en los que el sistema extrae la máxima potencia de los paneles PVS.

Un óptimo local se encuentra dentro del rango de funcionamiento del panel fotovoltaico, lo que permite al sistema extraer la máxima potencia localmente, pero puede no ser el punto óptimo para todo el sistema. Si el algoritmo MPPT no puede encontrar el óptimo global, puede quedarse atascado en un óptimo local. El objetivo del algoritmo MPPT es encontrar el óptimo global, que representa el punto en el que el panel fotovoltaico genera la mayor potencia, garantizando la máxima extracción de energía. Sin embargo, dependiendo del algoritmo y de la calidad de los datos, el MPPT puede quedar atrapado en un óptimo local, lo que conduce a una producción de potencia subóptima.

El concepto de punto de máxima potencia global (GMPP) se refiere a la potencia máxima absoluta alcanzable por un sistema fotovoltaico (FV) en unas condiciones dadas, independientemente de las condiciones meteorológicas o del estado del sistema.

## **¿Como optimizar aun mas a las redes neuronales?**

Hay varias formas de optimizar los algoritmos de redes neuronales, algunas de las cuales son:

- **Inicialización de pesos:** Los valores iniciales de los pesos en una red neuronal pueden tener un impacto significativo en su rendimiento. Las técnicas más comunes para la inicialización de pesos incluyen la inicialización aleatoria, la inicialización de Xavier y la inicialización de He Mazaheri, Rahnamayan, y Bidgoli (2022).
- **Datos de entrenamiento y preprocesamiento:** La calidad y cantidad de los datos de entrenamiento puede tener un impacto significativo en el rendimiento de una red neuronal. Las técnicas de preprocesamiento de datos, como la normalización, el aumento de datos y el escalado de características, también pueden utilizarse para mejorar el rendimiento de la red.
- **Regularización:** En las redes neuronales, el sobreajuste es una preocupación común. Para abordar este problema, se pueden emplear diversas técnicas de regularización, como la regularización L1

y L2, el abandono y la detención temprana. Estas estrategias son útiles para prevenir el sobreajuste y mejorar la capacidad de generalización de la red.

- Algoritmos de optimización: Para optimizar los pesos de una red neuronal se pueden utilizar algoritmos de optimización como el descenso de gradiente estocástico (SGD), Adam y Adagrad. Estos algoritmos también pueden combinarse con otras técnicas como el impulso y la programación de la tasa de aprendizaje
- Arquitectura de la red neuronal: La arquitectura de una red neuronal, como el número de capas, el número de neuronas por capa y el tipo de función de activación, puede tener un impacto significativo en su rendimiento. Para optimizar la arquitectura de una red neuronal pueden utilizarse técnicas como la búsqueda de arquitectura neuronal (NAS), el aprendizaje por transferencia y el aprendizaje por conjuntos.
- Ajuste de hiperparámetros: Las redes neuronales tienen muchos parámetros, conocidos como hiperparámetros, que deben ajustarse. El ajuste de hiperparámetros, también conocido como optimización de hiperparámetros, es el proceso de búsqueda sistemática de la mejor combinación de hiperparámetros. Para optimizar los hiperparámetros de una red neuronal se pueden utilizar técnicas como la búsqueda en cuadrícula, la búsqueda aleatoria y la optimización bayesiana.

La optimización de redes neuronales constituye un procedimiento iterativo, y puede resultar imperativa la utilización de una combinación de estas técnicas con el fin de alcanzar el rendimiento óptimo. Además, dicho logro puede estar condicionado por la naturaleza del problema que se busca resolver y las características particulares del conjunto de datos en cuestión.

Para finalizar y generar un breve resumen, existen varias técnicas que se pueden utilizar para optimizar los algoritmos de redes neuronales, como la inicialización de pesos, los datos de entrenamiento y el preprocesamiento, la regularización, los algoritmos de optimización, la arquitectura de redes neuronales y el ajuste de hiperparámetros. Cada una de ellas desempeña un papel importante en el rendimiento global de la red neuronal y a menudo es necesaria una combinación de estas técnicas para obtener los mejores resultados.

## **¿Que es la optimización de hiper-parámetros en las ANN?**

La optimización de hiperparámetros, también denominada ajuste de hiperparámetros, constituye el procedimiento sistemático para identificar la configuración óptima de hiperparámetros, necesarios para el funcionamiento de los diferentes algoritmos de aprendizaje automático, con especial énfasis en las redes neuronales. Se definen como parámetros preestablecidos antes del inicio del entrenamiento del modelo, son generalmente establecidos por el usuario, o se definen con parámetros recomendados Y. A. Ali, Awwad, Al-Razgan, y Maarouf (2023); Antunes, Ferreira, Marques, y Carriço (2023); Elgeldawi, Sayed, Galal, y Zaki (2021). contrastan con los parámetros (por ejemplo, pesos y sesgos en las redes neuronales) que se aprenden intrínsecamente durante la fase de entrenamiento.

En el ámbito de las redes neuronales, la selección de hiperparámetros puede influir profundamente en la eficacia del modelo resultante. Algunos hiperparámetros fundamentales son:

- **Tasa de aprendizaje:** Este parámetro define la magnitud del paso incremental durante cada iteración a medida que el modelo gravita hacia el mínimo de la función de pérdida. Una tasa de aprendizaje reducida puede dar lugar a una optimización más estable, aunque a un ritmo más lento, mientras que una tasa aumentada puede acelerar el entrenamiento, pero con el riesgo de pasar por alto el mínimo óptimo.
- **Tamaño del lote:** Definido como la cantidad de ejemplares de entrenamiento empleados en una iteración singular para el ajuste de los pesos del modelo.
- **Cantidad de épocas:** Representa el total de iteraciones en las que el algoritmo trabaja con el conjunto completo de datos de entrenamiento.
- **Cantidad de capas:** Medida de la profundidad de la red neuronal.
- **Cantidad de neuronas:** El número específico de nodos o neuronas dentro de una capa individual.
- **Funciones de activación:** Funciones no lineales, como ReLU, tanh y sigmoide, integradas en la red.
- **Protocolos de inicialización de pesos:** Metodologías prescritas para las asignaciones preliminares de pesos, incluidas, entre otras, las inicializaciones de Xavier o He.
- **Algoritmo de optimización:** El algoritmo designado invocado para recortar la función de pérdida, entre cuyos ejemplos se incluyen SGD, Adam y RMSprop.
- **Tasa de abandono:** Estrategia de regularización en la que se excluye un subconjunto arbitrario de neuronas durante las iteraciones de entrenamiento, lo que sirve para mitigar el fenómeno del sobreajuste.
- **Técnicas de regularización:** Metodologías instituidas para contrarrestar el sobreajuste, que abarcan los enfoques de regularización L1 y L2.

## Algoritmos Meta-heuristicos

Los algoritmos meta-heurísticos son una clase de algoritmos de optimización aproximada muy utilizados para resolver problemas de optimización complejos. El término "meta-heurístico" procede de las palabras griegas "meta", que significa "superior", y "heurístico", que significa encontrar Yang (2020). Estos algoritmos se caracterizan por los siguientes atributos:

1. **Independencia del problema:** Los algoritmos meta-heurísticos están diseñados para resolver una amplia gama de problemas de optimización y no están adaptados a un problema específico Sörensen (2015).



2. **Calidad de la solución:** Proporcionan soluciones lo suficientemente buenas para fines prácticos, aunque no siempre sean la solución óptima.
3. **Utilización de procesos estocásticos:** Los algoritmos meta-heurísticos suelen incorporar variables aleatorias y probabilidades para escapar de los óptimos locales y explorar más a fondo el espacio de búsqueda.
4. **Equilibrio entre búsqueda local y global:** Equilibran entre exploración (búsqueda global) y explotación (búsqueda local). La exploración ayuda a evitar los mínimos locales buscando nuevas áreas en el espacio de búsqueda, mientras que la explotación ayuda a afinar las soluciones en áreas prometedoras.
5. **Proceso iterativo:** Estos algoritmos suelen emplear un proceso iterativo que refina progresivamente las soluciones candidatas.
6. **Adaptabilidad:** Los algoritmos metaheurísticos pueden adaptarse a diferentes dominios de problemas modificando la heurística o mediante la hibridación con otras técnicas.
7. **Basados en la población o en un único punto:** Algunas metaheurísticas, como los algoritmos genéticos o la optimización por enjambre de partículas, utilizan una población de soluciones y realizan operaciones sobre toda esta población. Otras, como Simulated Annealing o Hill Climbing, parten de un único punto y realizan movimientos locales para mejorar la solución.

Algunos ejemplos comunes de algoritmos metaheurísticos son los algoritmos genéticos Yang (2020), la optimización por enjambre de partículas Kennedy y Eberhart (1995a), la optimización por colonia de hormigas Dorigo y Stützle (2004), el templado simulado y la búsqueda tabú Venkateswarlu (2021). Cada uno de estos algoritmos tiene sus propias características y estrategias para explorar el espacio de soluciones de los problemas de optimización

## Utilización de procesos estocásticos en algoritmos meta-heurísticos

Los algoritmos metaheurísticos suelen emplear procesos estocásticos como parte de su estrategia de búsqueda. Los procesos estocásticos son aquellos en los que influye el azar. En el contexto de la metaheurística, los procesos estocásticos se utilizan para escapar de los óptimos locales y explorar el espacio de búsqueda con mayor eficacia.

- **Soluciones aleatorias:** Los algoritmos metaheurísticos suelen comenzar generando una solución inicial al problema de forma aleatoria. Este inicio estocástico ayuda a garantizar una amplia exploración del espacio de búsqueda.
- **Operadores aleatorios:** Muchos meta-heurísticos utilizan operadores (como la mutación en los algoritmos genéticos o la actualización de la velocidad en la optimización por enjambre de partículas) que implican componentes aleatorios. Esta aleatoriedad introduce variabilidad y ayuda a la búsqueda a escapar de los óptimos locales.

- **Toma de decisiones probabilística:** Algunas meta-heurísticas como el Recocido Simulado emplean la toma de decisiones probabilística en su estrategia de búsqueda. En el templado simulado, incluso las soluciones peores que la actual tienen una cierta probabilidad de ser aceptadas, especialmente en las primeras fases del algoritmo. Esta estrategia de aceptación estocástica ayuda al algoritmo a evitar quedarse atascado en óptimos locales.
- **Búsqueda aleatoria de vecindarios:** Algunas meta-heurísticas seleccionan estocásticamente un subconjunto de la vecindad de una solución para su exploración, en lugar de explorar toda la vecindad. Esto es habitual en algoritmos como Tabu Search y Variable Neighborhood Search.

Recuerde que el principal objetivo de utilizar procesos estocásticos es equilibrar el compromiso entre exploración y explotación. Si se explora demasiado, el algoritmo puede tardar demasiado en converger. Demasiada explotación y el algoritmo podría quedarse atascado en un óptimo local. Los procesos estocásticos, cuando se utilizan correctamente, pueden ayudar a conseguir este equilibrio.

## Algoritmo Optimizador Lobo Gris

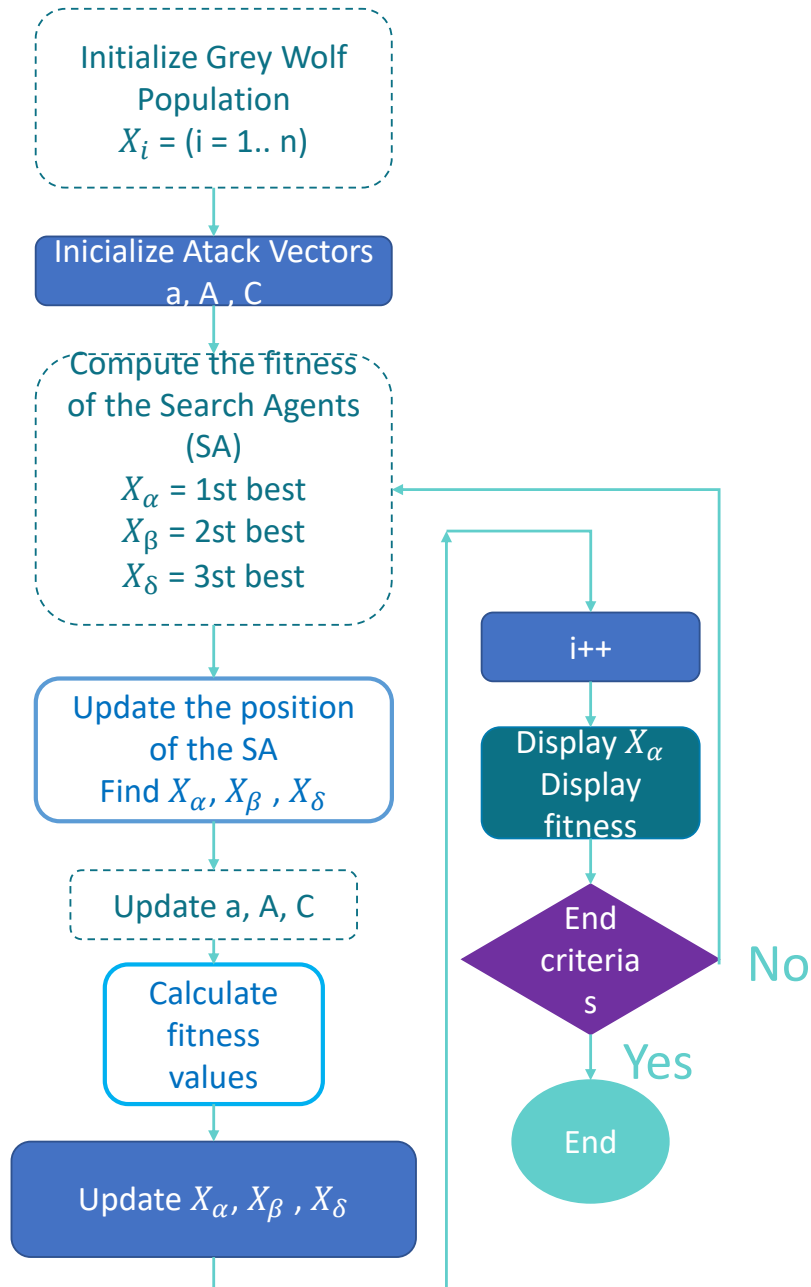
El Optimizador Lobo Gris (GWO) Mirjalili et al. Mirjalili, Mirjalili, y Lewis (2014) es un algoritmo de optimización meta-heurístico inspirado en la naturaleza y basado en el comportamiento social y los mecanismos de caza de los lobos grises. El objetivo principal de GWO, al igual que otros algoritmos de optimización, es encontrar la mejor solución a un problema dado mediante la búsqueda eficiente en el espacio de soluciones.

Los lobos grises presentan una estructura social jerárquica, con cuatro categorías principales: alfa ( $\alpha$ ), beta ( $\beta$ ), delta ( $\delta$ ) y omega ( $\omega$ ). En la GWO, estas categorías desempeñan papeles diferentes:

- Alfa ( $\alpha$ ): Líder de la manada, el lobo alfa toma decisiones sobre la caza, el sueño y la vigilia. En el algoritmo, el lobo alfa representa la mejor solución encontrada hasta el momento.
- Beta ( $\beta$ ): El segundo al mando, el lobo beta ayuda al alfa en la toma de decisiones. En el algoritmo, el lobo beta representa la segunda mejor solución encontrada hasta el momento.
- Delta ( $\delta$ ): Los lobos subordinados responsables de mantener la disciplina en la manada. En el algoritmo, los lobos delta representan otras soluciones potencialmente buenas.
- Omega ( $\omega$ ): Los lobos de menor rango de la manada, los lobos omega son responsables de ejecutar las tareas asignadas por los lobos de mayor rango. En el algoritmo, los lobos omega exploran el espacio de soluciones y siguen el ejemplo de los lobos alfa, beta y delta.

El algoritmo GWO parte de una población inicial de soluciones potenciales (lobos) y actualiza iterativamente sus posiciones en el espacio de búsqueda basándose en las posiciones de los lobos alfa, beta y delta. Los lobos convergen hacia la mejor solución encontrada hasta el momento, y el algoritmo termina cuando se alcanza un criterio de parada (por ejemplo, un número máximo de iteraciones).

El GWO se ha aplicado a diversos problemas de optimización, como la optimización de funciones, el aprendizaje automático, la programación y los sistemas de control, gracias a su capacidad para escapar de los óptimos locales y encontrar óptimos globales de forma eficiente.



**Figura 3**  
Diagrama de flujo del algoritmo Optimizador Lobo Gris.

## Algoritmo de Optimización por Enjambre de Partículas

La optimización por enjambre de partículas (PSO) fue desarrollada por Kennedy et al. en 1995 Kennedy y Eberhart (1995b), basándose en el comportamiento de los enjambres observado en la naturaleza, como el de los peces y las aves. Desde entonces, los algoritmos PSO han suscitado mucha atención y ahora constituye un tema de investigación muy interesante, y que esta en constante expansión en el campo de la inteligencia basadas en el comportamiento de los enjambres. Las PSO han sido aplicados a casi todos los ámbitos de la optimización, la inteligencia computacional tanto en aplicaciones de diseño y programación Devarakonda y Bozic (2022); Wang, Xue, y Zhang (2020).

Existen al menos dos docenas de variantes de PSO, así como algoritmos híbridos obtenidos mediante la combinación de PSO con otros algoritmos existentes, que también son cada vez más populares Junior y Yen (2019); Rahman y Islam (2020).

Los principales componentes de PSO son las partículas, que representan soluciones potenciales al problema que se está optimizando. Cada partícula tiene una posición y una velocidad dentro del espacio de búsqueda. La posición de una partícula representa una solución candidata, y su velocidad determina cómo se desplaza la partícula por el espacio de búsqueda. Las partículas "vuelan" por el espacio de búsqueda ajustando sus posiciones y velocidades en función de su propia posición mejor conocida (llamada pbest) y de la posición mejor conocida de todo el enjambre (llamada gbest) Dai, Chen, y Zheng (2018); Mazaheri y cols. (2022).

El algoritmo se puede definir de la siguiente manera:

1. Inicializar un enjambre de partículas con posiciones y velocidades aleatorias dentro del espacio de búsqueda.
2. Evaluar la aptitud de la posición de cada partícula (solución).
3. Actualizar el pbest de cada partícula si su posición actual es mejor (tiene una aptitud mayor) que su pbest anterior.
4. Actualizar el gbest del enjambre si el pbest de alguna partícula es mejor que el gbest actual.
5. Actualizar la velocidad y posición de cada partícula usando las siguientes ecuaciones:

$$v = \omega * v + c_1 * r_1 * (p_{best} - x) + c_2 * r_2 * (g_{best} - x) \quad (2)$$

$$x = x + v \quad (3)$$

donde:

- $v$  es la velocidad.
- $\omega$  es la inercia.
- $c_1$  y  $c_2$  son los factores cognitivos y sociales respectivamente.

- $r1$  y  $r2$  son números aleatorios entre 0 y 1.
- $pbest$  es la mejor posición personal.
- $gbest$  es la mejor posición global.
- $x$  es la posición actual.

Repita los pasos 2-5 hasta que se cumpla un criterio de parada (por ejemplo, un número máximo de iteraciones o un valor de aptitud aceptable).

El algoritmo PSO es relativamente fácil de implementar, tiene pocos parámetros de ajuste y puede aplicarse a una amplia gama de problemas de optimización. Ha demostrado ser eficaz para encontrar óptimos globales en muchos casos, aunque a veces puede quedar atrapado en óptimos locales, dependiendo del problema y de la configuración de los parámetros.

## Optimización mediante Algoritmos Genéticos

El algoritmo genético, inicialmente propuesto por Holland et al. Holland (1975) en su obra "Adaptation in Natural and Artificial Systems", destaca como uno de los algoritmos metaheurísticos o bioinspirados más reconocidos. Inspirado en la teoría darwiniana de la supervivencia del más apto, fue pionero en el uso de conceptos como el cruce, la recombinación, la mutación y la selección en el estudio de sistemas adaptativos y artificiales. Hoy en día, se emplea ampliamente en ciencias de la computación y diversas disciplinas para abordar problemas de optimización, tanto con restricciones como sin ellas, modelando su funcionamiento a partir de la evolución biológica.

Los algoritmos genéticos (AG) destacan como una de las variantes más populares de los algoritmos evolutivos, siendo aplicados con éxito en una variedad de problemas de optimización. Su enfoque basado en poblaciones ha influido en muchos algoritmos evolutivos modernos, directa o indirectamente.

Estos algoritmos utilizan operadores genéticos como elementos fundamentales para resolver problemas, codificando soluciones como matrices de bits o cadenas de caracteres (cromosomas), y aplicando manipulaciones mediante operadores genéticos. La selección, cruce y mutación, proporcional a la aptitud, son esenciales en la creación de nuevas poblaciones. Los pasos se repiten a lo largo de varias generaciones hasta obtener una solución. La función de aptitud, crucial en este proceso, debe garantizar que los cromosomas más aptos sean seleccionados con mayor frecuencia. La codificación y decodificación, así como la elección adecuada de parámetros como las probabilidades de cruce y mutación, también son aspectos esenciales en la efectividad del algoritmo genético.

Cuestiones como el elitismo, la mutación en múltiples sitios y la determinación del tamaño de la población también desempeñan roles importantes en la eficacia del algoritmo. La elección cuidadosa de estos aspectos garantiza un proceso de evolución efectivo, evitando convergencias prematuras o soluciones incorrectas.

# Análisis de series de tiempo

## ¿Que son las series de tiempo?

Una serie temporal es una secuencia de puntos de datos recogidos o registrados a lo largo del tiempo a intervalos regulares o irregulares. Cada punto de datos de una serie temporal suele representar una observación o medición de una determinada variable de interés. Los datos de series temporales pueden encontrarse en diversos campos, como las finanzas, la economía, la meteorología, las ciencias sociales y la ingeniería Alsharif, Sonia, Kumar, y Iwendi (2022); Peixeiro (2022).

Algunos ejemplos de series temporales son:

1. Precios de las acciones: El precio de cierre diario de las acciones de una empresa durante un periodo determinado.
2. Medidas de temperatura: Lecturas horarias de temperatura de una estación meteorológica.
3. Datos de ventas: Cifras de ventas mensuales de un producto o servicio.
4. Consumo de electricidad: Consumo eléctrico horario de un hogar o una instalación industrial.

## Series de tiempo lineales

Las series temporales lineales son secuencias de puntos de datos cuyos patrones y estructuras subyacentes pueden modelarse o explicarse mediante relaciones lineales. En los modelos de series temporales lineales, se supone que el valor futuro de la serie es una combinación lineal de sus valores pasados, errores pasados y/o factores externos. Los modelos lineales suelen ser más sencillos y fáciles de interpretar que los no lineales Chatfield y Xing (2019); Peixeiro (2022).

Ejemplos de series temporales lineales:

1. Los datos de ventas mensuales de un producto cuyas cifras de ventas siguen una tendencia lineal con cierta estacionalidad.
2. El precio de cierre diario de un activo financiero estable con un crecimiento o descenso lineal constante a lo largo del tiempo.
3. El número de pasajeros que utilizan un sistema de transporte público, con un aumento o disminución lineal a lo largo del tiempo y cierta estacionalidad.
4. El consumo energético diario de un edificio, que podría tener una relación lineal con factores como la temperatura exterior, el día de la semana y la ocupación.

Es importante señalar que no todos los datos de series de tiempo presentan patrones lineales. En muchos casos, pueden ser necesarios modelos o transformaciones no lineales para captar con precisión las relaciones subyacentes en los datos.

## **Series de tiempo no lineales**

Las series temporales no lineales se refieren a datos de series temporales que no muestran una relación lineal entre las variables. En otras palabras, la relación entre las variables no queda bien reflejada por una línea recta o una ecuación lineal. En su lugar, la relación puede ser curva o mostrar otros tipos de patrones no lineales Kantz y Schreiber (2003).

Las series temporales de este tipo son más difíciles de analizar y modelizar que las series temporales lineales, porque las relaciones matemáticas entre las variables pueden ser más complejas. Sin embargo, también son más comunes en muchas aplicaciones del mundo real, como las finanzas, los modelos climáticos y la neurociencia Ambika y Harikrishnan (2020).

Existen muchos métodos diferentes para analizar series temporales no lineales, dependiendo de las características específicas de los datos y de la pregunta de investigación. Algunos métodos comunes son la teoría del caos, el análisis de recurrencia y la regresión no paramétrica. Los métodos de aprendizaje automático, como las redes neuronales y las máquinas de vectores de soporte, también pueden utilizarse para modelar series temporales no lineales.

## **La división entrenamiento-prueba-validación**

En las redes neuronales, la división entrenamiento-prueba-validación es una técnica habitual para evaluar el rendimiento del modelo y evitar el sobreajuste. El conjunto de datos se divide en tres conjuntos: el conjunto de entrenamiento, el conjunto de validación y el conjunto de prueba. El tamaño de cada conjunto puede variar, pero una división común es 60 % para entrenamiento, 20 % para validación y 20 % para pruebas Pawluszek-Filipiak y Borkowski (2020).

El conjunto de entrenamiento se utiliza para entrenar el modelo. Durante el proceso de entrenamiento, el modelo recibe datos de entrada y los resultados correspondientes se comparan con los esperados. Los pesos del modelo se ajustan mediante un algoritmo de optimización, como el descenso de gradiente, para minimizar la diferencia entre la salida prevista y la salida esperada. Este proceso se repite de forma iterativa hasta que el modelo alcanza un rendimiento satisfactorio en el conjunto de entrenamiento.

El conjunto de validación se utiliza para ajustar los hiperparámetros del modelo, como la tasa de aprendizaje o el número de capas ocultas. El modelo se evalúa en el conjunto de validación después de cada época de entrenamiento, y los hiperparámetros se ajustan en función del rendimiento en el conjunto de validación. Este proceso se repite hasta que el modelo alcanza un rendimiento satisfactorio en el conjunto de validación.

El conjunto de pruebas se utiliza para evaluar el rendimiento final del modelo. Una vez entrenado el modelo y ajustados los hiperparámetros, se evalúa en el conjunto de pruebas para medir su rendimiento de generalización. El conjunto de pruebas es un conjunto de datos que el modelo nunca ha visto antes, por lo que proporciona una estimación no sesgada del rendimiento del modelo en datos nuevos y no vistos Xu y Goodacre (2018).

La división de entrenamiento-prueba-validación es un paso crítico en el proceso de construcción de redes neuronales, ya que permite una evaluación imparcial del rendimiento del modelo y ayuda a prevenir el sobreajuste Ying (2019). Al dividir el conjunto de datos en tres conjuntos, el modelo puede entrenarse,

validarse y probarse con datos diferentes, lo que ayuda a garantizar que el modelo puede generalizarse bien a datos nuevos y desconocidos Pawluszek-Filipiak y Borkowski (2020).

## Métricas estadísticas para la validación de datos

En esta subsección, se introducen métricas e indicadores pertinentes para la evaluación de modelos predictivos. Estas medidas han sido meticulosamente seleccionadas basándose en una revisión exhaustiva de la literatura contemporánea y sirven para determinar la precisión de los datos. A pesar del hecho de que el Error Porcentual Absoluto Medio (MAPE) y la precisión son comúnmente considerados como las métricas más confiables para análisis predictivos, este estudio incluye cuatro métricas adicionales altamente valoradas identificadas a través de una revisión exhaustiva de trabajos precedentes en este campo de estudio. Philibus, Sallehuddin, Yussof, y Yusuf (2021).

**El Error Cuadrado Medio (MSE):** Este es quizás una de las métricas más sencillas que se pueden calcular en el campo del aprendizaje automático. El MSE esencialmente toma la discrepancia entre las predicciones hechas por el modelo y los datos reales o verdad fundamental, cuadra esta diferencia, y calcula la media para todo el conjunto de datos. Una característica notable del MSE es que su valor nunca será inferior a cero.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (4)$$

**El error cuadrático medio (RMSE):** calcula la bondad del ajuste, que está relacionado con la prevención de errores muy elevados.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (5)$$

**El error medio porcentual absoluto (MAPE):** Su función es calcular el error absoluto en porcentaje de las variables predichas u observadas Wu y Ying (2019).

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_i - \hat{y}}{y_i} \right| * 100 \quad (6)$$

**El error medio absoluto (MAE):** es un indicador del rendimiento del modelo de predicción, esto se consigue observando lo cerca que están las variables predichas de las variables observadas.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (7)$$

**R-cuadrado o coeficiente de determinación:** es la medida estadística que mide en porcentaje la aproximación de los datos a la recta de regresión. Alvarez-Alvarado, Moreno, Ventura-Ramos, Ronquillo-Lomeli, y Trejo-Perea (2020).

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (8)$$



Estos indicadores permiten conocer la eficacia de los modelos de aprendizaje automático: Si el valor del indicador estadístico es cero en el caso ideal.

## **Sistemas fotovoltaicos**

En esta sección se describe la teoría sobre los sistemas fotovoltaicos, donde se definen los términos comunes para entender el comportamiento de la energía fotovoltaica. Posteriormente se describen los módulos fotovoltaicos y los convertidores CC/CC. Se ha analizado el comportamiento de las células y de los módulos fotovoltaicos para su simulación mediante modelos informáticos. Para analizar, se definen los algoritmos de control, para el MPPT, utilizados en esta tesis.

### **Efecto fotovoltaico**

El efecto fotovoltaico (PVE) es un proceso por el cual la luz se transforma en electricidad. Eso se logra mediante las propiedades de los materiales que absorben fotones y emiten electrones. Cuando la radiación solar es absorbida, esta energía se trasfiere al electron, con esta energía, el electron se escapa del atomo y se une a la corriente que fluye en un circuito electrico. Este proceso de conversión de la energía luminosa en energía eléctrica mediante el efecto fotovoltaico es lo que permite a los paneles solares generar electricidad. Alhamer, Grigsby, y Mulford (2022); Balfour, Shaw, y Nash (2013); Messenger y Abtahi (2017).

### **Radiación Solar**

Irradiancia y radiación solar son conceptos interconectados que describen la cantidad de energía emitida por el sol y recibida en la superficie terrestre.

La radiación solar representa el espectro completo de la energía liberada por el sol, cuantificada en vatios por metro cuadrado ( $W/m^2$ ). Abarca todas las formas de radiación electromagnética, como la ultravioleta (UV), la luz visible y la radiación infrarroja (IR) Messenger y Abtahi (2017); Motahhir y Eltamaly (2021).

### **Irradiancia**

La radiancia solar (SI) cuantifica la radiación solar incidente sobre una superficie determinada y se mide en  $W/m^2$ . Por el contrario, la irradiancia solar (G) evalúa la cantidad de energía solar que llega a una superficie durante un periodo de tiempo determinado y se expresa en  $Wh/m^2$ . La irradiancia es un parámetro esencial para evaluar el rendimiento de los sistemas fotovoltaicos (FV), ya que influye directamente en la energía producida por los paneles FV Atsu y Dhaundiyal (2019); Messenger y Abtahi (2017); Motahhir y Eltamaly (2021).

## Temperatura Ambiental

La temperatura (T), también denominada temperatura ambiente, representa el grado de calor presente en el entorno de un sistema fotovoltaico (FV). En relación con los sistemas fotovoltaicos, también puede denotar la temperatura operativa para que las células o conjuntos fotovoltaicos funcionen eficientemente. Al igual que ocurre con otros componentes electrónicos, el rendimiento de un panel fotovoltaico puede disminuir a medida que aumenta la temperatura. Esta reducción de la potencia resultante de una temperatura elevada puede cuantificarse mediante un "coeficiente de temperatura", que el fabricante suministra para cada modelo de panel fotovoltaico. Atsu y Dhaundiyal (2019); Köppen (2011); Messenger y Abtahi (2017).

## Celda Fotovoltaicas

Las células fotovoltaicas (PVC) son aparatos electrónicos diseñados para convertir la luz solar en corriente continua (CC), un proceso cuya eficacia varía en función de la intensidad de la luz solar. Las PVC se construyen a partir de finas capas de materiales semiconductores en los que los electrones de valencia están más firmemente ligados al núcleo atómico. Sin embargo, con una modesta cantidad de energía, estos electrones se comportan como conductores. Para las aplicaciones prácticas, la corriente continua debe convertirse en corriente alterna (CA) a la tensión deseada, normalmente mediante el uso de inversores .

Normalmente, se interconectan varios PVC para formar módulos que, a su vez, se conectan para crear matrices. A continuación, estas matrices se conectan a un inversor, que genera energía a la tensión deseada. Este proceso de generación de energía mediante sistemas fotovoltaicos está bien documentado en la literatura científica, incluidos los trabajos de Boxwell (2010); Fraas y Partain (2010); Singh Briar y He (2021).

## Inversor fotovoltaico

El inversor fotovoltaico (IVF) es el componente crucial del sistema fotovoltaico y pertenece a la categoría más amplia de los convertidores estáticos. Su función principal es convertir la corriente continua (CC) -procedente del panel fotovoltaico- en corriente alterna (CA). Esta CA es entonces compatible con los requisitos de carga y puede ser utilizada por baterías o dispositivos electrónicos más comúnmente reconocidos, como se detalla en Alhamer y cols. (2022); Fraas y Partain (2010); Messenger y Abtahi (2017)

Los autores en Khan et al. Ali Khan, Liu, Yang, y Yuan (2020) mencionan que los IVF se suelen clasificar en dos tipos: inversores autónomos (SAPV) e inversores conectados a la red (GCPV). Los SAPV funcionan independientemente de la red eléctrica, mientras que los GCPV están diseñados para interconectarse con la red pública. Sin embargo, esta distinción se ha ido difuminando en los últimos tiempos, ya que los sistemas modernos pueden funcionar en cualquiera de los dos modos. Estos sistemas, capaces de funcionar tanto de forma independiente como en conjunción con la red, se denominan inversores híbridos.

## **Convertidores CC/CC**

Un convertidor CC-CC, también conocido como convertidor CC-CC, es un circuito o dispositivo electrónico que convierte una tensión de corriente continua (CC) de un nivel a otro. Puede aumentar (convertidor boost) o disminuir (convertidor buck) el nivel de tensión.

Los convertidores CC-CC se utilizan ampliamente en diversos sistemas electrónicos, como dispositivos electrónicos portátiles, vehículos eléctricos y sistemas de energías renovables, como los sistemas fotovoltaicos. Se utilizan para convertir el nivel de tensión de la fuente de alimentación al nivel requerido por la carga.

Por ejemplo, en un sistema fotovoltaico, el nivel de tensión de la fuente de alimentación, que es el panel fotovoltaico, puede variar en función de la intensidad de la luz solar y la temperatura. El convertidor CC-CC se utiliza para convertir el nivel de tensión variable en un nivel de tensión estable que sea adecuado para la carga, como una batería o la red.

Los convertidores CC-CC pueden clasificarse en función de su topología, como buck, boost, buck-boost y cuk. También pueden clasificarse en función de su método de control: controlados por tensión, controlados por corriente y controlados por potencia constante.

La elección de la topología y el método de control depende de los requisitos específicos del sistema, como el nivel de tensión de entrada y salida, el rendimiento, la potencia y el coste.

## **Módulo Fotovoltaico**

En cambio, un módulo fotovoltaico es un paquete premontado de células fotovoltaicas conectadas en serie y en paralelo para formar una sola unidad eléctrica. Las células están encapsuladas en una carcasa protectora y equipadas con conexiones eléctricas, lo que permite conectarlas a un sistema mayor.

Los módulos PV pueden estar formados por múltiples células PV, suelen tener una potencia de unos pocos vatios a varios cientos de vatios, depende del número de células que lo componen y del tipo de células Messenger y Abtahi (2017).

Las células fotovoltaicas son el corazón del sistema fotovoltaico, generan la energía, mientras que los módulos fotovoltaicos son el envoltorio de las células fotovoltaicas, las protegen y facilitan su instalación Alhamer y cols. (2022).

Los módulos FV se utilizan ampliamente en sistemas FV residenciales, comerciales e industriales, son el producto final que se instala en el tejado o en el campo. Es importante mencionar que el rendimiento del sistema fotovoltaico depende de la eficiencia de las células fotovoltaicas y de la calidad del módulo fotovoltaico Motahhir y Eltamaly (2021); Petrone, Ramos-Paja, y Spagnuolo (2017).

# Modelos de módulos fotovoltaicos

## Modelo del diodo ideal o simple

De acuerdo los siguientes autores Tobon Mejia, Rojas Montano, Serna Garces, y Herrera Cuartas (2021), la ecuación del modelo de diodo único es un modelo matemático que describe el comportamiento de una célula o módulo fotovoltaico (FV) en diferentes condiciones de funcionamiento. Se trata de un modelo simplificado que describe la célula o el módulo fotovoltaico como un único diodo, conectado en paralelo con una resistencia en serie. La ecuación del modelo de diodo único viene dada por:

$$I = I_L - I_0 * \left( e^{\frac{qV}{nkT}} - 1 \right) - \frac{V + I * R_s}{R_{sh}} \quad (9)$$

Donde:

- $I$  es la corriente que circula por la célula o el módulo fotovoltaico.
- $I_L$  es la corriente de saturación inversa del diodo.
- $I_0$  es la corriente de saturación inversa del diodo en condiciones de prueba estándar (STC).
- $q$  es la carga del electrón: ( $1,6 \times 10^{-19}$  Coulombs).
- $V$  es la tensión o voltaje a través de la célula o módulo fotovoltaico.
- $n$  es el factor de idealidad del diodo.
- $k$  es la constante de Boltzmann ( $1,38 \times 10^{-23}$  Joules/Kelvin).
- $T$  es la temperatura de la célula o módulo fotovoltaico en grados Kelvin.
- $R_s$  es la resistencia en serie de la célula o módulo fotovoltaico.
- $R_{sh}$  es la resistencia de derivación de la célula o módulo fotovoltaico.

La ecuación del modelo de diodo único puede utilizarse para estimar el rendimiento de una célula o módulo fotovoltaico en diferentes condiciones de funcionamiento, como la variación de la irradiancia solar y la temperatura, y es muy útil para diseñar algoritmos MPPT.

También referido como el modelo de cinco parámetros, este enfoque ofrece una precisión adecuada para la modelización y simulación de módulos fotovoltaicos fabricados con Si cristalino. Sin embargo, su aplicabilidad puede ser limitada al ser empleado en otras tecnologías fotovoltaicas, (particularmente aquellas asociadas a la segunda generación de dispositivos fotovoltaicos. Massi Pavan, Vergura, Mellit, y Lughì (2017)). Hay que tener en cuenta que la ecuación del modelo de diodo único es una aproximación del comportamiento de una célula o módulo fotovoltaico y que no tiene en cuenta todos los fenómenos físicos que ocurren en una célula y módulo fotovoltaicos, pero es una buena representación para la mayoría de las aplicaciones comunes Messenger y Abtahi (2017); Motahhir y Eltamaly (2021); Nguyen y Nguyen (2015) .

## ¿Qué otros modelos existen?

Existen diferentes modelos usados para describir el comportamiento de las células fotovoltaicas (FV). Estos modelos pueden clasificarse a grandes rasgos en dos categorías: modelos fenomenológicos y modelos físicos. He aquí algunos ejemplos Hasan y Parida (2016):

- **Modelo de doble diodo:** Este modelo es una extensión del modelo de diodo único e introduce un diodo adicional en el circuito para tener en cuenta las pérdidas por recombinación en la célula. Aunque este modelo es más preciso que el de un solo diodo, también es más complejo y requiere definir más parámetros.

El modelo de doble diodo puede utilizarse para calcular las características de corriente-tensión (I-V) y potencia-tensión (P-V) de una célula fotovoltaica en distintas condiciones de funcionamiento, como la temperatura y la iluminación. Esta información puede utilizarse para diseñar y optimizar sistemas fotovoltaicos Abbassi, Ben Mehrez, Touaiti, Abualigah, y Touti (2022); Bastidas-Rodríguez, Ramos-Paja, y Serna-Garcés (2022); Hasan y Parida (2016); Pujahari (2021). Puede encontrarse un modelo preliminar para su cálculo en la Subsección Modelo de doble diodo.

- **Modelos físicos o semifísicos:** Estos modelos se basan en la física de los semiconductores y en la estructura real de las células fotovoltaicas. Son más complejos y requieren un conocimiento detallado de las propiedades físicas de los materiales utilizados en la célula fotovoltaica. Algunos ejemplos son el modelo PC1D, AMPS-1D, AFORS-HET, ASPIN3, CROWM, OghmaNano, wxAMPS Hajjiah, Gamal, Kandas, Gorji, y Shehata (2022); Pujahari (2021).
- **Modelos empíricos:** Estos modelos se basan en el ajuste de datos experimentales de la curva IV. Pueden ser precisos para condiciones específicas, pero pueden no extrapolarse bien a condiciones diferentes. Gadjeva y Hristov (2014); Hassan, Zakzouk, y Abdelsalam (2022); Massi Pavan y cols. (2017); Moussa y Khedher (2022); Olayiwola y Choi (2023).
- **Modelos de caja negra:** Estos modelos se basan en el aprendizaje automático o en métodos estadísticos, y no intentan modelar físicamente los procesos subyacentes en la célula fotovoltaica. Pueden ser muy precisos para conjuntos de datos específicos, pero pueden no extrapolarse bien a diferentes condiciones o tipos de células fotovoltaicas como los que podemos encontrar en la Sección de resultados.

## Condiciones de prueba estándar

Las condiciones estándar de prueba (STC) standard test conditions por sus siglas en inglés, son un conjunto de puntos de referencia universalmente reconocidos que se utilizan en la industria fotovoltaica para estandarizar la evaluación del rendimiento de los paneles solares Moldovan, Burduhos, y Visa (2023).

Las STC estipulan que el rendimiento de un panel solar se mide en las siguientes condiciones:


- Una temperatura de la célula, a menudo denominada temperatura nominal de funcionamiento de la célula, de 25 grados Celsius (o 77 grados Fahrenheit) Segbefia y Sætre (2022).
- Irradiancia solar, que es la cantidad de radiación electromagnética recibida del Sol por unidad de superficie, de 1.000 vatios por metro cuadrado ( $W/m^2$ ). Esta métrica es indicativa de un día claro y soleado con el Sol directamente encima Razykov y cols. (2011).
- Un coeficiente de masa de aire (AM) de 1,5, valor que representa la trayectoria del sol a través de la atmósfera terrestre Cattin y cols. (2019).

El STC ofrece una base estandarizada para comparar el rendimiento de distintos sistemas fotovoltaicos o para contrastar el rendimiento de un sistema fotovoltaico en distintas condiciones reales. Sin embargo, es crucial reconocer que las condiciones reales de funcionamiento pueden desviarse sustancialmente de las especificadas en el STC. Por ejemplo, las células solares pueden superar significativamente una temperatura de 25 grados centígrados en un día caluroso y soleado, y la irradiancia solar puede ser muy inferior a  $1.000 W/m^2$  durante la mañana, a última hora de la tarde o en días nublados Quansah, Adaramola, Takyi, y Edwin (2017).

La potencia (corriente x tensión) de un PV en estas condiciones de prueba estándar suele denominarse "vatios pico." "Wp". Existe un punto concreto en la curva I-V de un panel fotovoltaico denominado punto de máxima potencia (MPP), en el que el panel funciona con la máxima eficiencia y produce su máxima potencia de salida. Las STC no son una representación exacta de cómo funcionarán los sistemas PV en condiciones reales Cha, Bhang, Park, Choi, y Ahn (2018).

## Curvas características

Una curva I-V caracteriza cada panel o módulo FV, véase la Figura 4 donde se explican las condiciones de potencia máxima ( $I_{mp}$ ,  $V_{mp}$ ). Esta curva, que es un estándar, está disponible en la hoja de datos de cada módulo o panel fotovoltaico. Se calcula según la prueba STC estandarizada, igual a las siguientes condiciones: ( $1000 W/m^2$ ,  $25\text{ }^\circ\text{C}$ , IAM 1,5) Castro y cols. (2020).



**Figura 4**  
 Curva I-V característica de un módulo fotovoltaico.

## ¿Como optimizar un sistema fotovoltaico?

Diferentes autores Alsadi y Khatib (2018); Hazim, Baharin, Gan, Sabry, y Humaidi (2023); Mi y cols. (2023) proponen diferentes maneras o caminos para optimizar un SFV y mejorar su rendimiento e incrementar su eficiencia, se presentan brevemente los siguientes puntos:

1. Diseño adecuado del sistema: El sistema fotovoltaico debe diseñarse para maximizar la cantidad de energía solar que son capaces de captar los paneles, Ciertos factores como la inclinación y orientación de los paneles, el sombreado(arboles y edificios) y las condiciones meteorológicas de la zona Khan y cols. (2022).
2. Uso de sistemas de movimiento: Los paneles fotovoltaicos que se mueven para seguir la posición del sol a lo largo del día pueden aumentar la producción de energía del sistema.
3. Uso de células fotovoltaicas de mayor eficiencia: Aumentar la eficiencia de las células fotovoltaicas utilizadas en el sistema puede incrementar la cantidad de energía producida por metro cuadrado de panel.Usualmente van del 12 % a 50 % de transformacion de energia.
4. Uso de controladores y algoritmos de seguimiento del punto de máxima potencia (MPPT): Los controladores MPPT pueden optimizar la potencia de salida del sistema fotovoltaico asegurándose de que los paneles funcionan en su punto de máxima potencia.

5. Mantenimiento y limpieza periódicos: La limpieza periódica de los paneles fotovoltaicos y el mantenimiento del sistema pueden garantizar que funcione con la máxima eficiencia.
6. Uso de sistemas de almacenamiento de energía: Utilizar sistemas de almacenamiento de energía como baterías, puede permitir almacenar la energía generada en los momentos de alta producción, para los momentos en los que el consumo de energía sea superior a la producción Garip y Ozdemir (2022).
7. Supervisión y análisis de datos: La supervisión y el análisis periódicos del rendimiento del sistema fotovoltaico pueden ayudar a identificar problemas y oportunidades de optimización. También aquí pueden aplicarse los diferentes algoritmos de inteligencia artificial Asif y cols. (2023).

A pesar de esto, no todos los métodos aquí mencionados son los más adecuados o viables para todos los casos, depende de las características específicas del sistema y del lugar donde se vaya a instalar.

## Algoritmos para la Búsqueda del Punto de Máxima Potencia

Como fue discutido en la introducción, las variaciones en las condiciones atmosféricas, el lugar de la instalación del sistema PV, afectan enormemente a dos variables principalmente la radiación ( $G$ ) y la temperatura ( $T$ ) que llegan al panel PV. Debido a esto la cantidad de energía generada puede variar alejándose del MPP, resultando que el sistema obtenga una menor eficiencia y se tenga menor desperdicio de energía solar.

Para poder contrarrestar estos efectos es necesario monitorear estas variaciones, mediante algoritmos de seguimiento al punto de funcionamiento máximo del sistema PV y así extraer la mayor cantidad de energía posible. Estos algoritmos se conocen como *MPPT maximum power point tracker*, y son los encargados de llevarlo a cabo Atri, Modi, y Gujar (2021); Rokonzaman (2016).

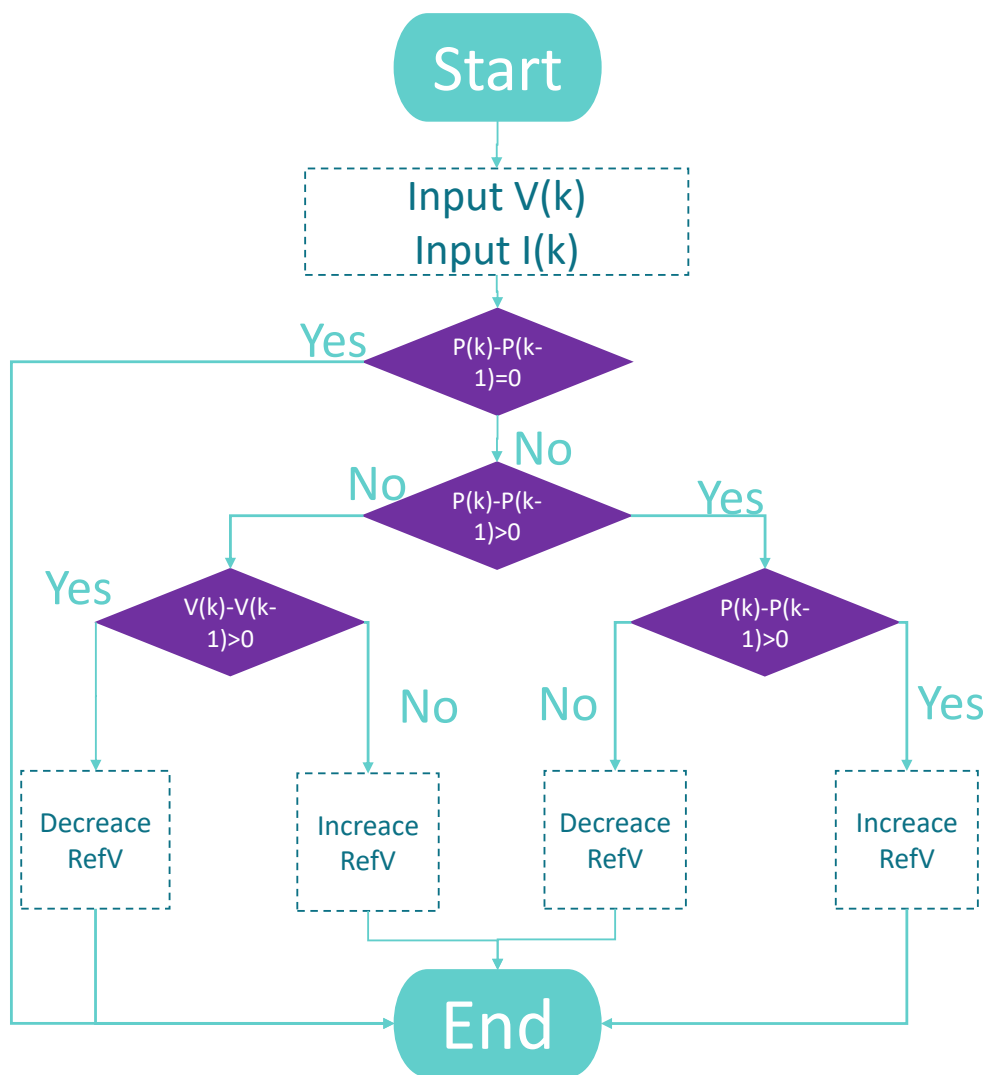
En la literatura se pueden encontrar diferentes técnicas o algoritmos, que varían respecto a la complejidad, número de entradas y sensores usados, velocidad y tiempo de convergencia, rango de efectividad, implementación de hardware, costo, popularidad, entre otros aspectos M. N. Ali y cols. (2021); Kathe, Makokha, Zachary, y Adaramola (2023).

Además, una de las clasificaciones más utilizadas es la distinción entre algoritmos directos Dolar, Grimalcia, Mussetta, Ogliari, y Leva (2018); Marroquin-Arreola y cols. (2022); Ortiz, Mendez, Macias, y Molina (2022) e indirectos Anuradha, Senthil Kumar, y Senthil Kumar (2016); Kermadi, Mekhilef, Salam, Ahmed, y Berkouk (2020) y la combinación de ambos. En esta sección se presentan varios de los algoritmos que se utilizaron para entender a fondo su principio de funcionamiento, también se evalúan sus ventajas y desventajas. La clasificación en la que se encuentra son Algoritmos clásicos MPPT. Algoritmos MPPT que hacen uso de las ANN.



## Algoritmo Perturbación & Observación

Dentro de los algoritmos de control digital para sistemas fotovoltaicos el algoritmo P&O es el mas reconocido Kamran y cols. (2020); Kumar y Titus (2023); Salman, AI, y WU (2018). La manera en como trabaja es de la siguiente manera: El punto critico de trabajo del sistema es controlado por mediante una variación periódica en la salida de voltaje del panel PV, dependiendo a su vez de la variación en la salida de potencia o poder. Si la salida de potencia de un panel PV en el ciclo de corriente es mayor que comparada contra el ciclo anterior, entonces el cambio de voltaje se compara. Si este se ha incrementado, entonces el punto de critico de trabajo sera ajustado en consecuencia y el mismo procedimiento se aplica para disminuir el voltaje e incrementar la potencia. La precisión de este modelo depende del paso de incremento o decremento. La siguiente Figura 5 muestra el diagrama de flujo del algoritmo P&O.



**Figura 5**  
Diagrama de flujo del algoritmo MPPT de P&O.

## Algoritmo Conductancia Incremental

Otro de los algoritmos (MPPT) más conocidos es el de Conductancia Incremental (IncCond), se utiliza en sistemas fotovoltaicos (PV) y se utiliza también para optimizar la producción de energía eléctrica ajustando el punto de funcionamiento eléctrico de los módulos o del conjunto.

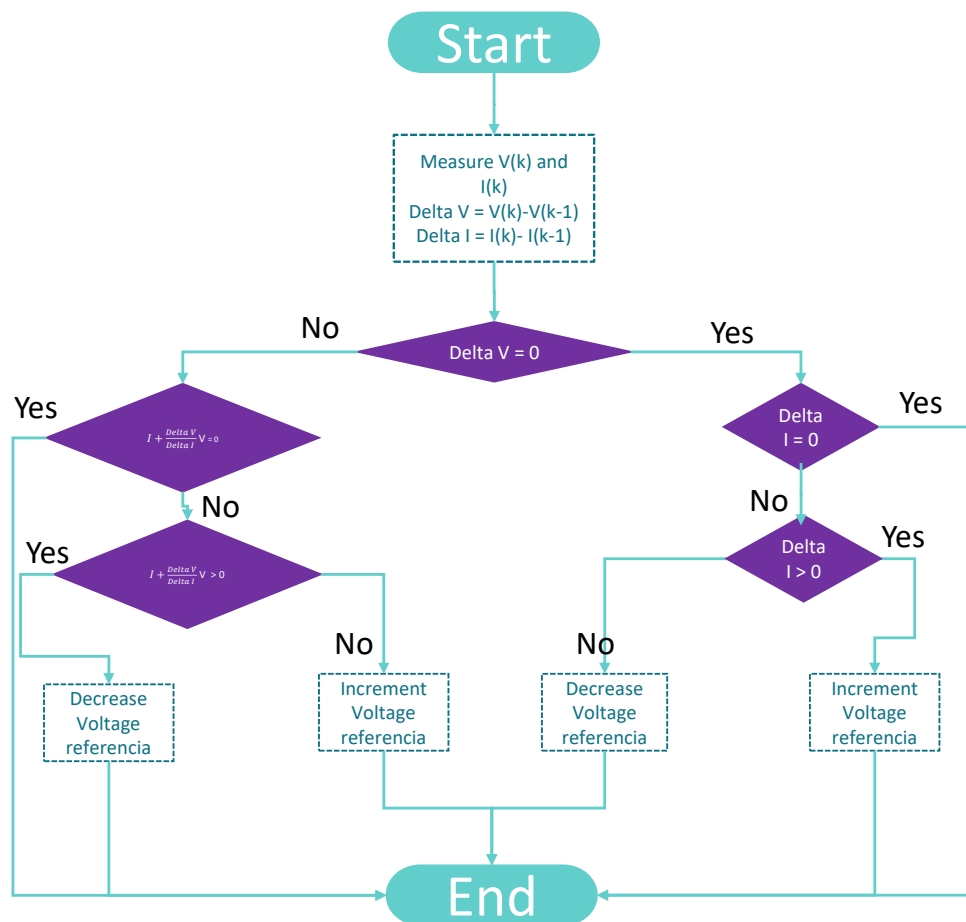
- **Principios:** El principio básico del método de Conductancia Incremental es que la derivada de la potencia  $P$  con respecto a la tensión  $V$  en el Punto de Máxima Potencia (MPP) es cero Barkat (2022); Shang, Guo, y Zhu (2020). Matemáticamente, esto se representa como:

$$\frac{dP}{dV} = 0$$

- **Inferencia de Condiciones:** La potencia  $P$  puede representarse como el producto de la tensión  $V$  y la intensidad  $I$ , es decir,  $P = V \cdot I$  Owusu-Nyarko, Elgenedy, Abdelsalam, y Ahmed (2021). Así, en el MPP, la condición es:

$$\frac{d(V \cdot I)}{dV} = V \cdot \frac{dI}{dV} + I = 0 \Rightarrow -I = V \cdot \frac{dI}{dV} \Rightarrow \frac{I}{V} = -\frac{dI}{dV}$$

- **Análisis comparativo:** Esta condición significa que la Conductancia Incremental ( $\frac{dI}{dV}$ ) es igual a la inversa de la Conductancia Estática ( $\frac{I}{V}$ ) pero con signo negativo en el MPP. Por lo tanto, el algoritmo compara la conductancia Incremental y Estática en cada iteración para aproximarse al MPP.
- **Mecanismo de Decisión:** Si  $\frac{dI}{dV} + \frac{I}{V} > 0$ , el MPP está a la derecha, y si  $\frac{dI}{dV} + \frac{I}{V} < 0$ , el MPP está a la izquierda del punto de operación actual, modificando el ciclo de trabajo del convertidor adecuadamente para alcanzar el MPP N. Ali (2023); Barkat (2022).
- **Implementación:** El algoritmo de Conductancia Incremental suele implementarse en controladores digitales, utilizando un bucle de realimentación que ajusta continuamente la tensión para encontrar el punto de máxima potencia, adaptándose a las variaciones de iluminación y temperatura Cheng (2013); Chevtchenko, Barbosa, Cavalcanti, Azevedo, y Ludermir (2022).
- **Rendimiento:** El algoritmo es conocido por su precisión y eficacia en condiciones atmosféricas que cambian rápidamente. Sin embargo, requiere un proceso computacional más complejo, que implica la diferenciación de la corriente y la tensión, y por lo tanto exige un sistema de control más robusto Barkat (2022).
- **Aplicación:** Debido a su precisión y adaptabilidad, el método MPPT de Conductancia Incremental se aplica ampliamente en sistemas fotovoltaicos, especialmente cuando las condiciones ambientales son muy dinámicas y la maximización de la potencia de salida es crucial Cheng (2013).



**Figura 6**  
Diagrama de flujo del algoritmo MPPT de Conductancia Incremental

## Redes Neuronales para el seguimiento del punto de máxima potencia

En el contexto del MPPT, las redes neuronales pueden utilizarse para modelar la compleja relación no lineal entre la corriente, la tensión y la potencia de salida del panel solar. La red neuronal se entrena con datos recogidos del panel solar en distintas condiciones de funcionamiento, como distintos niveles de luz solar, temperaturas y sombras. Una vez entrenada la red neuronal, puede utilizarse para predecir el punto de máxima potencia (MPP) del panel solar en tiempo real, basándose en sus condiciones de funcionamiento actuales Divyasharon, Banu, y Devaraj (2019); Elobaid, Abdelsalam, y Zakzouk (2015); Haq y cols. (2022).

El uso de redes neuronales para el MPPT tiene varias ventajas.

- Las redes neuronales son capaces de manejar relaciones complejas y no lineales, lo que es importante en el caso de un panel solar, ya que la curva I-V de un panel solar es altamente no lineal.

Además, las redes neuronales pueden adaptarse a condiciones de funcionamiento cambiantes, como cambios en la intensidad de la luz solar, la temperatura y el sombreado. Esto resulta especialmente útil en aplicaciones reales, en las que las condiciones de funcionamiento pueden variar significativamente Divyasharon y cols. (2019).

- Los métodos MPPT que utilizan redes neuronales pueden implementarse de diferentes maneras, dependiendo del diseño específico del sistema. Algunos métodos utilizan redes neuronales para modelar la curva I-V del panel solar y predecir el MPP, mientras que otros utilizan redes neuronales para controlar el punto de funcionamiento del panel solar en tiempo real Haq y cols. (2022).
- Cabe señalar que el uso de redes neuronales para el MPPT también plantea algunos problemas. Uno de ellos es la complejidad del algoritmo, que requiere una gran cantidad de datos y necesita ser reentrenado cuando cambian las condiciones. Además, algunos estudios han demostrado que la eficiencia del MPPT utilizando redes neuronales no siempre es mejor que la de los métodos clásicos, especialmente en condiciones de cielo nublado Elobaid y cols. (2015).

## **Aprendizaje Automático para el seguimiento del punto de máxima potencia**

Así como las redes neuronales, otros algoritmos de aprendizaje automático (Machine Learning, ML) y regresión, se han propuesto como una herramienta muy eficaz en el seguimiento del punto de máxima potencia (Maximum Power Point Tracking, MPPT) por varias razones:

- **Adaptabilidad:** Los algoritmos de aprendizaje automático pueden aprender de los datos y adaptarse a los cambios. En el contexto del MPPT, estos algoritmos pueden aprender y adaptarse a las condiciones variables de irradiación solar y temperatura, que afectan directamente a la producción de energía de los sistemas fotovoltaicos (FV) KARABINA OGLU, GÜNER OGLU, ÇAKIR, ABDULVEHAB KAZDAL OGLU, y BASOGLU (2022); Roh (2022); Yap, Sarimuthu, y Lim (2020).
- **Gestión de la no linealidad:** Las características I-V y P-V de los sistemas fotovoltaicos son no lineales y cambian con la irradiancia y la temperatura. Los algoritmos de aprendizaje automático, especialmente los no lineales como las redes neuronales artificiales (RNA), las máquinas de vectores de apoyo (SVM) o los métodos de conjunto, pueden manejar estas relaciones no lineales de forma eficaz Ishrat, Gupta, y Nayak (2023); Nkambule, Hasan, Ali, Geem, y Junhee (2020).
- **Capacidad predictiva:** El aprendizaje automático puede utilizar datos históricos para predecir valores futuros. Esto puede ser especialmente útil en el seguimiento del punto de máxima potencia (MPP) en condiciones ambientales cambiantes Xie y Wu (2021).
- **Eficacia:** Los modelos de aprendizaje automático pueden aprender y mejorar continuamente, haciéndose más eficientes con el tiempo en el seguimiento del MPP Roh (2022).

- **Oscilaciones reducidas:** Los métodos MPPT tradicionales, como (P&O) o (InC), tienen una oscilación inherente alrededor del MPP. Los algoritmos de aprendizaje automático pueden reducir estas oscilaciones, lo que permite un seguimiento más preciso del MPP Ishrat y cols. (2023).
- **Generalizabilidad:** Una vez entrenado, un modelo de aprendizaje automático puede aplicarse a diferentes sistemas fotovoltaicos sin necesidad de reprogramación o recalibración significativa Nkambule y cols. (2020); Xie y Wu (2021); Yap y cols. (2020).
- **Gestión de múltiples máximos:** En condiciones de sombreado parcial, la curva P-V de un sistema solar fotovoltaico puede tener múltiples máximos locales. Las técnicas MPPT tradicionales tienen dificultades en estas situaciones y pueden quedarse atascadas en un máximo local en lugar de en el global. Los algoritmos avanzados de aprendizaje automático pueden ayudar a encontrar el máximo global de forma más eficaz KARABINA OGLU y cols. (2022); Roh (2022).

## V.- Metodología

En esta sección se muestra la metodología propuesta y utilizada para llevar a cabo el cumplimiento del objetivo general y los objetivos específicos y así validar nuestra hipótesis.

### Tipo de Investigación

La investigación científica es un proceso sistemático utilizado para explorar, probar y analizar el mundo natural. Existen varios tipos de investigación científica, cada uno con su propia finalidad y metodología: Investigación descriptiva: Las investigaciones descriptivas consisten en recoger y describir observaciones sobre el mundo natural. Este tipo de investigación no suele implicar la comprobación de una hipótesis ni la manipulación de variables. Algunos ejemplos son la observación del comportamiento animal, la descripción de formaciones geológicas o la realización de una encuesta.

Investigación exploratoria: En las investigaciones exploratorias, los investigadores examinan un fenómeno nuevo o poco conocido para generar nuevas ideas, hipótesis o teorías. Este tipo de investigación puede incluir enfoques tanto descriptivos como experimentales y a menudo sirve como punto de partida para una investigación más profunda.

Investigación experimental: Las investigaciones experimentales consisten en manipular una o varias variables independientes y medir los efectos sobre las variables dependientes para comprobar una hipótesis. Estas investigaciones están diseñadas para establecer relaciones causa-efecto y son el tipo más común de investigación científica en campos como la física, la química y la biología.

Investigación correlacional: En las investigaciones correlacionales, los investigadores examinan las relaciones entre dos o más variables sin manipular ninguna de ellas. Los estudios correlacionales pueden ayudar a identificar asociaciones entre variables, pero no pueden establecer relaciones de causa-efecto.

Partiendo de estas definiciones, la presente investigación es del tipo proyectiva en virtud de que propone una solución tecnológica (algoritmo para control) enfocada a la problemática determinada relacionada con las instalaciones de paneles PV.

Esta investigación proyectiva se apoyó en un diseño de campo teniendo en cuenta que los datos necesarios para la puesta a punto del controlador neuronal serán tomados de un sistema FV en funcionamiento.

### Fases de la Investigación

Para cumplir con los objetivos específicos se plantearon un conjunto de fases basando la constitución y el desarrollo de las actividades en la gestión de proyectos, que es la disciplina que permite organizar y administrar recursos de manera tal que se pueda culminar el proyecto dentro del alcance, el tiempo y los costos definidos. Por lo tanto se definieron las siguientes fases ajustadas a los objetivos específicos:

- Revisión del estado del arte y antecedentes. Se realizó una minuciosa revisión bibliográfica relacionada con las variables de investigación del presente proyecto y además se definieron los

sensores, componentes electrónicos, módulos de comunicación inalámbricos y tarjetas de desarrollo basadas en Arduino que fueron utilizadas para la implementación del controlador neuronal. Se tuvieron en cuenta criterios como la confiabilidad, facilidad de programación, capacidad de procesamiento y relación costo-beneficio.

- **Diseño del controlador neuronal.** Durante esta fase se diseñó el controlador neuronal, para lo cual se definieron las entradas y salidas del controlador, topología de la red, algoritmo de entrenamiento o aprendizaje y función de transferencia. Para lo anterior, se utilizó el Neural Network Toolbox de Matlab. Además, se adquirieron los datos necesarios para realizar el entrenamiento tanto del controlador neuronal, como del sensor artesanal, esto por medio del sistema fotovoltaico en funcionamiento.
- **Recopilar los datos de entrada:** Esto incluye información como los datos meteorológicos (como la radiación solar y la temperatura), las especificaciones de los paneles solares (como la eficiencia de los módulos y el coeficiente de temperatura) y la configuración del sistema (como la inclinación y orientación de los paneles).
- **Elegir un software de simulación:** Existen varios programas informáticos para simular sistemas fotovoltaicos, como PVSYST, HOMER y PVSOL. Cada software tiene sus propias características y capacidades, por lo que es importante elegir el que mejor se adapte a sus necesidades.
- **Introducir los datos en el software:** Esto incluye introducir en el software los datos meteorológicos, las especificaciones de los paneles solares y la configuración del sistema. El software utilizará esta información para modelar el rendimiento del sistema fotovoltaico.
- **Ejecutar la simulación:** Esto generará una serie de resultados que pueden utilizarse para evaluar el rendimiento del sistema fotovoltaico en diferentes condiciones. Estos resultados pueden incluir información como la producción de energía, la eficiencia del sistema y el rendimiento financiero.
- **Analizar los resultados:** Los resultados pueden analizarse para obtener información sobre el rendimiento del sistema fotovoltaico. Esto puede incluir la identificación de áreas de mejora y la optimización del diseño del sistema.
- **Repetir el proceso:** La simulación puede repetirse con diferentes entradas o configuraciones del sistema para evaluar diferentes escenarios y optimizar el rendimiento del sistema fotovoltaico.

Cabe señalar que, para obtener resultados precisos, es importante utilizar datos meteorológicos exactos para la ubicación específica del sistema fotovoltaico, y también el sistema fotovoltaico debe modelarse lo más cerca posible del sistema real.

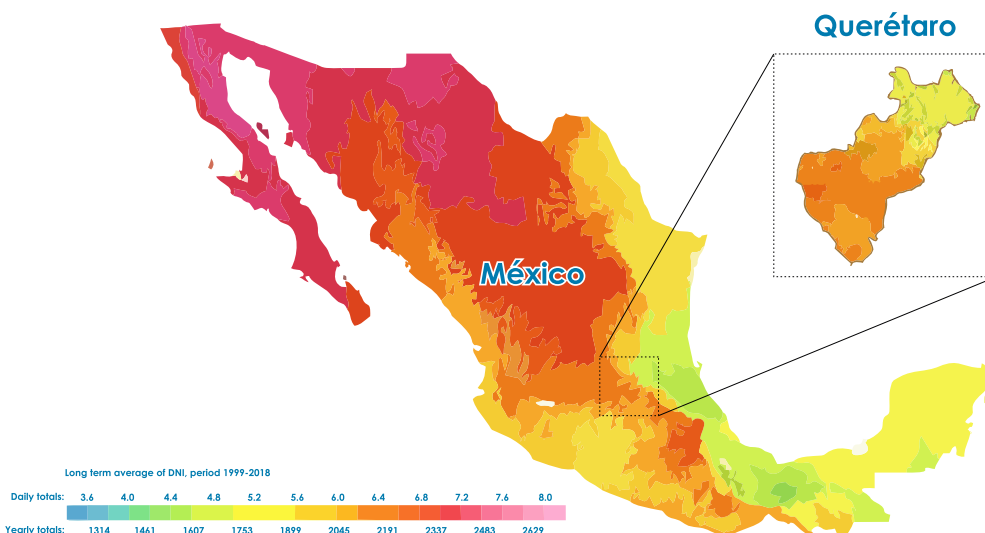
## **Área de Estudio**

México consume casi el 20 % de la producción total de energía de América Latina, y su demanda aumenta continuamente. Las principales fuentes de esta energía son el gas natural y el petróleo. Esto plantea

un reto importante, especialmente si se tiene en cuenta la necesidad de reducir las emisiones de gases de efecto invernadero en un 40 % para 2030 a fin de cumplir los objetivos medioambientales fijados. Torres (2015), de los Ángeles Ubaldo Higuera (2013).

Un enfoque viable para alcanzar este objetivo es el despliegue de fuentes de energía renovables. En este contexto, México, cuyo avance en este sector se ha visto obstaculizado, presenta un importante potencial de innovación y expansión. Se prevé que para 2030 la energía solar fotovoltaica aportará aproximadamente 30 GW de energía al año a través de una combinación de centrales fotovoltaicas distribuidas y aplicaciones de mini redes eléctricas..

La evaluación del potencial de energía solar de una región suele realizarse mediante el análisis de la radiación solar. México, situado entre 15° y 35° de latitud norte, como se muestra en la Figura 7, es notablemente ventajoso en términos de recursos solares según Martín de Jesús Nieto Pérez; Jorge Pineda Piñón (2010), Torres (2015). El país promedia una recepción solar diaria de 5,5 a 6,3  $\frac{kWh}{m^2}$ , lo que supone una generación anual de energía solar de 114,2 GWh Martín de Jesús Nieto Pérez; Jorge Pineda Piñón (2010). Este valor es un 60 % superior al potencial de países como Alemania Torres (2015). En particular, la región noroeste de México muestra un potencial sustancial para la producción de energía solar fotovoltaica, con una irradiación media diaria en la región superior a 8  $\frac{kWh}{m^2}$  durante las estaciones de primavera y verano de los Ángeles Ubaldo Higuera (2013).



**Figura 7**  
Mapa del Atlas solar de Mexico. Atlas (2022).

Para este trabajo de tesis, la ciudad elegida para recabar los datos, es Querétaro, capital del estado del mismo nombre. Está situada en el centro geográfico de México a 20.612137°N, 100.410217°W, con una altitud media de 1.820 m sobre el nivel del mar. Durante la estación lluviosa, la ciudad experimenta una importante nubosidad, mientras que en la estación seca está parcialmente nublada, manteniendo un clima cálido durante todo el año.

En Macías (2022), el autor detalla que Querétaro tiene potencial para generar 1178  $\frac{GW}{h}$  adicionales, ocupando el quinto lugar en la región del Bajío y superando a países como Alemania. Sin embargo, su producción energética actual se limita a 8  $\frac{GW}{h}$  a través de biomasa, lo que representa sólo el 0,6 % de su



potencial Torres (2015). Estudios recientes estiman que la capacidad de la ciudad para generar energía a través de la energía solar es de entre 6 y 7  $KWh$  Hernandez-Escobedo, Ramirez-Jimenez, Dorador-Gonzalez, Perea-Moreno, y Perea-Moreno (2020).

## Conjunto de Datos

Los datos utilizados en este estudio se obtuvieron diligentemente de la Red Universitaria de Observatorios Atmosféricos (RUOA) situada en el campus Juriquilla, Querétaro, que depende de la Universidad Nacional Autónoma de México. De acuerdo con la política institucional, estos datos son fácilmente accesibles al público. Existe un observatorio singular en la ciudad, marcado por las siguientes coordenadas geográficas:  $20.7030^{\circ}N$ ,  $100.4473^{\circ}W$ , y una elevación de 1,945 m.s.n.m.

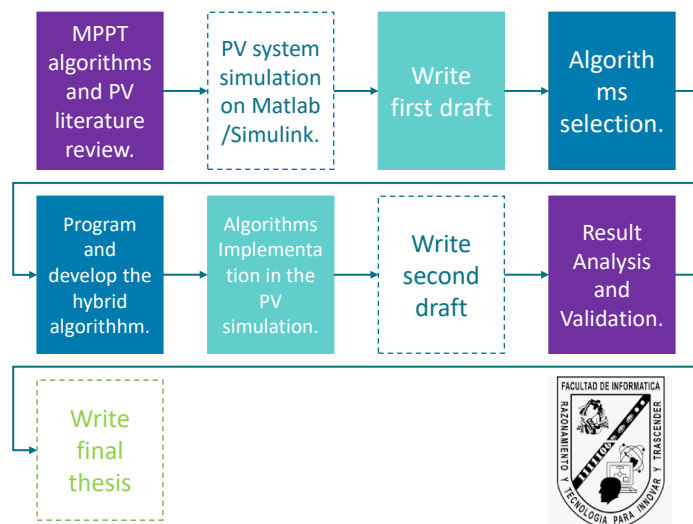
La obtención de datos sigue un proceso bien estructurado: un adquisidor de datos programado registra los datos a cada intervalo de un minuto y, posteriormente, se elabora una media horaria. Las variables registradas abarcan la velocidad y dirección del viento, la temperatura del aire, la presión atmosférica, las precipitaciones, la humedad relativa y la radiación solar (SR), que son accesibles a través de la página web referenciada como de Observatorios Atmosféricos (2023). El periodo de recogida de datos abarca los años 2020 y 2021, lo que facilita un análisis comparativo para evaluar el rendimiento del algoritmo. El conjunto de datos se compone de un total de 52.698 muestras, en las que se registra el valor máximo de cada variable cada hora

- SR: medido en  $\frac{W}{m^2}$
- Temperatura: medido en  $^{\circ}C$
- Humedad: en porcentaje %
- Presión barométrica: medida en  $Hg$
- Dirección del viento: medida en grados
- Velocidad del viento: medida en  $\frac{km}{h}$
- Amanecer/atardecer: Hora de Querétaro (GMT-5)

Tras la inclusión de la columna UNIXTime, fue necesario reformatear la fecha de dd/MM/AAAA a MM/DD/AAAA. Posteriormente, esta fecha se convirtió a UnixTime utilizando una herramienta de procesamiento por lotes.

En la Figura 8 se describe la metodología usada para separar los datos, transformarlos, y predecir el MPP mediante diversos algoritmos de ML incluyendo los algoritmos HIS. Cada paso se elabora meticulosamente y se refleja posteriormente en la sección de resultados.Resultados.

# Methodology



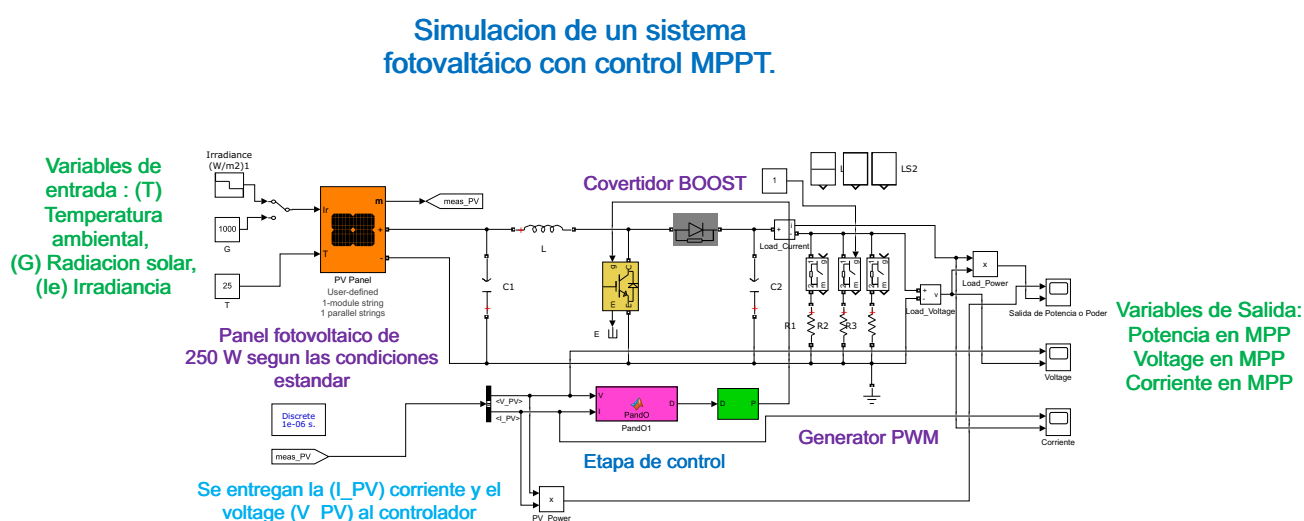
**Figura 8**  
*Representación gráfica de la metodología.*

## VI.- Resultados y discusión

En esta capítulo se presentan los resultados obtenidos a lo largo de 4 años de investigación, también se presentan los resultados de implementar el algoritmo en un sistema simulado en el entorno MATLAB/Simulink y además una implementación experimental en el lenguaje de programación Python.

### Simulación e implementación de los algoritmos en MATLAB/Simulink

Para que los resultados sean consistentes y precisos un único modelo simulado en Matlab/Simulink, que fue reutilizado cambiando únicamente el algoritmo dentro del bloque de control preestablecido. como puede observarse en la siguiente Figura 9.



**Figura 9**  
Simulación de bloques de un sistema PV usando Matlab/Simulink.

Cuyas características son las siguientes:

- Las variables de Temperatura e Irraiancia.

Les fue dado una serie estandar de Radiaciones y temperaturas que son recomendadas por los siguientes autores, esto con el objetivo de simular cambio en las mismas variales Para la T temperatura fueron las siguinetes [ 1000 800 600 400 ] y para la irradiancia las siguientes [ 1000 800

600 400 ]. Tambien una variables de radiacion que sirve para calcular la irradiancia

- Un Panel fotovoltaico del modelos estandard de 250W
- Un bloque de control representado por el color morado, este bloque a su ves tiene como la entradas a la corriente y el voltaje del panel PV.
- Un PWM para ajustar la salida de potencia calculada
- Los bloques electrónicos para simular un convertidor Boost.
- Gráficas del comportamiento a través del tiempo para el seguimiento del MPP.

# Simulación e implementación de los algoritmos en Python

Esta sección presenta los resultados obtenidos de esta investigación y sigue la metodología presentada en la Figura 8.

## Acceso y tratamiento de los datos atmosféricos

Antes de realizar cualquier análisis, es necesario preparar los datos, mantener una estructura de alto nivel para utilizar cualquier método, y asegurar que nuestros resultados obtengan una misma integridad, Estos son los pasos seguidos para esta tesis:

- Eliminar los datos corruptos o ilegibles
- Reemplazar todos los datos no numéricos en todas las columnas con valores numéricos y flotantes.
- Reemplazar todos los valores ausentes o nulos con técnicas de normalización.
- Aplicar codificación de etiquetas a todas las columnas.

Para determinar el subconjunto, comience por dividir el conjunto original en conjuntos de entrenamiento y de prueba en la proporción (80-20 %). Este subconjunto consta de muestras de todas las características con un generador aleatorio fijo para proporcionar resultados homogéneos en todos los modelos ML en los que un conjunto de datos de entrenamiento desequilibrado se transforma en subconjuntos de datos equilibrados.

No hay que olvidar como funcionan los algoritmos de aprendizaje automático supervisados, estos trabajan con características para anticipar etiquetas.

Una característica se define como un atributo del sistema que influye en la salida del modelo. Estas características se consideran las 'entradas' del modelo, y se busca idealmente que sean variables independientes entre sí. Por otro lado, una etiqueta representa el valor que el modelo intenta predecir. Las etiquetas se comportan como las 'salidas' del modelo, siendo el objetivo de la predicción por parte del algoritmo."

Después del procesamiento estas variables son características para el algoritmo de aprendizaje automático:

- Fecha (o duración del día)
- Hora del día
- Temperatura
- Presión
- Humedad

- Velocidad del viento
- Dirección del viento

## **Análisis de tendencia**

Siguiendo con el trabajo en el conjunto de datos 2021, se realiza un análisis de tendencias. El objetivo principal es identificar patrones, tendencias y cambios en los datos para tomar decisiones informadas y hacer predicciones sobre la evolución futura.

De la Figura 10 anterior pueden entenderse las siguientes observaciones:

- Los conjuntos de datos relativos a la temperatura, la humedad y la velocidad del viento presentan valores discretos, posiblemente atribuidos a la naturaleza de los sensores empleados en el proceso de recogida de datos.
- Por el contrario, los datos de presión muestran un patrón discernible caracterizado por la alternancia de valores de presión altos y bajos.
- El conjunto de datos de velocidad del viento muestra una volatilidad sustancial, lo que puede introducir un nivel de incertidumbre en su idoneidad para el análisis de regresión.
- Como se preveía, la radiación solar se mantiene constante en cero durante la noche, mientras que las horas diurnas muestran una variabilidad sustancial.
- Los datos de dirección del viento muestran volatilidad, aunque con tendencias identificables. Las fluctuaciones ocasionales dentro de las mediciones, que abarcan el rango de 0 a 360 grados, crean una impresión de cambios.<sup>en</sup> la dirección del viento, a pesar de su continuidad práctica.

.<sup>En</sup> la fase final de nuestro análisis preliminar de datos, es prudente crear representaciones visuales del conjunto de datos dentro de un marco temporal limitado. Para ello, hemos elegido un intervalo conciso de cinco días.


La representación gráfica de estos datos ofrece una valiosa perspectiva de su variabilidad diurna y la oportunidad de extraer patrones dignos de mención. Esta información será muy útil a medida que avancemos en la construcción de un modelo de aprendizaje automático para predecir la radiación solar.

Además de los datos brutos, también hemos incorporado valores medios horarios en nuestras visualizaciones. Esta preferencia por la mediana frente a la media es deliberada, ya que es menos susceptible a la influencia de posibles valores atípicos, lo que la convierte en una opción más sólida para la identificación de patrones".

## **Heatmap y Correlación de Distancia**

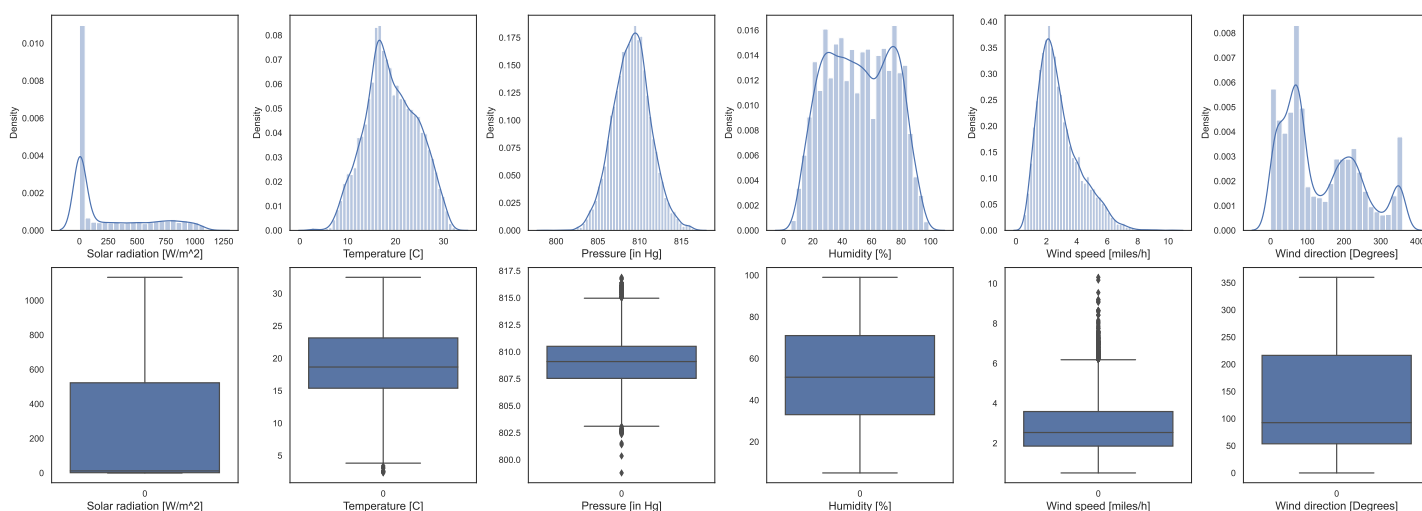
Tras completar el proceso de lectura y realizar las transformaciones de datos necesarias, el siguiente paso es visualizar los datos. Inicialmente, se construye una matriz de correlaciones para determinar las relaciones entre las variables más importantes.

Trend of the various parameters over a five-day period



**Figura 10**  
*Heatmap con los datos de generados por la correlación de distancia.*

Distribution and box plots for all relevant features



**Figura 11**


*Distribución de los Datos.*

Dado que el coeficiente de correlación de Pearson por sí solo puede no ser suficiente para establecer la relación entre dos variables, se emplearon métricas complementarias como la distancia de correlación. La siguiente Figura 12 muestra los valores de distancia de correlación obtenidos para el conjunto de datos Querétaro 2021.

A partir de esta exploración de datos se pueden hacer las siguientes observaciones:

- A medida que aumenta la temperatura, también lo hace la cantidad de radiación solar (SR). Esto es evidente a partir del valor de correlación de Pearson  $R$  de 0,56. Una distancia de correlación de 0,55 indica que existe al menos cierta relación entre la temperatura y la SR.
- La humedad tiene una relación inversa o negativa con la radiación solar en comparación con la temperatura, pero aún así podría ser significativa y no debería descartarse como posible factor impulsor del sistema climático.
- Según la correlación de Pearson y la distancia, la presión no tiene una relación directa con la radiación solar, pero sí con la temperatura y la humedad. Se pueden encontrar algunos trabajos relacionados en Zhang, Wu, Li, Yu, y Bian (2022).
- Las variables de velocidad y dirección del viento no son relevantes para este estudio. Aunque puede observarse una correlación, no implica causalidad.
- Querétaro es una ciudad con cambios estacionales mínimos. Sin embargo, se pueden observar cambios significativos durante los periodos de lluvia y verano.
- La escala temporal semanal es la más adecuada para las previsiones. Las variaciones mes a mes son muy variables y no captan los cambios estacionales dentro de un año. Las escalas de tiempo por minutos son útiles para trabajos más refinados, como los sistemas de control fotovoltaico. Las escalas horarias son beneficiosas, pero pueden ser ruidosas si no se filtran adecuadamente.





**Figura 12**  
*Heatmap con los datos de generados por la correlación de distancia.*

## Modelado de un panel PV usando el diodo simple

En este apartado se simula el funcionamiento de un panel fotovoltaico.

---

**Algorithm 1:** Algoritmo de cálculo de la potencia del panel fotovoltaico

---

**Data:** Conjunto de datos WeatherInfo con radiación y temperatura

**Result:** Conjunto de datos WeatherInfo con corriente, voltaje y potencia calculadas en el MPP

**Parameters:**  $I_{sc}$  (Short-circuit current [A]),  $V_{oc}$  (Open-circuit voltage [V]),  $I_{mp}$  (Current at maximum power [A]),  $V_{mp}$  (Voltage at maximum power [V])

```
1 foreach entry in WeatherInfo do
  /* Calcular la corriente [A] */
2    $Current_{MPP} \leftarrow I_{sc} \times \left( \frac{entry.Radiation}{1000} \right) \times \left( \frac{1}{entry.Temperature} - \frac{1}{298,15} \right);$ 
  /* Calcular el voltaje [V] */
3    $Voltage_{MPP} \leftarrow V_{oc} - \left( \frac{V_{oc} - V_{mp}}{I_{sc} - I_{mp}} \right) \times Current_{MPP};$ 
  /* Calcular la potencia [W] */
4    $Power_{MPP} \leftarrow Voltage_{MPP} \times Current_{MPP};$ 
  /* Actualizar la entrada WeatherInfo con los valores calculados */
5   entry.CurrentMPP  $\leftarrow Current_{MPP};$ 
6   entry.VoltageMPP  $\leftarrow Voltage_{MPP};$ 
7   entry.PowerMPP  $\leftarrow Power_{MPP};$ 
```

---

Para elaborar este código se hizo uso de los concepto del Modelo del diodo ideal o simple en la subsección Modelo del diodo ideal o simple.

Al eliminar los campos restantes en nuestro dataset este quedaría de la siguiente manera:

Listo al agregarlos dentro del dataframe podemos ahora si aplicar los modelos de machine learning que son aptos para predicción.

## **Experimentos para calcular el MPP usando Aprendizaje Automático**

Con forme al objetivo principal y para darle cumplimiento es se aplicaron y programaron 5 algoritmos de machine learning, capaces de predecir los valores de energía o de potencia máxima producida para varias entradas. Según la investigación llevada a cabo en el Capítulo Revisión de la literatura, múltiples modelos pueden ser adecuados para este propósito. Sobre la base de ese análisis, se probaron y evaluaron varios modelos por su rendimiento incluyendo:


- Bosque Aleatorio Optimizado.
- Redes Neuronales MPL.
- RNA + Optimización por Algoritmo Genético.
- RNA + Optimización por Lobo Gris.
- RNA + Optimización por Enjambre de Partículas.

## **Bosque Aleatorio Optimizado**


Este fue utilizado con éxito en nuestro trabajo sobre predicción de Radiación Solar obteniendo muy buenos resultados, con un 96 % de precisión de a la hora de predecir esta variable, y dado que esta serie de tiempo es una derivada de la climática, queríamos ver su funcionamiento para este tipo de casos.

Para llevar a cabo esta regresión, utilizamos los hiperparámetros por defecto proporcionados por la biblioteca (`n_estimators=100`, `max_samples=None`) como base de comparación con el algoritmo optimizado Random Forest.

Un 92 % de exactitud el momento de realizar la predicción, Después de 5 intentos los resultados no variaron demasiado obteniendo entre 90.67 a 95.53 respectivamente al momento de lograr una predicción. Sin duda random forest es un candidato ideal para evaluar series de tiempo climáticas o que sean un derivado de estas.



(a)



(b)


**Figura 13**  
*Resultados usando Bosque Aleatorio Optimizado.*

## **Redes Neuronales MLP**


El uso de algoritmo MLP (Perceptrón Multicapa) para la predicción es una opción atractiva a la hora de tratar de obtener buenos resultados. La regresión MLP es un tipo de red neuronal artificial (RNA) que ha demostrado su eficacia en el modelado de complejas relaciones no lineales entre variables de entrada y salida. Puede capturar estas no linealidades empleando múltiples capas de neuronas interconectadas con funciones de activación que introducen la no linealidad en el modelo.

Entre distintos dataset calculado, logro obtenerse un rango entre el 60 y 75 % al momento de calculo del MPP, no esta mal considerando que no se optimizo ningún hyperparametro, ni los pesos, ni bias de la librería usada.

Como puede observarse en la Figura 14a los puntos de la regresión entre el dataset real contra el de prueba todavía pueden observarse dispersos en contraposición a la recta. En la Figura 14b puede observarse de forma gráfica que el modelo dista mucho de un ajuste a los datos reales.



(a)



(b)

**Figura 14**  
*Resultados usando RNA MLP.*

La selección de hiperparámetros tiene un impacto directo en el rendimiento del modelo, incluida su capacidad para aprender de los datos de entrenamiento y generalizarlos. Un ajuste adecuado de los hiperparámetros puede mejorar la convergencia durante el entrenamiento y aumentar la precisión en los datos de prueba. Este proceso ayuda a alcanzar un equilibrio óptimo entre el sobreajuste, en el que el modelo es excesivamente complejo y aprende del ruido presente en los datos, y el infraajuste, en el que el modelo es excesivamente simplista e incapaz de captar los patrones inherentes. Un modelo bien calibrado es más apto para generalizar datos desconocidos.

Los hiperparámetros regulan la complejidad de la red neuronal, como el número de capas, neuronas y conexiones. Además, algunos hiperparámetros controlan el grado de regularización aplicado durante el entrenamiento, lo que ayuda a evitar el sobreajuste introduciendo un término de penalización en la función objetivo del modelo.



## RNA + Optimización por Lobo Gris

Se puede utilizar GWO para optimizar los hiperparámetros de una red neuronal y mejorar su rendimiento al predecir el punto de máxima potencia (MPP) de un sistema fotovoltaico.

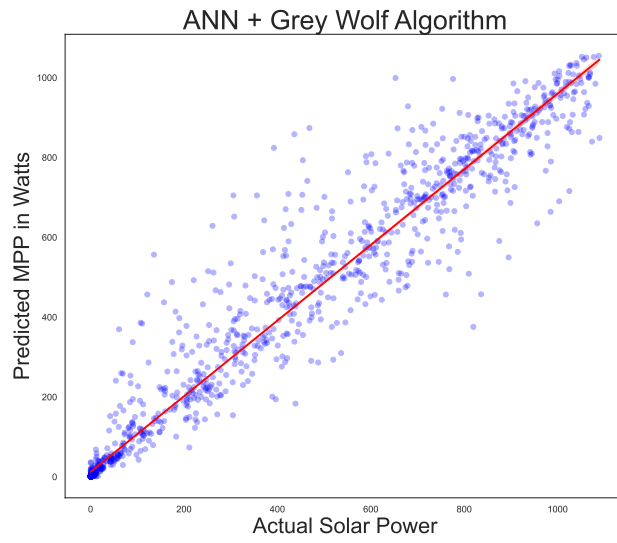
A continuación se presentan los pasos para poder lograrlo.

1. Definir la arquitectura de la red neuronal y los hiperparámetros a optimizar.
2. Implementar el algoritmo GWO o utilizar una biblioteca que incluya el algoritmo GWO.
3. Definir una función de fitness que entrene y evalúe la red neuronal utilizando un conjunto de hiperparámetros.
4. Aplicar el algoritmo GWO para buscar los hiperparámetros óptimos.
5. Entrene la red neuronal utilizando los hiperparámetros óptimos y realice predicciones MPP.


La optimización de los hiperparámetros de las ANN mediante el algoritmo de manada de lobos grises (GWO), también demuestra ser efectivo para el seguimiento preciso y adaptable a encontrar el MPP. La fortaleza de esta estrategia radica en la capacidad de las redes neuronales para modelar relaciones no lineales y aprender de los datos, mientras que el algoritmo GWO proporciona un mecanismo de búsqueda robusto y eficiente para optimizar los hiperparámetros de la red neuronal.

La precisión de este enfoque NN+GWO para el MPPT también es interesante, con niveles de precisión que oscilan entre el 88.3 % y el 92.4 %. Esta alta precisión garantiza que el sistema fotovoltaico opere cerca de su punto óptimo la mayor parte del tiempo, maximizando así la captura de energía y la eficiencia del sistema.

La Figura de la regresión 15a muestra que los valores entrenados en la gráfica de la media sin estar tan dispersos. La Figura de la validación del modelo 15b también refleja una estimación cercana sin necesidad de sobre-ajuste.



(a)




(b)

**Figura 15**  
*Resultados usando optimización por Lobo Gris.*

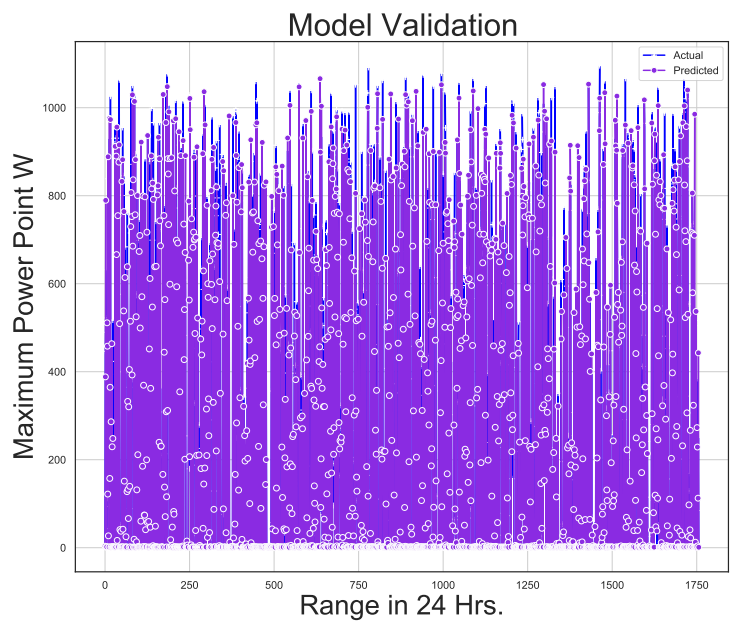
## **RNA + Optimización por Algoritmo Genético**

Esta amalgamación entre las RNA y la optimización mediante algoritmos genéticos (OAG) ha demostrado ser una potente potente algoritmo para aumentar el potencial de predicción. La fuerza de este enfoque reside en la capacidad de las RNA para modelar relaciones no lineales y aprender de los datos, mientras que el OAG proporciona un mecanismo de búsqueda robusto y eficiente para la optimización de los hiper-parámetros de la red. Esta sinergia facilita el seguimiento preciso y adaptativo del punto de máxima potencia (MPP), aumentando así el rendimiento y la eficiencia de los sistemas fotovoltaicos (FV). La precisión de este enfoque RNA+OGA para el seguimiento del MPP es muy también resultado muy meritorio, obteniendo precisiones que fluctúan entre el 90 % y el 95 %. Este alto nivel de precisión garantiza que el sistema fotovoltaico funcione cerca de su punto óptimo la mayor parte del tiempo, maximizando así la captura de energía y la eficiencia del sistema.

Al utilizar las capacidades de las RNA para el reconocimiento de patrones, la aproximación y el aprendizaje, junto con el potencial de optimización de los AG, este enfoque híbrido puede producir algoritmos MPPT altamente fiables y precisos. El éxito de este método radica en la capacidad de las RNA para modelar complejas relaciones no lineales entre variables y de los AG para ajustar con precisión los parámetros de la red para obtener un rendimiento óptimo.



(a)



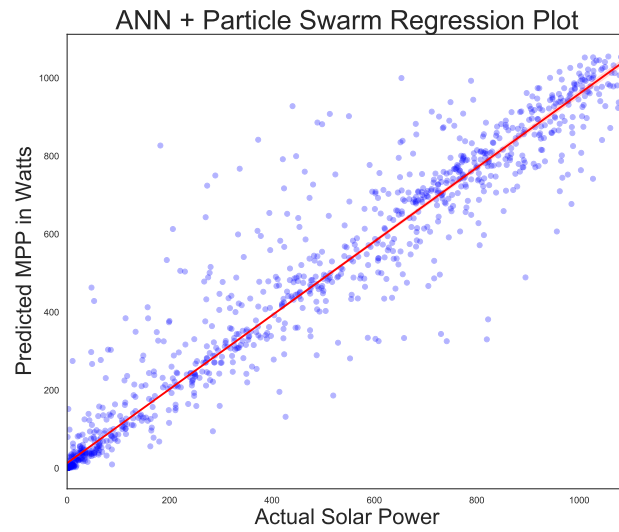
(b)

**Figura 16**  
*Resultados usando Optimización por Algoritmo Genético.*

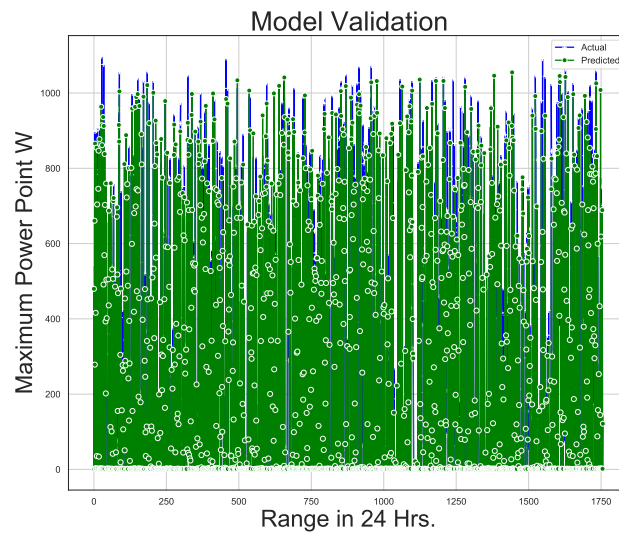
## **RNA + Optimización por Enjambre de Partículas**

La combinación de redes neuronales (NN) con la optimización por enjambre de partículas (PSO) ha demostrado ser un enfoque eficaz para esta compleja tarea. La fuerza de este enfoque reside en la capacidad de las redes neuronales para modelar relaciones no lineales y aprender de los datos, mientras que la PSO proporciona un mecanismo de búsqueda robusto y eficiente para optimizar los parámetros de la red neuronal. Esta sinergia permite un seguimiento preciso y adaptativo del Punto de Máxima Potencia, mejorando así el rendimiento y la eficiencia de los sistemas fotovoltaicos.

La precisión de este enfoque NN+PSO para MPPT es bastante impresionante, con precisiones que oscilan entre el 94 % y el 96 %. Este alto nivel de precisión garantiza que el sistema fotovoltaico funcione cerca de su punto óptimo la mayor parte del tiempo, maximizando así la captura de energía y la eficiencia del sistema.



(a)



(b)

**Figura 17**  
*Resultados usando Optimización por Enjambre de Partículas.*

Los resultados del enfoque NN+PSO se pueden inspeccionar visualmente y validarse mediante las Figuras de regresión 17a. En estas figuras, los puntos de máxima potencia predichos se comparan con los valores reales, lo que ilustra claramente el rendimiento del modelo.

Es interesante observar que, en comparación con otros métodos como las redes neuronales combinadas con la optimización del lobo gris (NN+GWO) o el algoritmo genético (NN+GA), la cifra de regresión de NN+PSO muestra un grado similar de alineación y correlación. Esto sugiere que el enfoque NN+PSO es competitivo con estos otros métodos de optimización para MPPT y podría superarlos.

Además, al comparar los resultados de los distintos métodos mediante Figuras comparativas 17b, se pueden hacer observaciones similares. A pesar de las diferencias en los algoritmos de optimización, todos los métodos demuestran un grado de precisión comparable en el seguimiento del MPP.

Esto pone de manifiesto el potencial y la versatilidad de los métodos de aprendizaje automático para el seguimiento teórico y sugiere que la elección del algoritmo de optimización podría adaptarse a los requisitos o limitaciones específicos del sistema.

## Resultados Numéricos

Para obtener resultados precisos, es necesario presentar los valores de las métricas y los indicadores. Estas pueden encontrarse en la sub-sección "métricas" son las indicadas para evaluar el desempeño de las técnicas de aprendizaje, es posible estimar cada parámetro utilizando la predicción y el entrenamiento como entradas.

Se pueden interpretar los datos de la siguiente manera:

El modelo RF optimizado obtuvo un rendimiento en un rango del 94 % al , otros estudios, como en Srivastava, Tiwari, y Giri (2019) obtuvieron resultados similares al implementar RF para la predicción de MPP. Los valores obtenidos se validan comparandolos con las gráficas de regresión y de comparación de los datos de prueba vs los datos reales.

Como se discute en la metodología, es necesario validar estos resultados en diferentes escenarios, la Tabla 2 muestra los resultados calculados para la misma zona pero en 2022. Este conjunto de datos, obtuvo resultados similares a los encontrados anteriormente, con los algoritmos optimizados obteniendo una respuesta de hasta un 95 % de precisión al momento de predicción; los demás algoritmos de aprendizaje automático también obtuvieron resultados favorables, sobre todo el bosque aleatorio optimizado.

### Cuadro 2

*Resultados obtenidos para el dataset 2021 con PV diodo simple, utilizando algoritmos aprendizaje automático y ANN optimizados con meta-heuristicos programados en python.*

Modelo	Mean Square Error (MSE)	Root Mean Square Error (RMSE)	Mean Absolute Error (MAE)	R <sup>2</sup>	MAPE	Accuracy %
RF	6609.73	81.30	38.25	0.92	6.2481E+12	92.39
ORF	5800.26	76.15	36.39	0.9489	4.7453E+12	94.89
Adaboost	21521.27	146.70	84.68	0.81	2.76E+14	81.92
ANN (MLP)	45,120.43	212.41	154.95	0.53	7.47	53.78
ANN + GAO	5011.19	70.78	33.44	0.95	1.596E+13	95.98
ANN + GWO	6170.84	78.554	32.66	0.93	0.49	93.68
ANN + PSO	5573.45	74.655	33.638	0.92	2.5002E+12	92.54



### Cuadro 3

Resultados obtenidos para el dataset 2022 con PV diodo simple.

Modelo	Mean Square Error (MSE)	Root Mean Square Error (RMSE)	Mean Absolute Error (MAE)	R <sup>2</sup>	MAPE	Accuracy %
RF	6423.53	79.17	37.14	0.92	6.3837E+12	94.19
ORF	5636.52	74.07	35.33	0.9489	4.6086E+12	92.39
Adaboost	20990.74	143.37	82.17	0.81	2.6972E+14	84.05
ANN (MLP)	43,904.01	206.23	150.40	0.53	7.66	56.05
ANN + GAO	4909.96	68.70	32.49	0.95	1.5519E+13	94.11
ANN + GWO	5987.96	76.60	31.73	0.93	0.4865	90.79
ANN + PSO	5444.71	72.944	32.891	0.92	2.4501E+12	90.07

## Discusión

Una limitación esencial al momento de realizar esta investigación fue la falta de datos fiables. Aunque hay diferentes estaciones meteorológicas por toda la ciudad, ninguna tiene las normas para la recogida o recolección de datos, lo que dificulta la creación de conjuntos de datos y la obtención de resultados coherentes.

La presencia de datos nulos o incompletos puede dar lugar a resultados inexactos o sesgados en el análisis de series temporales. Esto se debe a que los puntos de datos que faltan pueden crear lagunas en las series temporales que pueden afectar a la precisión de los análisis de tendencias, los análisis estacionales o los modelos de previsión.

Los datos nulos o incompletos también pueden provocar una pérdida de información, lo que puede limitar la capacidad de detectar patrones o tendencias en las series temporales. Esto es especialmente problemático cuando se analizan series temporales cortas o irregulares. también pueden reducir la potencia estadística de los análisis de series temporales. Esto significa que la capacidad de detectar efectos o tendencias reales puede verse disminuida, lo que puede conducir a una falsa sensación de seguridad o a la pérdida de oportunidades.

Aunque por el contrario se determinó que el clima de esta zona de México es muy favorable para este estudio, ya que es muy constante la mayor parte del tiempo, lo cual ayuda a crear modelos muy precisos. Otra de las limitaciones fue encontrar simulaciones de sistemas fotovoltaicos, la gran mayoría del tiempo solo están disponibles para matlab/simulink.

Tendiendo que generar nuestros propios tutoriales para simular el sistema en el lenguaje Python y este a su vez cuenta con desventajas como:

Es posible que no tenga las capacidades de modelado específicas necesarias para determinadas simula-

ciones de sistemas fotovoltaicos. Por ejemplo, Python no es la mejor opción para simular interacciones complejas entre varios componentes de un sistema fotovoltaico, como reguladores de carga, inversores y baterías.

Aunque Python ofrece muchas herramientas para visualizar datos, estas pueden no ser las mejores opciones para crear gráficas y figuras avanzadas de simulaciones. Por ejemplo, como MATLAB/Simulink cuenta con herramientas para crear visualizaciones en 3D. Esto además de limitaciones propias del lenguaje como su rapidez y rendimiento en comparación con lenguajes como C, C++.

## VII.- Conclusiones

A continuación se resumen los principales logros y conclusiones alcanzados durante el periodo de investigación y que se obtuvieron para esta tesis:

En conclusión, queda demostrado que combinando el poder de las redes neuronales artificiales y algoritmos metaheurísticos, puede conducir a un enfoque altamente eficaz para el seguimiento del punto de máxima potencia (MPPT) en sistemas fotovoltaicos (FV). Mediante la integración de estos dos métodos, se han podido superar las limitaciones de las técnicas MPPT tradicionales que se basan únicamente en modelos matemáticos y aproximaciones lineales. En su lugar, los algoritmos propuestos son capaces de modelar eficazmente el comportamiento complejo y no lineal de los sistemas fotovoltaicos, dando lugar a predicciones más precisas de la potencia máxima de salida.

Para la elaboración de esta tesis, se recolectaron datos meteorológicos históricos de los últimos dos años para la ciudad de Queretaro, en la zona de Juriquilla, diariamente con un intervalo de una hora a un minuto.

Con los experimentos previos se puede concluir que:

- El análisis reveló que existe una correlación entre la radiación solar (RS) y la temperatura. Esta relación se puede comprobar gracias a los análisis de Person Ro la correlación de distancia.
- La correlación de distancia es capaz de captar relaciones no lineales entre variables que pueden no ser evidentes utilizando medidas de correlación lineal. Esto es especialmente importante cuando se trata de conjuntos de datos complejos en los que es poco probable que se mantengan relaciones lineales. Sin embargo, es importante señalar que la relación también depende de los niveles de humedad y velocidad del viento a la hora de capturar los datos.
- Los últimos avances en la aplicación de técnicas de aprendizaje automático para el seguimiento del punto de máxima potencia (MPPT) han arrojado resultados prometedores.
- En general, nuestros resultados indican que la integración de redes neuronales y algoritmos metaheurísticos ofrece un camino prometedor para mejorar la eficiencia y fiabilidad de los sistemas de energías renovables. It achieved up to 94 % prediction accuracy.
- El algoritmo de optimización por enjambre de partículas (PSO) era particularmente eficaz cuando se utilizaba en combinación con una red neuronal, lo que resultaba en una mayor precisión y eficiencia en comparación con otros algoritmos metaheurísticos.
- Los resultados demuestran que el algoritmo Grey Wolf, en particular, es un optimizador muy eficaz para el sistema MPPT basado en redes neuronales, logrando muy buenos resultados en términos de eficiencia y precisión de seguimiento.
- La combinación NN+GAO también obtuvo buenos resultados, lo que indica que también es una clara alternativa viable para la optimización del en la calculo de MPP. Se observa que el rendimiento del sistema MPPT basado este algoritmo, mejora con la adición de más parámetros de entrada, lo que permite un modelado más exhaustivo del sistema fotovoltaico.

- Estos resultados servirán de base para futuros experimentos, como la exploración de otros tipos de redes neuronales, incluidas las redes neuronales recurrentes, así como la aplicación de técnicas de regresión kernel.
- Los hallazgos sugieren que estos enfoque combinatorios/optimizadores tiene un potencial significativo para mejorar el rendimiento de los sistemas MPPT en una amplia gama de aplicaciones, incluyendo matrices fotovoltaicas a gran escala y sistemas remotos que están sujetos a condiciones ambientales variables, y pueden conducir al desarrollo de técnicas de optimización aún más eficaces.

Aunque todavía queda mucho por explorar en este campo, los hallazgos proporcionan una base sólida para futuras investigaciones y desarrollos en el área del MPPT y la optimización de sistemas fotovoltaicos.

## **Recomendaciones y trabajo futuro**

Para futuros proyectos sobre Controladores con RNA, obtener datos que oscilen dentro de los valores óptimos de control, no ampliar demasiado el margen de datos. Esto permitirá que en el entrenamiento, se obtengan mejores resultados. Un sistema de control neuronal basado en RNA con entrenamiento en línea, es un buen camino a seguir. Ya que este tipo de entrenamiento permitiría construir sistemas adaptativos y que en teoría puedan aprender y corregir perturbaciones del sistema de control, ocasionadas por datos de entrenamiento no adquiridos en un entrenamiento previo.

Un controlador MPPT puede integrarse con la tecnología de Internet de las Cosas (IoT) para permitir la supervisión y el control remotos del sistema MPPT. Esto puede proporcionar varios beneficios como:

- **Monitorización en tiempo real:** Los dispositivos IoT se pueden utilizar para recopilar y transmitir datos del sistema MPPT en tiempo real, lo que permite supervisar el rendimiento del sistema e identificar cualquier problema potencial.
- **Control remoto:** La tecnología IoT se puede utilizar para controlar el sistema MPPT de forma remota, lo que permite realizar ajustes en la configuración y los parámetros del sistema.
- **Mantenimiento predictivo:** Los datos recopilados por los dispositivos IoT pueden analizarse para predecir cuándo puede ser necesario realizar tareas de mantenimiento, lo que reduce el tiempo de inactividad y aumenta la eficiencia general del sistema.
- **Gestión de la energía:** La tecnología IoT puede utilizarse para optimizar la energía generada por el sistema fotovoltaico, ajustando el sistema MPPT en respuesta a las condiciones meteorológicas cambiantes.
- **Monitorización remota:** Los datos recopilados por los dispositivos IoT pueden utilizarse para supervisar el rendimiento del sistema de forma remota y detectar cualquier anomalía que pueda indicar un fallo en el sistema.

Al integrar los sistemas MPPT con la tecnología IoT, es posible aumentar la eficiencia general del sistema, reducir el tiempo de inactividad y mejorar el rendimiento general del sistema. Sin embargo, cabe señalar que esta integración también aumenta la complejidad del sistema y que debe tenerse en cuenta la seguridad del mismo para garantizar que los datos se transmiten y almacenan de forma segura. Otro ejemplo sería el de adaptar y dotar a nuestro algoritmo MPPT, varias formas para la detección de fallos en sistemas fotovoltaicos (FV) como:

- **Comparación con una referencia:** Un enfoque consiste en comparar el punto MPPT actual con un punto MPPT de referencia, normalmente obtenido en condiciones normales de funcionamiento. Si hay una desviación significativa del punto de referencia, podría indicar un fallo en el sistema.
- **Detección de la tasa de cambio:** Otro método consiste en controlar la tasa de cambio del punto MPPT a lo largo del tiempo. Si la tasa de cambio está fuera de un rango determinado, podría indicar un fallo en el sistema.
- **Supervisión de la curva de potencia:** Otro enfoque consiste en monitorizar la forma de la curva de potencia a lo largo del tiempo, si la forma de la curva cambia significativamente, podría indicar un fallo en el sistema.
- **Comparación con los valores esperados:** Otro enfoque consiste en comparar el punto MPPT actual con el punto MPPT esperado en función de las condiciones meteorológicas, si el punto MPPT es significativamente inferior al valor esperado, podría indicar un fallo en el sistema.
- **Monitorización de la curva I-V:** También es posible monitorizar la forma de la curva I-V, si la forma de la curva cambia significativamente, podría indicar un fallo en el sistema.

Cabe señalar que estos son sólo ejemplos, y que el enfoque específico utilizado para la detección de fallos dependerá del diseño del sistema fotovoltaico y del tipo de fallos que se espera que se produzcan. Además, es importante tener en cuenta que la detección de fallos es sólo una de las muchas formas en que pueden utilizarse los algoritmos MPPT en los sistemas fotovoltaicos, y que debe combinarse con otras técnicas para disponer de un sistema de detección de fallos robusto y fiable.

En el caso de los sistemas eólicos, el MPPT se utiliza para optimizar la potencia de salida de un aerogenerador ajustando el ángulo de paso de las palas para que coincida con el ángulo óptimo para la velocidad del viento, pero no se utiliza habitualmente.

Además, los cambios en la velocidad del viento pueden ser más bruscos que los cambios en la irradiancia solar, por lo que el controlador MPPT tiene que ser capaz de manejar esos cambios rápidamente, de lo contrario, podría causar daños a la turbina eólica.

## **Uso de Redes neuronales en sistemas embebidos**

Las redes neuronales son intensivas en cálculo y requieren una cantidad significativa de memoria y potencia de procesamiento. En los últimos años, la capacidad de cálculo de los sistemas empujados ha

aumentado considerablemente y muchos de ellos disponen ahora de los recursos necesarios para ejecutar redes neuronales.

Existen varias técnicas que pueden utilizarse para implementar redes neuronales en sistemas embebidos, entre ellas:

- **Cuantización:** Es el proceso de reducir la precisión de los pesos y las activaciones de una red neuronal. Esto puede hacerse utilizando menos bits para representar los valores, lo que puede reducir los requisitos de memoria y las demandas computacionales de la red.
- **Poda:** Es el proceso de eliminar pesos y neuronas innecesarios de una red neuronal. Esto puede reducir el número de cálculos necesarios para que funcione la red, y también puede reducir los requisitos de memoria de la red.
- **Destilación:** Se trata de una técnica que puede utilizarse para reducir las demandas computacionales de una red neuronal mediante el entrenamiento de una red más pequeña para imitar las predicciones de una red más grande.
- **Edge computing:** se trata de una técnica en la que el cálculo se realiza cerca de la fuente de datos, en lugar de enviar todos los datos a una ubicación central para su procesamiento.

Estas técnicas pueden ayudar a reducir las demandas computacionales de una red neuronal, haciendo posible su funcionamiento en sistemas empujados con recursos limitados. Sin embargo, es importante tener en cuenta que la implantación de una red neuronal en un sistema empujado dependerá de los requisitos específicos del sistema, como la memoria y la capacidad de procesamiento disponibles y el consumo de energía.

Implementar una red neuronal optimizada para el seguimiento del MPP en un Arduino puede resultar complicado debido a los limitados recursos computacionales y de memoria disponibles en los microcontroladores. Sin embargo, con algunas adaptaciones y simplificaciones, es posible implementar un modelo de red neuronal ligero para el seguimiento de MPP en un Arduino.

Aquí hay algunas sugerencias para lograr una implementación con éxito.

1. **Simplificar la red neuronal:** Reduzca la complejidad de la red neuronal utilizando menos capas y neuronas. Esto disminuirá los requisitos de memoria y la complejidad computacional, por lo que es más adecuado para un Arduino.
2. **Cuantificación de el modelo:** Reduzca la precisión de los pesos y sesgos del modelo cuantificándolos a representaciones de bits inferiores (por ejemplo, int8 o int16). Esto reducirá la huella de memoria y la complejidad computacional.
3. **Exporte los parámetros del modelo:** Guarde los pesos, sesgos y funciones de activación de la red neuronal simplificada y cuantificada, como un archivo de cabecera C/C++ o cualquier otro formato compatible con el IDE de Arduino.

4. Implementar la red neuronal en Arduino: Escribir una implementación en C/C++ de la red neuronal en el IDE de Arduino utilizando los parámetros exportados del modelo. Esto incluye la implementación del paso hacia adelante y las funciones de activación.
5. Integrar el modelo con MPP Tracking: Conecta el Arduino con los sensores y actuadores necesarios para medir el voltaje, la corriente, la irradiancia y la temperatura, y utiliza el modelo de red neuronal para predecir el MPP.

Hay que tener en cuenta que se requerirá de una implementación manual de una red feedforward o con paso hacia adelante y de las funciones de activación, deberá implementarse un manejo con tipos de datos de menor precisión.

También puede ser necesario optimizar el código para una ejecución eficiente en el hardware limitado del Arduino usando lenguaje ensamblador u otras técnicas de optimización de código.

En el Anexo Código para Arduino de MPPT usando redes neuronales puede encontrarse una propuesta de código para poder llevarlo a cabo. Cabe destacar que no ha sido probado en hardware real.

Como alternativa, podría considerarse el uso de un ESP32 o un microcontrolador más potente con mejores capacidades de cálculo y memoria, lo que haría que la implementación de la red neuronal fuera más fácil y potencialmente más precisa.

## VIII.- Referencias

- Abbassi, A., Ben Mehrez, R., Touaiti, B., Abualigah, L., y Touti, E. (2022). Parameterization of photovoltaic solar cell double-diode model based on improved arithmetic optimization algorithm. *Optik*, 253, 168600. Descargado de <https://www.sciencedirect.com/science/article/pii/S0030402622000286> doi: <https://doi.org/10.1016/j.ijleo.2022.168600>
- Alhamer, E., Grigsby, A., y Mulford, R. (2022). The influence of seasonal cloud cover, ambient temperature and seasonal variations in daylight hours on the optimal pv panel tilt angle in the united states. *Energies*, 15(20). Descargado de <https://www.mdpi.com/1996-1073/15/20/7516> doi: 10.3390/en15207516
- Ali, M. N., Mahmoud, K., Lehtonen, M., y Darwish, M. M. F. (2021). Promising mppt methods combining metaheuristic, fuzzy-logic and ann techniques for grid-connected photovoltaic. *Sensors*, 21(4). Descargado de <https://www.mdpi.com/1424-8220/21/4/1244> doi: 10.3390/s21041244
- Ali, N. (2023). *Incremental conductance MPPT algorithm for PV system*. Descargado 2023-09-26, de <https://www.mathworks.com/matlabcentral/fileexchange/132852-incremental-conductance-mppt-algorithm-for-pv-system> (MATLAB Central File Exchange)
- Ali, Y. A., Awwad, E. M., Al-Razgan, M., y Maarouf, A. (2023). Hyperparameter search for machine learning algorithms for optimizing the computational complexity. *Processes*, 11(2). Descargado de <https://www.mdpi.com/2227-9717/11/2/349>
- Ali Khan, M. Y., Liu, H., Yang, Z., y Yuan, X. (2020). A comprehensive review on grid connected photovoltaic inverters, their modulation techniques, and control strategies. *Energies*, 13(16). Descargado de <https://www.mdpi.com/1996-1073/13/16/4185> doi: 10.3390/en13164185
- Alsadi, S., y Khatib, T. (2018). Photovoltaic power systems optimization research status: A review of criteria, constrains, models, techniques, and software tools. *Applied Sciences*, 8(10). Descargado de <https://www.mdpi.com/2076-3417/8/10/1761> doi: 10.3390/app8101761
- Alsharaf, A., Sonia, Kumar, K., y Iwendi, C. (2022). Time series data modeling using advanced machine learning and automl. *Sustainability*, 14(22). Descargado de <https://www.mdpi.com/2071-1050/14/22/15292> doi: 10.3390/su142215292
- Alvarez-Alvarado, J. M., Moreno, J. G. R., Ventura-Ramos, E. J., Ronquillo-Lomeli, G., y Trejo-Perea, M. (2020). An alternative methodology to evaluate sites using climatology criteria for hosting wind, solar, and hybrid plants. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 0(0), 1-18. Descargado de <https://doi.org/10.1080/15567036.2020.1772911> doi: 10.1080/15567036.2020.1772911
- Ambika, G., y Harikrishnan, K. (2020). *Methods of nonlinear time series analysis and applications: A review*. Singapore: Springer. doi: [https://doi.org/10.1007/978-981-15-0536-2\\_2](https://doi.org/10.1007/978-981-15-0536-2_2)
- Andrew-Cotter, J., Nasir Uddin, M., y Amin, I. K. (2019). Particle swarm optimization based adaptive neuro-fuzzy inference system for mppt control of a three-phase grid-connected photovoltaic system. *IEEE*, 2089-2094. doi: 10.1109/IEMDC.2019.8785403
- Angra, S., y Ahuja, S. (2017). Machine learning y sus aplicaciones: Una revisión. En *2017 international*



- conference on big data analytics and computational intelligence (icbdac)* (p. 57-60). doi: 10.1109/ICBDACI.2017.8070809
- Antunes, A., Ferreira, B., Marques, N., y Carriço, N. (2023). Hyperparameter optimization of a convolutional neural network model for pipe burst location in water distribution networks. *Journal of Imaging*, 9(3). Descargado de <https://www.mdpi.com/2313-433X/9/3/68> doi: 10.3390/jimaging9030068
- Anuradha, T., Senthil Kumar, V., y Senthil Kumar, P. (2016). A comparison of existing mppt techniques for a pv system with interleaved converter. *Australian Journal of Basic and Applied Sciences*, 10(5), 69–75. Descargado de <https://ssrn.com/abstract=2792683> (Special 2016)
- Asif, Ahmad, W., Qureshi, M. B., Khan, M. M., Fayyaz, M. A. B., y Nawaz, R. (2023). Optimizing large-scale pv systems with machine learning: A neuro-fuzzy mppt control for pscs with uncertainties. *Electronics*, 12(7). Descargado de <https://www.mdpi.com/2079-9292/12/7/1720> doi: 10.3390/electronics12071720
- Atlas, G. S. (2022). *Global photovoltaic power potential by country*. Autor. Descargado de <https://globalsolaratlas.info/download/mexico> (Accessed: 2022-04-15)
- Atri, P., Modi, P., y Gujar, N. (2021, 02). Design and development of solar charge controller by implementing two different mppt algorithm. En *2021 international conference on advances in electrical, computing, communication and sustainable technologies (icaect)* (p. 1-5). doi: 10.1109/ICAECT49130.2021.9392426
- Atsu, D., y Dhaundiyal, A. (2019). Effect of ambient parameters on the temperature distribution of photovoltaic (pv) modules. *Resources*, 8(2). Descargado de <https://www.mdpi.com/2079-9276/8/2/107> doi: 10.3390/resources8020107
- Balfour, J., Shaw, M., y Nash, N. (2013). *Introduction to photovoltaic system design*. Jones & Bartlett Learning. Descargado de <https://books.google.com.mx/books?id=kN1x4Rnv64kC>
- Barkat, N. (2022). *Comparative analysis of modified inc.cond mppt algorithms based on direct control* (Tesis de Master, Capital University of Science and Technology, Islamabad). Descargado de <https://thesis.cust.edu.pk/UploadedFiles/Noman%20Barkat-MEE193003.pdf> (A thesis submitted in partial fulfillment for the degree of Master of Science)
- Bastidas-Rodríguez, J. D., Ramos-Paja, C. A., y Serna-Garcés, S. I. (2022). Model of series-parallel photovoltaic arrays using double-diode model and parallel computing. *Computation*, 10(6). Descargado de <https://www.mdpi.com/2079-3197/10/6/100> doi: 10.3390/computation10060100
- Boxwell, M. (2010). *Solar electricity handbook: A simple, practical guide to solar energy-designing and installing photovoltaic solar electric systems* (illustrated ed., Vol. 1). England: Greenstream Publishing. Descargado de <https://books.google.com.mx/books?id=BJz1CwAAQBAJ>
- Cano, J., Alfaro, C., Gomez, J., y Duarte, A. (2022). Out of the niche: Using direct search methods to find multiple global optima. *Mathematics*, 10(9). Descargado de <https://www.mdpi.com/>

- Castro, J., Schweiger, M., Mosek, D., Tanahashi, T., King, B., Friesen, G., ... Jahn, U. (2020, 12). *Climatic rating of photovoltaic modules: Different technologies for various operating conditions*.
- Cattin, J., Dupré, O., Aïssa, B., Haschke, J., Ballif, C., y Boccard, M. (2019). Optimized design of silicon heterojunction solar cells for field operating conditions. *IEEE Journal of Photovoltaics*, 9(6), 1541-1547. doi: 10.1109/JPHOTOV.2019.2938449
- Cha, H. L., Bhang, B. G., Park, S. Y., Choi, J. H., y Ahn, H. K. (2018). Power prediction of bifacial si pv module with different reflection conditions on rooftop. *Applied Sciences*, 8(10). Descargado de <https://www.mdpi.com/2076-3417/8/10/1752> doi: 10.3390/app8101752
- Chatfield, C., y Xing, H. (2019). *The analysis of time series: An introduction with r* (7.<sup>a</sup> ed.). Chapman and Hall/CRC. doi: 10.1201/9781351259446
- Chen, L., y Wang, X. (2019, 08). An enhanced mppt method based on ann-assisted sequential monte carlo and quickest change detection. *IET Smart Grid*, 2. doi: 10.1049/iet-stg.2019.0012
- Cheng, W. (2013). *Incremental conductance algorithm for maximum wind power extraction using permanent magnet synchronous generator* (Tesis de Master, Faculty of the Department of Engineering Technology, University of Houston). Descargado de <http://hdl.handle.net/10657/417>
- Chevtchenko, S. F., Barbosa, E. J., Cavalcanti, M. C., Azevedo, G. M., y Ludermit, T. B. (2022). Combining ppo and incremental conductance for mppt under dynamic shading and temperature. *Applied Soft Computing*, 131, 109748. Descargado de <https://www.sciencedirect.com/science/article/pii/S1568494622007979> doi: <https://doi.org/10.1016/j.asoc.2022.109748>
- Dai, H.-P., Chen, D.-D., y Zheng, Z.-S. (2018). Effects of random values for particle swarm optimization algorithm. *Algorithms*, 11(2). Descargado de <https://www.mdpi.com/1999-4893/11/2/23> doi: 10.3390/a11020023
- de los Ángeles Ubaldo Higuera, J. E. E. J. H. S. J. A. O. M. F. R. B. E. Y. J. B. A. (2013). Prospectiva del sector eléctrico 2013-2027. *Secretaria de Energia*, 2013(1).
- de Observatorios Atmosféricos, R. U. (2023, 22 de 05). *Estaciones de la red universitaria de observatorios atmosféricos*. <https://www.ruoa.unam.mx/index.php?page=estaciones&id=3>.
- Devarakonda, P. G., y Bozic, B. (2022). Particle swarm optimization of convolutional neural networks for human activity prediction. En N. Vakhania y M. E. Aydin (Eds.), *Optimisation algorithms and swarm intelligence* (cap. 4). Rijeka: IntechOpen. Descargado de <https://doi.org/10.5772/intechopen.97259> doi: 10.5772/intechopen.97259
- Divyasharon, R., Banu, R. N., y Devaraj, D. (2019). Artificial neural network based mppt with cuk converter topology for pv systems under varying climatic conditions. *2019 IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing (INCOS)*, 1-6.
- Dolara, A., Grimaccia, F., Mussetta, M., Ogliari, E., y Leva, S. (2018). An evolutionary-based mppt algorithm for photovoltaic systems under dynamic partial shading. *Applied Sciences*, 8(4). Des-

- cargado de <https://www.mdpi.com/2076-3417/8/4/558> doi: 10.3390/app8040558
- Dominico, G., y Parpinelli, R. S. (2021). Multiple global optima location using differential evolution, clustering, and local search. *Applied Soft Computing*, 108, 107448. Descargado de <https://www.sciencedirect.com/science/article/pii/S1568494621003719> doi: <https://doi.org/10.1016/j.asoc.2021.107448>
- Dorigo, M., y Stützle, T. (2004). *Ant Colony Optimization*. The MIT Press. Descargado de <https://doi.org/10.7551/mitpress/1290.001.0001> doi: 10.7551/mitpress/1290.001.0001
- Elgeldawi, E., Sayed, A., Galal, A. R., y Zaki, A. M. (2021). Hyperparameter tuning for machine learning algorithms used for arabic sentiment analysis. *Informatics*, 8(4). Descargado de <https://www.mdpi.com/2227-9709/8/4/79> doi: 10.3390/informatics8040079
- Elobaid, L. M., Abdelsalam, A. K., y Zakzouk, E. E. (2015, 11). Artificial neural network-based photovoltaic maximum power point tracking techniques: a survey. *IET Renewable Power Generation*. (First published: 01 November 2015) doi: 10.1049/iet-rpg.2014.0359
- Farzaneh, J. (2019, 09). A hybrid modified fa-anfis-p&o approach for mppt in photovoltaic systems under pscs. *International Journal of Electronics*, 107. doi: 10.1080/00207217.2019.1672808
- Fraas, L., y Partain, L. (2010, 08). Solar cells and their applications. En *Solar cells and their applications, second edition, second edition* (p. 581-611). Wiley. doi: 10.1002/9780470636886.ch26
- Gadjeva, E., y Hristov, M. (2014). Development of empirical spice models of photovoltaic panels. *2014 18th International Symposium on Electrical Apparatus and Technologies (SIELA)*, 1-4. Descargado de <https://api.semanticscholar.org/CorpusID:40145983>
- Garip, S., y Ozdemir, S. (2022). Optimization of pv and battery energy storage size in grid-connected microgrid. *Applied Sciences*, 12(16). Descargado de <https://www.mdpi.com/2076-3417/12/16/8247> doi: 10.3390/app12168247
- Gonzalez-Castano, C., Marulanda, J., Restrepo, C., Kouro, S., Alzate, A., y Rodriguez, J. (2021). Hardware-in-the-loop to test an mppt technique of solar photovoltaic system: A support vector machine approach. *Sustainability*, 13(6). Descargado de <https://www.mdpi.com/2071-1050/13/6/3000> doi: 10.3390/su13063000
- Hajjiah, A., Gamal, M., Kandas, I., Gorji, N. E., y Shehata, N. (2022). Dft and amps-1d simulation analysis of all-perovskite solar cells based on cspbi3/fapbi3 bilayer structure. *Solar Energy Materials and Solar Cells*, 248, 112026. Descargado de <https://www.sciencedirect.com/science/article/pii/S0927024822004433> doi: <https://doi.org/10.1016/j.solmat.2022.112026>
- Haq, I. U., Khan, Q., Ullah, S., Khan, S. A., Akmeliawati, R., Khan, M. A., y Iqbal, J. (2022, 01). Neural network-based adaptive global sliding mode mppt controller design for stand-alone photovoltaic systems. *PLOS*. (Published: January 20, 2022) doi: <https://doi.org/10.1371/journal.pone.0260480>
- Hasan, M., y Parida, S. (2016). An overview of solar photovoltaic panel modeling based on analytical and experimental viewpoint. *Renewable and Sustainable Energy Reviews*, 60, 75-83. Descargado de <https://www.sciencedirect.com/science/article/pii/S1364032116001179> doi: <https://doi.org/10.1016/j.rser.2016.01.087>

- Hassan, O., Zakzouk, N., y Abdelsalam, A. (2022). Novel photovoltaic empirical mathematical model based on function representation of captured figures from commercial panels datasheet. *Mathematics*, 10(3). Descargado de <https://www.mdpi.com/2227-7390/10/3/476> doi: 10.3390/math10030476
- Hazim, H. I., Baharin, K. A., Gan, C. K., Sabry, A. H., y Humaidi, A. J. (2023). Review on optimization techniques of pv/inverter ratio for grid-tie pv systems. *Applied Sciences*, 13(5). Descargado de <https://www.mdpi.com/2076-3417/13/5/3155> doi: 10.3390/app13053155
- Hernandez-Escobedo, Q., Ramirez-Jimenez, A., Dorador-Gonzalez, J. M., Perea-Moreno, M.-A., y Perea-Moreno, A.-J. (2020). Sustainable solar energy in mexican universities. case study: The national school of higher studies juriquilla (unam). *Sustainability*, 12(8). Descargado de <https://www.mdpi.com/2071-1050/12/8/3123> doi: 10.3390/su12083123
- Holland, J. (1975). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. University of Michigan Press. Descargado de <https://books.google.com.mx/books?id=JE5RAAAAMAAJ>
- Hussain, M., Dhimish, M., Titarenko, S., y Mather, P. (2020). Artificial neural network based photovoltaic fault detection algorithm integrating two bi-directional input parameters. *Renewable Energy*, 155, 1272-1292. Descargado de <https://www.sciencedirect.com/science/article/pii/S0960148120305516> doi: 10.1016/j.renene.2020.04.023
- Ishrat, Z., Gupta, A., y Nayak, S. (2023). A comprehensive review of mppt techniques based on ml applicable for maximum power in solar power systems. *Journal of Renewable Energy and Environment*. Descargado de [https://www.jree.ir/article\\_171383.html](https://www.jree.ir/article_171383.html) doi: 10.30501/jree.2023.385661.1556
- Junior, F. E. F., y Yen, G. G. (2019). Particle swarm optimization of deep neural networks architectures for image classification. *Swarm and Evolutionary Computation*, 49, 62-74. Descargado de <https://www.sciencedirect.com/science/article/pii/S2210650218309246> doi: <https://doi.org/10.1016/j.swevo.2019.05.010>
- Kamran, M., Mudassar, M., Fazal, M. R., Asghar, M. U., Bilal, M., y Asghar, R. (2020). Implementation of improved perturb and observe mppt technique with confined search space for standalone photovoltaic system. *Journal of King Saud University - Engineering Sciences*, 32(7), 432-441. Descargado de <https://www.sciencedirect.com/science/article/pii/S101836391730380X> (Photovoltaic Materials, Devices and Systems) doi: <https://doi.org/10.1016/j.jksues.2018.04.006>
- Kantz, H., y Schreiber, T. (2003). *Nonlinear time series analysis* (2.<sup>a</sup> ed.). Cambridge University Press. doi: 10.1017/CBO9780511755798
- KARABINAOGLU, M. S., GÜNEROGLU, A., ÇAKIR, B., abdulvehhab kazdaloglu, y BASOGLU, M. E. (2022). Comparison of deep learning and regression-based mppt algorithms in pv systems. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(6). Descargado de <http://search.yayin/detay/1142607>
- Karsoliya, S. (2012). ".approximating number of hidden layer neurons in multiple hidden layer bpnn architecture". seventh sense research group. Descargado de [www.ijettjournal.org](http://www.ijettjournal.org)

- Katche, M. L., Makokha, A. B., Zachary, S. O., y Adaramola, M. S. (2023). A comprehensive review of maximum power point tracking (mppt) techniques used in solar pv systems. *Energies*, 16(5). Descargado de <https://www.mdpi.com/1996-1073/16/5/2206> doi: 10.3390/en16052206
- Kelleher, J. D., Mac Namee, B., y D'Arcy, A. (2015). *Fundamentals of machine learning for predictive data analytics: Algorithms, worked examples, and case studies*. The MIT Press.
- Kennedy, J., y Eberhart, R. (1995a). Particle swarm optimization. En *Proceedings of ieee international conference on neural networks* (Vol. 4, pp. 1942–1948). IEEE.
- Kennedy, J., y Eberhart, R. (1995b). Particle swarm optimization. En *Proceedings of icnn'95 - international conference on neural networks* (Vol. 4, p. 1942-1948 vol.4). doi: 10.1109/ICNN.1995.488968
- Kermadi, M., Mekhilef, S., Salam, Z., Ahmed, J., y Berkouk, E. M. (2020). Assessment of maximum power point trackers performance using direct and indirect control methods. *International Transactions on Electrical Energy Systems*, 30(10), e12565. Descargado de <https://onlinelibrary.wiley.com/doi/abs/10.1002/2050-7038.12565> doi: <https://doi.org/10.1002/2050-7038.12565>
- Khan, A. Y., Ahmad, Z., Sultan, T., Alshahrani, S., Hayat, K., y Imran, M. (2022). Optimization of photovoltaic panel array configurations to reduce lift force using genetic algorithm and cfd. *Energies*, 15(24). Descargado de <https://www.mdpi.com/1996-1073/15/24/9580> doi: 10.3390/en15249580
- Köppen, W. (2011, 06). The thermal zones of the earth according to the duration of hot, moderate and cold periods and to the impact of heat on the organic world. *Meteorologische Zeitschrift*, 20(3), 351-360. Descargado de <http://dx.doi.org/10.1127/0941-2948/2011/105> doi: 10.1127/0941-2948/2011/105
- Kumar, G. G. S., y Titus, S. (2023). Hybrid artificial rabbit optimization and perturb and observe mppt for grid connected pv system. *Electric Power Components and Systems*, 0(0), 1-22. Descargado de <https://doi.org/10.1080/15325008.2023.2249885> doi: 10.1080/15325008.2023.2249885
- Larranaga, P., y Inza, I. (2021). *Tema 8. redes neuronales*. Descargado de <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf> ((accessed: 09.09.2021))
- Macías, G. (2022). Radiación solar convertiría en potencia a querétaro. *Diario de Queretaro*. Descargado de <https://www.diariodequeretaro.com.mx/local/radiacion-solar-convertiria-en-potencia-a-queretaro-8219266.html> (Accessed: 2022-05-01)
- Mahesh, P. V., Meyyappan, S., y Alla, R. R. (2022, 10). Maximum power point tracking using decision-tree machine-learning algorithm for photovoltaic systems. *Clean Energy*, 6(5), 762-775. Descargado de <https://doi.org/10.1093/ce/zkac057> doi: 10.1093/ce/zkac057
- Manikandan, P., y Selvaperumal, S. (2020, 07). Eanfis-based maximum power point tracking for standalone pv system. *IETE Journal of Research*, 1-14. doi: 10.1080/03772063.2020.1788425

- Marroquin-Arreola, R., Lezama, J., Hernandez-De León, H. R., Martinez-Romo, J. C., Hoyo-Montano, J. A., Camas-Anzueto, J. L., ... Santos-Ruiz, I. (2022). Design of an mppt technique for the indirect measurement of the open-circuit voltage applied to thermoelectric generators. *Energies*, 15(10). Descargado de <https://www.mdpi.com/1996-1073/15/10/3833> doi: 10.3390/en15103833
- Martín de Jesús Nieto Pérez; Jorge Pineda Piñón, R. P. E. G. A. R. L. M. A. V. H. (2010). Energías alternativas en cicata, querétaro. *CICATA*, 1.
- Massi Pavan, A., Vergura, S., Mellit, A., y Lughì, V. (2017). Explicit empirical model for photovoltaic devices. experimental validation. *Solar Energy*, 155, 647-653. Descargado de <https://www.sciencedirect.com/science/article/pii/S0038092X17305753> doi: <https://doi.org/10.1016/j.solener.2017.07.002>
- Mazaheri, P., Rahnamayan, S., y Bidgoli, A. A. (2022). Designing artificial neural network using particle swarm optimization: A survey. En M. A. Aceves-Fernández (Ed.), *Swarm intelligence* (cap. 3). Rijeka: IntechOpen. Descargado de <https://doi.org/10.5772/intechopen.106139> doi: 10.5772/intechopen.106139
- Messenger, R., y Abtahi, H. (2017). *Photovoltaic systems engineering: Fourth edition*. Routledge. doi: 10.1201/9781315151434
- Mi, J., Du, J., Liu, C., Li, X., Zhang, Y., y Fan, G. (2023). Design and optimization of photovoltaic system in full-chain ground-based validation system of space solar power station. *Energies*, 16(7). Descargado de <https://www.mdpi.com/1996-1073/16/7/3247> doi: 10.3390/en16073247
- Mirjalili, S., Mirjalili, S. M., y Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46-61. Descargado de <https://www.sciencedirect.com/science/article/pii/S0965997813001853> doi: <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Moldovan, M., Burduhos, B. G., y Visa, I. (2023). Efficiency assessment of five types of photovoltaic modules installed on a fixed and on a dual-axis solar-tracked platform. *Energies*, 16(3). Descargado de <https://www.mdpi.com/1996-1073/16/3/1229> doi: 10.3390/en16031229
- Morales-Enciso, S., y Branke, J. (2015). Tracking global optima in dynamic environments with efficient global optimization. *European Journal of Operational Research*, 242(3), 744-755. Descargado de <https://www.sciencedirect.com/science/article/pii/S0377221714009515> doi: <https://doi.org/10.1016/j.ejor.2014.11.028>
- Motahhir, S., y Eltamaly, A. (2021). *Advanced technologies for solar photovoltaics energy systems*. Springer. doi: 10.1007/978-3-030-64565-6
- Moussa, I., y Khedher, A. (2022). Chapter 4 - an experimental test bench for emulating the standard characteristics of photovoltaic (pv) systems. En M. Jeguirim (Ed.), *Renewable energy production and distribution* (Vol. 1, p. 107-135). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B978032391892300011X> doi: <https://doi.org/10.1016/B978-0-323-91892-3.00011-X>
- Ngan, M., y Tan, C. (2016, 06). Photovoltaic multiple peaks power tracking using particle swarm opti-

- mization with artificial neural network algorithm. En *Photovoltaic multiple peaks power tracking using particle swarm optimization with artificial neural network algorithm* (p. 107-138). Springer. doi: 10.1007/978-3-662-50521-2\_5
- Nguyen, X. H., y Nguyen, M. P. (2015, 09 de 12). Mathematical modeling of photovoltaic cell/module/arrays with tags in matlab/simulink. *Environmental Systems Research*, 4(1), 24. Descargado de <https://doi.org/10.1186/s40068-015-0047-9> doi: 10.1186/s40068-015-0047-9
- Nkambule, M., Hasan, A., Ali, A., Geem, Z. W., y Junhee. (2020, 12). Comprehensive evaluation of machine learning mppt algorithms for a pv system under different weather conditions. *Journal of Electrical Engineering and Technology*. doi: 10.1007/s42835-020-00598-0
- Olayiwola, T. N., y Choi, S.-J. (2023). Superellipse model: An accurate and easy-to-fit empirical model for photovoltaic panels. *Solar Energy*, 262, 111749. Descargado de <https://www.sciencedirect.com/science/article/pii/S0038092X23003547> doi: <https://doi.org/10.1016/j.solener.2023.05.026>
- Ortiz, A., Mendez, E., Macias, I., y Molina, A. (2022). Earthquake algorithm-based voltage referenced mppt implementation through a standardized validation frame. *Energies*, 15(23). Descargado de <https://www.mdpi.com/1996-1073/15/23/8971> doi: 10.3390/en15238971
- Ostheimer, J., Chowdhury, S., y Iqbal, S. (2021). An alliance of humans and machines for machine learning: Hybrid intelligent systems and their design principles. *Technology in Society*, 66, 101647. Descargado de <https://www.sciencedirect.com/science/article/pii/S0160791X21001226> doi: <https://doi.org/10.1016/j.techsoc.2021.101647>
- Owusu-Nyarko, I., Elgenedy, M. A., Abdelsalam, I., y Ahmed, K. H. (2021). Modified variable step-size incremental conductance mppt technique for photovoltaic systems. *Electronics*, 10(19). Descargado de <https://www.mdpi.com/2079-9292/10/19/2331> doi: 10.3390/electronics10192331
- Pawluszek-Filipiak, K., y Borkowski, A. (2020). On the importance of train–test split ratio of datasets in automatic landslide detection by supervised classification. *Remote Sensing*, 12(18). Descargado de <https://www.mdpi.com/2072-4292/12/18/3054> doi: 10.3390/rs12183054
- Peixeiro, M. (2022). *Time series forecasting in python*. Manning Publications.
- Petrone, G., Ramos-Paja, C., y Spagnuolo, G. (2017). *Photovoltaic sources modeling*. Wiley - IEEE. doi: 10.1002/9781118755877
- Philibus, E., Sallehuddin, R., Yussof, Y., y Yusuf, L. M. (2021, 12). Global solar radiation forecasting using artificial neural network and support vector machine. *Journal of Physics: Conference Series*, 2129(1), 012079. Descargado de <https://doi.org/10.1088/1742-6596/2129/1/012079> doi: 10.1088/1742-6596/2129/1/012079
- Prasad, L. B., Sahu, S., Gupta, M., Srivastava, R., Mozhui, L., y Asthana, D. N. (2016). An improved method for mppt using ann and ga with maximum power comparison through perturb amp; observe technique. En *2016 ieeu uttar pradesh section international conference on electrical, computer and electronics engineering (upcon)* (p. 206-211). doi: 10.1109/UPCON.2016.7894653
- Priyadarshi, N., Padmanaban, S., Holm-Nielsen, J. B., Blaabjerg, F., y Bhaskar, M. S. (2020). An experimental estimation of hybrid anfis–pso-based mppt for pv grid integration under fluctuating

- sun irradiance. *IEEE Systems Journal*, 14(1), 1218-1229. doi: 10.1109/JSYST.2019.2949083
- Pujahari, R. (2021). Chapter 2 - solar cell technology. En S. Dhoble, N. Kalyani, B. Vengadaesvaran, y A. Kariem Arof (Eds.), *Energy materials* (p. 27-60). Elsevier. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128237106000078> doi: <https://doi.org/10.1016/B978-0-12-823710-6.00007-8>
- Quansah, D. A., Adaramola, M. S., Takyi, G., y Edwin, I. A. (2017). Reliability and degradation of solar pv modules—case study of 19-year-old polycrystalline modules in ghana. *Technologies*, 5(2). Descargado de <https://www.mdpi.com/2227-7080/5/2/22> doi: 10.3390/technologies5020022
- Rabinowitz, N., Perbet, F., Song, H., Zhang, C., Eslami, S., y Botvinick, M. (2018, 02). Machine theory of mind. *Computer Science*.
- Rahman, M. M., y Islam, M. S. (2020, 04). Pso and ann based hybrid mppt algorithm for photovoltaic array under partial shading condition. *Engineering International*, 8(1), 9-24. Descargado de <https://abc.us.org/ojs/index.php/ei/article/view/481> doi: 10.18034/ei.v8i1.481
- Razykov, T., Ferekides, C., Morel, D., Stefanakos, E., Ullal, H., y Upadhyaya, H. (2011). Solar photovoltaic electricity: Current status and future prospects. *Solar Energy*, 85(8), 1580-1608. Descargado de <https://www.sciencedirect.com/science/article/pii/S0038092X1000366X> (Progress in Solar Energy 1) doi: <https://doi.org/10.1016/j.solener.2010.12.002>
- Roh, C. (2022). Deep-learning algorithmic-based improved maximum power point-tracking algorithms using irradiance forecast. *Processes*, 10(11). Descargado de <https://www.mdpi.com/2227-9717/10/11/2201> doi: 10.3390/pr10112201
- Rokonuzzaman, M. (2016). *Design and implementation of a microcontroller based maximum power point tracking solar charge controller* (Master of Science in Electrical, Electronic and Communication Engineering). Military Institute of Science and Technology, Mirpur Cantonment, Dhaka-1216, Bangladesh. (Student No./ID - 1013160025 (F), Session: 2013-2014)
- Salman, S., AI, X., y WU, Z. (2018). Design of a p and o algorithm based mppt charge controller for a stand-alone 200w pv system. *Protection and Control of Modern Power Systems*, 3(1), 25. Descargado de <https://doi.org/10.1186/s41601-018-0099-8> doi: 10.1186/s41601-018-0099-8
- Segbefia, O. K., y Sætre, T. O. (2022). Investigation of the temperature sensitivity of 20-years old field-aged photovoltaic panels affected by potential induced degradation. *Energies*, 15(11). Descargado de <https://www.mdpi.com/1996-1073/15/11/3865> doi: 10.3390/en15113865
- Shang, L., Guo, H., y Zhu, W. (2020). An improved MPPT control strategy based on incremental conductance algorithm. *Protection and Control of Modern Power Systems*, 5(1), 14. Descargado de <https://doi.org/10.1186/s41601-020-00161-z> doi: 10.1186/s41601-020-00161-z
- Shareef, H., Mutlag, A., y Mohamed, A. (2017). Random forest-based approach for maximum power point tracking of photovoltaic systems operating under actual environmental conditions. *Compu-*



- tational Intelligence and Neuroscience*, 2017, 1673864. doi: 10.1155/2017/1673864
- Singh Briar, J. P., y He, L. (2021). A high efficiency solar cell and system. En *2021 IEEE 48th Photovoltaic Specialists Conference (PVSC)* (p. 0074-0079). doi: 10.1109/PVSC43889.2021.9518701
- Sörensen, K. (2015). Metaheuristics—the metaphor exposed. *International Transactions in Operational Research*, 22(1), 3–18.
- Srivastava, R., Tiwari, A., y Giri, V. (2019). Solar radiation forecasting using mars, cart, m5, and random forest model: A case study for india. *Heliyon*, 5(10), e02692. Descargado de <https://www.sciencedirect.com/science/article/pii/S2405844019363522> doi: <https://doi.org/10.1016/j.heliyon.2019.e02692>
- Taye, M. M. (2023). Understanding of machine learning with deep learning: Architectures, workflow, applications and future directions. *Computers*, 12(5). Descargado de <https://www.mdpi.com/2073-431X/12/5/91> doi: 10.3390/computers12050091
- Tobon Mejia, A. F., Rojas Montano, J. J., Serna Garces, S. I., y Herrera Cuartas, J. A. (2021, 3). Parameters estimation of the single diode model of a photovoltaic module based on the improved patterns search method. *Revista Ingenierías Universidad de Medellín*, 20(38), 13-32. Descargado de <https://revistas.udem.edu.co/index.php/ingenierias/article/view/3024> doi: 10.22395/rium.v20n38a1
- Torres, D. G. D. S. . N. W. . L. I. G. E. R. N. (2015). Renewable energy sources : Mexico. *IRENA*, 1.
- Venkata Mahesh, P., Meyyappan, S., y Alla, R. (2023). Support vector regression machine learning based maximum power point tracking for solar photovoltaic systems. *International Journal of Electrical and Computer Engineering Systems*, 14(1). doi: <https://doi.org/10.32985/ijeces.14.1.11>
- Venkateswarlu, C. (2021). A metaheuristic tabu search optimization algorithm: Applications to chemical and environmental processes. En M. S. Tsuzuki y cols. (Eds.), *Engineering problems* (cap. 10). Rijeka: IntechOpen. Descargado de <https://doi.org/10.5772/intechopen.98240> doi: 10.5772/intechopen.98240
- Vincheh, M., Kargar, A., y Arab Markadeh, G. R. (2014, 06). A hybrid control method for maximum power point tracking (mppt) in photovoltaic systems. *Arabian Journal for Science and Engineering*, 39, 4715-4725. doi: 10.1007/s13369-014-1056-0
- Wang, B., Xue, B., y Zhang, M. (2020). Particle swarm optimisation for evolving deep neural networks for image classification by evolving and stacking transferable blocks. *Neural and Evolutionary Computing*. Descargado de <https://arxiv.org/abs/1907.12347>
- Wu, H., y Ying, W. (2019). Benchmarking machine learning algorithms for instantaneous net surface shortwave radiation retrieval using remote sensing data. *Remote Sensing*, 11(21). Descargado de <https://www.mdpi.com/2072-4292/11/21/2520> doi: 10.3390/rs11212520
- Xie, Z., y Wu, Z. (2021). Maximum power point tracking algorithm of pv system based on irradiance estimation and multi-kernel extreme learning machine. *Sustainable Energy Technologies and Assessments*, 44, 101090. Descargado de <https://www.sciencedirect.com/science/article/pii/S2213138821001004> doi: <https://doi.org/10.1016/j.seta.2021.101090>
- Xu, Y., y Goodacre, R. (2018). On splitting training and validation set: A comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of

- supervised learning. *Journal of Analytical Testing*, 2, 249–262. doi: 10.1007/s41664-018-0068-2
- Yang, X.-S. (2020). *Nature-inspired optimization algorithms: Second edition*. Elsevier.
- Yap, K. Y., Sarimuthu, C. R., y Lim, J. M.-Y. (2020, 11). Artificial intelligence based mppt techniques for solar power system: A review. *Journal of Modern Power Systems and Clean Energy*, 8(6).
- Ying, X. (2019, 02). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168, 022022. doi: 10.1088/1742-6596/1168/2/022022
- Zador, A. (2019, 12). A critique of pure learning and what artificial neural networks can learn from animal brains. *Nature Communications*, 10. doi: 10.1038/s41467-019-11786-6
- Zhang, C., Wu, S., Li, T., Yu, Z., y Bian, J. (2022). Interpreting the trends of extreme precipitation in florida through pressure change. *Remote Sensing*, 14(6). Descargado de <https://www.mdpi.com/2072-4292/14/6/1410> doi: 10.3390/rs14061410

## IX. Anexos

### Publicaciones

En esta sección se presenta una lista de publicaciones obtenidas durante el periodo del proyecto, como actas de conferencias, publicaciones en revistas y patentes.

### Primer Artículo en revista indexada

Villegas-Mier CG, Rodríguez-Resendiz J, Álvarez-Alvarado JM, Rodríguez-Resendiz H, Herrera-Navarro AM, Rodríguez-Abreo O. Artificial Neural Networks in MPPT Algorithms for Optimization of Photovoltaic Power Systems: A Review. *Micromachines*. 2021; <https://doi.org/10.3390/mi12101260>



## Segundo Articulo en revista indexada

Villegas-Mier CG, Rodriguez-Resendiz J, Álvarez-Alvarado JM, Jiménez-Hernández H, Odry Á. Optimized Random Forest for Solar Radiation Prediction Using Sunshine Hours. *Micromachines*. 2022; 13(9):1406. <https://doi.org/10.3390/mi13091406>



# Entregables

## Carta Aceptación Protocolo



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INFORMÁTICA



Campus Juriquilla, Qro., 09 de junio de 2023.

Oficio: FI/CA-441/100

Asunto: Dictamen del H. Consejo Académico

C. CÉSAR GABRIEL VILLEGAS MIER  
EXPEDIENTE 232579  
P R E S E N T E

Comunico a usted que en sesión ordinaria del H. Consejo Académico de la Facultad de Informática, celebrado el día 01 de febrero de 2022, se emitió

DICTAMEN: APROBADO

A su solicitud de aprobación de tema y contenido de Protocolo de Tesis denominada "Algoritmo para mejorar la eficiencia de un controlador MPPT fotovoltaico basado en un enfoque híbrido neuronal-metaheurístico" perteneciente al programa de Doctorado en Ciencias de Computación.

Sin otro particular, me es grato saludarle.

A T E N T A M E N T E  
"RAZONAMIENTO Y TECNOLOGÍA PARA INNOVAR Y TRANSFORMAR"

M.S.I. JOSÉ ALEJANDRO VARGAS DÍAZ  
SECRETARIO DEL H. CONSEJO ACADÉMICO



ccp. Acta No. 441  
M.S.I.'JAVD/sas'

**SOMOS UAQ**  
SERVIR. CONSTRUIR. TRANSFORMAR

Av. de las Ciencias s/n, Col. Juriquilla, Campus Juriquilla, Querétaro, Qro. México C.P. 76230  
Tel. Directo: 442 192 12 71, Conmutador 192 12 00 Ext. 5901 y 5902

# Firmas de registro de protocolo ante comité de investigación



## Registro del Protocolo de Investigación del Estudiante de Posgrado

Trámite a realizar:	Nuevo registro ( <input checked="" type="checkbox"/> )	Cambio ( <input type="checkbox"/> )
Fecha de Registro*:	08/09/2023	
No. Registro de Proyecto*:	14227	
Fecha de inicio de proyecto: Julio del 2019	Fecha de término de proyecto: Julio del 2023	

Espacio (\*) exclusivo para la Dirección de Investigación y Posgrado

### 1. Datos del solicitante:

No. de expediente: 232579

Nombre: **Villegas Mier Cesar Gabriel**

Apellido Paterno Apellido Materno Nombre(s)

Dirección: Loma de la Cañada #3 Loma Dorada 76060

Calle y número Colonia  
Querétaro 442-4645198  
C.P. cesarvillegasm@gmail.com  
Estado Teléfono

### 2. Datos del proyecto:

Facultad:	Informática
Programa:	Doctorado en Ciencias de la Computación
Tema específico del proyecto:	"Algoritmo para mejorar la eficiencia de un controlador MPPT fotovoltaico basado en un enfoque híbrido neuronal-metaheurístico"





### 3. Nombres y firmas de:

 Dr. Juvenal Rodríguez Reséndiz Director de Tesis	 Dr. José Manuel Álvarez Alvarado Co-director	 Dra. Ana Marcela Herrera Navarro Jefa de Investigación y Posgrado de la Facultad
 Cesar Gabriel Villegas Mier Alumno	 Dra. Gabriela Xicotencatl Ramírez Directora de la Facultad	 Dra. Ma. Guadalupe Flavia Loarca Piña Directora de Investigación y Posgrado

SOMOS UAQ

# Carta liberación de Inglés con + 80 %

  UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE LENGUAS Y LETRAS

8AS03

**A QUIEN CORRESPONDA:**


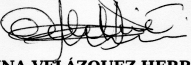
La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

**VILLEGAS MIER CESAR GABRIEL**

Presentó el **Examen de Manejo de la Lengua** efectuado el día seis de diciembre de dos mil veintidós, en el cual obtuvo la siguiente calificación:

**8+**

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día catorce de diciembre de dos mil veintitrés.

 **Atentamente,**  
"Enlazar Culturas por la Palabra"  
  
**DRA. ADELINA VELÁZQUEZ HERRERA**

**AVH/thb\*CL\*FLL-C.-2338**

**SOMOS UAQ**  
SERVIR CONSTRUIR TRANSFORMAR

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro. C.P. 76140  
Tel. 442 192 12 00 Dirección Ext. 61010, Secretaría Administrativa Ext.61300, Posgrado Ext. 61140,  
Licenciatura Ext.61070, Centro de Lenguas Ext.61050, Secretaría Académica Ext.61100 y Planeación Ext.61110

## Curso de Formación Académica



UNIVERSIDAD  
**AUTÓNOMA**  
DE QUERÉTARO

**HUAWEI**

**SA**  
SECRETARÍA  
ACADÉMICA

EDUCACIÓN  
COLABORATIVA PARA  
LA EXPERIENCIA VIVENCIAL

SA/EC23/CCH02

**SOMOS UAQ**  
ENSEÑAR PARA CONSTRUIR



**CERTIFICACIONES  
COLABORATIVAS**

La Universidad Autónoma de Querétaro  
le otorga la presente

# Constancia

**a: César Gabriel Villegas Mier**

Por haber participado y concluido con éxito el pilotaje de "Academia UAQ-Huawei" que comprende 3 Niveles con los cursos de Introducción a la IA, Búsqueda e IA, IA y aplicaciones, Desarrollo y conceptos básicos de Cloud Computing, Principios y aplicaciones de Cloud Computing y Internet de las cosas y aplicaciones, enmarcados en el proyecto de Certificaciones Colaborativas en conjunto con Huawei.

**Dr. Javier Ávila Morales**  
Secretario Académico

Centro Universitario, 14 de junio de 2023

**SOMOS UAQ**  
ENSEÑAR PARA CONSTRUIR



## Codigo Matlab/Simulink

En esta sección se presenta el código fuente de cada uno de los algoritmos o programas que fueron implementados a lo largo de esta tesis.

### Modelo de doble diodo

Listing 1: Insert code directly in your document

---

```
import numpy as np

def double_diode_model(v, i, rs, rsh, id1, id2, vd1, vd2):
    """Calculates the double diode model for PV systems.

    Args:
        v: The voltage of the PV cell (V).
        i: The current of the PV cell (A).
        rs: The series resistance of the PV cell (\omega).
        rsh: The shunt resistance of the PV cell (\omega).
        id1: The saturation current of the first diode (A).
        id2: The saturation current of the second diode (A).
        vd1: The ideality factor of the first diode.
        vd2: The ideality factor of the second diode.

    Returns:
        The current of the PV cell (A).
    """

    # Calculate the voltage across the first diode
    v_d1 = v - rs * i

    # Calculate the voltage across the second diode
    v_d2 = v - rs * i

    # Calculate the current through the first diode
    i_d1 = id1 * (np.exp(v_d1 / (vd1 * rs * i)) - 1)

    # Calculate the current through the second diode
    i_d2 = id2 * (np.exp(v_d2 / (vd2 * rs * i)) - 1)

    # Calculate the current through the shunt resistor
    i_sh = v / rsh

    # Calculate the total current
    i_total = i_d1 + i_d2 + i_sh

    return i_total

# Example usage:

v = 10 # Voltage of the PV cell (V)
i = 1 # Current of the PV cell (A)
```

```

rs = 0.1 # Series resistance of the PV cell (\omega)
rsh = 100 # Shunt resistance of the PV cell (\omega)
id1 = 1e-9 # Saturation current of the first diode (A)
id2 = 1e-10 # Saturation current of the second diode (A)
vd1 = 2 # Ideality factor of the first diode
vd2 = 3 # Ideality factor of the second diode

# Calculate the current of the PV cell
i_total = double_diode_model(v, i, rs, rsh, id1, id2, vd1, vd2)

print(i_total)

```

---

## Perturbacion y Observacion

Listing 2: Insert code directly in your document

---

```

import numpy as np
import pvlib

# Define the PV module parameters
Voc = 36.1 # Open-circuit voltage (V)
Isc = 9.8 # Short-circuit current (A)
Vmp = 29.8 # Maximum power point voltage (V)
Imp = 8.5 # Maximum power point current (A)

# Define the initial operating point
Vpv = Vmp # Voltage (V)
Ipv = Imp # Current (A)
Ppv = Vpv * Imp # Power (W)

# Define the step size for voltage perturbations
deltaV = 0.1 # Voltage step size (V)

# Define the maximum number of iterations
max_iter = 100 # Maximum number of iterations

# Implement the P&O MPPT algorithm
iter = 0
while iter < max_iter:
    # Perturb the voltage by the step size
    Vpv = Vpv + deltaV

    # Calculate the power at the new voltage
    Ipv = (Isc - Vpv / Voc * Isc) / (1 - Vpv / Voc)
    Ppv_new = Vpv * Ipv

    # Compare the power to the previous iteration
    if Ppv_new > Ppv:
        # If the power increased, continue perturbing in the same direction
        Ppv = Ppv_new
    else:

```

```

        # If the power decreased, change direction and reduce the step size
        deltaV = -deltaV / 2
        Vpv = Vpv + deltaV

    # Update the iteration counter
    iter += 1

# Print the maximum power point voltage and current
print("Maximum_power_point_voltage_(V):", Vpv)
print("Maximum_power_point_current_(A):", Ipv)

```

---

## Conductancia Incremental

Listing 3: Insert code directly in your document

---

```

import numpy as np

def pv_model(V, G, T):
    V_oc = 40 # Open-circuit voltage
    I_sc = 10 # Short-circuit current
    n = 1.3 # Ideality factor
    Rs = 0.01 # Series resistance

    k = 1.38064852e-23 # Boltzmann constant
    q = 1.60217662e-19 # Elementary charge
    T_ref = 298.15 # Reference temperature

    I_sat = I_sc / (np.exp((q * V_oc) / (n * k * T_ref)) - 1)
    I_out = I_sc - I_sat * (np.exp((q * (V + Rs * I_out)) /
    (n * k * T)) - 1) - (V + Rs * I_out) / 1e6

    return I_out

def incremental_conductance(G, T, V_init, step_size=0.1, max_iter=1000, tol=1e-6):
    V = V_init
    I = pv_model(V, G, T)

    for _ in range(max_iter):
        I_next = pv_model(V + step_size, G, T)
        dI_dV = (I_next - I) / step_size
        delta_V = -I / (I + dI_dV)
        V += delta_V

        if abs(delta_V) < tol:
            break

    I = I_next

    I_mpp = pv_model(V, G, T)
    P_mpp = V * I_mpp

```

```

    return V, I_mpp, P_mpp

# Example usage
G = 1000 # Irradiance (W/m^2)
T = 25 + 273.15 # Temperature (K)
V_init = 20 # Initial voltage guess

V_mpp, I_mpp, P_mpp = incremental_conductance(G, T, V_init)
print(f"V_mpp={V_mpp:.2f} V, I_mpp={I_mpp:.2f} A, P_mpp={P_mpp:.2f} W")

```

---

## Codigo para el acceso y tratamiento de los datos atmosfericos

### Codigo para el modelado y simulación de un panel PV usando el modelo ideal o simple

Listing 4: Insert code directly in your document

---

```

# Define the parameters of the PV panel
I_sc = 6.14 # short-circuit current [A]
V_oc = 36.3 # open-circuit voltage [V]
I_mp = 5.65 # current at maximum power [A]
V_mp = 28.4 # voltage at maximum power [V]

# Calculate current [A]
WeatherInfo['Current_MPP'] = I_sc * (WeatherInfo['Radiation'] / 1000) *
((1 / WeatherInfo['Temperature']) - (1 / 298.15))

# Calculate voltage [V]
WeatherInfo['Voltage_MPP'] =
V_oc - ((V_oc - V_mp) / (I_sc - I_mp)) * WeatherInfo['Current_MPP']

# Calculate power [W]
WeatherInfo['Power_MPP'] = WeatherInfo['Voltage_MPP'] * WeatherInfo['Current_MPP']

```

---

## Codigo para obtener el MPP usando ANN

Listing 5: Insert code directly in your document

---

```

import numpy as np
import pandas as pd
import tensorflow as tf
from tensorflow import keras
from sklearn.model_selection import train_test_split

# Define the input and output variables
X = WeatherInfo.drop(['Power_MPP'], axis=1)
y = WeatherInfo['Power_MPP']

# Split the data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Define the neural network model
model = keras.Sequential([

```

```

keras.layers.Dense(64, input_dim=X_train.shape[1], activation='relu'),
keras.layers.Dense(32, activation='relu'),
keras.layers.Dense(1, activation='linear')
])

# Compile the model
model.compile(optimizer='adam', loss='mse')

# Train the model
model.fit(X_train, y_train, epochs=100, batch_size=16, validation_data=(X_test, y_test))

# Use the model to predict the MPP
MPP_predicted = model.predict(X_test)

# Print the mean squared error
mse = np.mean((MPP_predicted - y_test)**2)
print('Mean_Squared_Error:', mse)

```

---

## Codigo para obtener el MPP usando ANN + GAO

Listing 6: Insert code directly in your document

---

```

import numpy as np
import pandas as pd
from deap import base, creator, tools, algorithms
from sklearn.model_selection import train_test_split
from tensorflow import keras

# Define the input and output variables
X = WeatherInfo.drop(['Power_MPP'], axis=1).values
y = WeatherInfo['Power_MPP'].values

# Split the data into training and testing sets
X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.2, random_state=42)

# Define the neural network evaluation function
def eval_nn(individual):
    model = keras.Sequential()
    model.add(keras.layers.Dense(individual[0], input_dim=X_train.shape[1], activation='relu'))
    model.add(keras.layers.Dense(individual[1], activation='relu'))
    model.add(keras.layers.Dense(1, activation='linear'))
    model.compile(optimizer='adam', loss='mse')
    model.fit(X_train, y_train, epochs=individual[2], batch_size=individual[3], verbose=0)
    score = model.evaluate(X_test, y_test, verbose=0)
    return score,

# Define the genetic algorithm toolbox
creator.create("FitnessMin", base.Fitness, weights=(-1.0,))
creator.create("Individual", list, fitness=creator.FitnessMin)
toolbox = base.Toolbox()

```

```

toolbox.register("attr_neurons", np.random.randint, 16, 128)
toolbox.register("attr_batch_size", np.random.randint, 8, 32)
toolbox.register("attr_epochs", np.random.randint, 50, 200)
toolbox.register("individual", tools.initCycle, creator.Individual,
(toolbox.attr_neurons, toolbox.attr_neurons,
toolbox.attr_epochs, toolbox.attr_batch_size), n=1)
toolbox.register("population", tools.initRepeat, list, toolbox.individual)
toolbox.register("evaluate", eval_nn)
toolbox.register("mate", tools.cxTwoPoint)
toolbox.register("mutate", tools.mutUniformInt, low=[16, 8, 50, 8],
up=[128, 32, 200, 32], indpb=0.1)
toolbox.register("select", tools.selTournament, tournsize=3)

# Define the genetic algorithm parameters
pop_size = 10
num_generations = 10
cxpb = 0.5
mutpb = 0.2

# Create the initial population and run the genetic algorithm
pop = toolbox.population(n=pop_size)
for gen in range(num_generations):
    offspring = algorithms.varAnd(pop, toolbox, cxpb=cxpb, mutpb=mutpb)
    fits = toolbox.map(toolbox.evaluate, offspring)
    for fit, ind in zip(fits, offspring):
        ind.fitness.values = fit
    pop = toolbox.select(offspring, k=len(pop))

# Print the best individual and its fitness score
best_ind = tools.selBest(pop, k=1)[0]
best_score = eval_nn(best_ind)
print('Best_individual:', best_ind)
print('Best_score:', best_score)

```

---

## Codigo para obtener el MPP usando ANN + GWO

Listing 7: Insert code directly in your document

---

```

import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from pygwo import gwo

# Load and preprocess the dataset
data = pd.read_csv("solar_data.csv")
X = data[["voltage", "current", "irradiance", "temperature"]].values
y = data["mpp"].values

```

```

scaler = MinMaxScaler()
X = scaler.fit_transform(X)
y = y.reshape(-1, 1)
y = scaler.fit_transform(y)

# Split the dataset
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Define the neural network architecture
def create_model(params):
    model = Sequential()
    model.add(Dense(int(params["hidden1"]), activation=params["activation1"], input_dim=4))
    model.add(Dense(int(params["hidden2"]), activation=params["activation2"]))
    model.add(Dense(1, activation="linear"))
    return model

# Define the fitness function
def fitness_function(params):
    model = create_model(params)
    model.compile(optimizer="adam", loss="mse", metrics=["mae"])
    history = model.fit(X_train, y_train, batch_size=int(params["batch_size"]),
                        epochs=int(params["epochs"]), verbose=0,
                        validation_split=0.2)
    loss, mae = model.evaluate(X_test, y_test, verbose=0)
    return mae

# Define the search space for the GWO algorithm
search_space = {
    "hidden1": (8, 64),
    "hidden2": (8, 64),
    "activation1": ["relu", "tanh"],
    "activation2": ["relu", "tanh"],
    "batch_size": (8, 64),
    "epochs": (50, 150)
}

# Define the GWO parameters
num_wolves = 20
num_iterations = 50

# Optimize the neural network using the GWO algorithm
best_params, best_fitness = gwo(fitness_function, search_space, num_wolves, num_iterations)

# Train the neural network using the optimal hyperparameters
optimal_model = create_model(best_params)
optimal_model.compile(optimizer="adam", loss="mse", metrics=["mae"])
optimal_model.fit(X_train, y_train,
                  batch_size=int(best_params["batch_size"]), epochs=int(best_params["epochs"]),
                  validation_split=0.2)

```

```

# Predict MPP using the optimized neural network
input_data = np.array([[voltage , current , irradiance , temperature]])
input_data_scaled = scaler.transform(input

```

---

## Codigo para obtener el MPP usando ANN + PSO

Listing 8: Insert code directly in your document

---

```

# Define the input and output variables

X = df.drop('Radiation', axis=1).values
y = df['Radiation'].values

# Split the data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Define the neural network model function
def create_model(params):
    model = keras.Sequential([
        keras.layers.Dense(int(params[0]), input_dim=X_train.shape[1], activation='relu'),
        keras.layers.Dense(int(params[1]), activation='relu'),
        keras.layers.Dense(1, activation='linear')
    ])

    # Compile the model
    model.compile(optimizer='adam', loss='mse')

    # Train the model
    model.fit(X_train, y_train, epochs=int(params[2]), batch_size=int(params[3]), verbose=0)

    # Use the model to predict the MPP
    MPP_predicted = model.predict(X_test)

    # Calculate the mean squared error
    mse = np.mean((MPP_predicted - y_test)**2)

    return mse

# Define the PSO objective function
def objective_function(params):
    n_particles = params.shape[0]
    mse = np.zeros(n_particles)
    for i in range(n_particles):
        mse[i] = create_model(params[i])
    return mse

# Define the PSO search space for hyperparameters
search_space = (
    np.array([16, 16, 50, 8]), # Lower bounds
    np.array([128, 64, 200, 32]) # Upper bounds

```



```

)

# Set PSO hyperparameters
n_particles = 10
n_iterations = 15

# Run the PSO optimization
options = {'c1': 0.5, 'c2': 0.3, 'w': 0.9}
optimizer = ps.single.GlobalBestPSO(n_particles=n_particles,
dimensions=4, options=options, bounds=search_space)
cost, optimal_params
= optimizer.optimize(objective_function, iters=n_iterations)

# Print the optimal hyperparameters and the corresponding MSE
print("Optimal_hyperparameters:")
print("First_hidden_layer_neurons: {}".format(int(optimal_params[0])))
print("Second_hidden_layer_neurons: {}".format(int(optimal_params[1])))
print("Number_of_training_epochs: {}".format(int(optimal_params[2])))
print("Batch_size: {}".format(int(optimal_params[3])))
print("Optimal_MSE: {:.4f}".format(cost))

```

---

### Código para Arduino de MPPT usando redes neuronales

Este ejemplo asume que se tiene una red neuronal de una sola capa oculta con una capa de salida lineal para el seguimiento de MPP. Sustituya los pesos y sesgos(bias) que están de muestra por los parámetros de su propio modelo entrenado.

Listing 9: Insert code directly in your document

---

```

#include <Arduino.h>

#define INPUT_NEURONS 4
#define HIDDEN_NEURONS 4
#define OUTPUT_NEURONS 1

//Pesos y sesgos de las redes neuronales

float input_weights[HIDDEN_NEURONS][INPUT_NEURONS] = {
// Reemplace estos valores con sus pesos entrenados de entrada a capa oculta
  {0.1, 0.2, 0.3, 0.4},
  {0.2, 0.3, 0.4, 0.5},
  {0.3, 0.4, 0.5, 0.6},
  {0.4, 0.5, 0.6, 0.7},
};

float hidden_biases[HIDDEN_NEURONS] = {
  // Reemplaza estos valores con los sesgos de tu capa oculta entrenada
  0.1, 0.2, 0.3, 0.4
};

float output_weights[OUTPUT_NEURONS][HIDDEN_NEURONS] = {

```

```

// Sustituye estos valores por los pesos de la capa oculta entrenada
{0.1, 0.2, 0.3, 0.4}
};

float output_biases[OUTPUT_NEURONS] = {
// Sustituye estos valores por los sesgos de tu capa de salida entrenada
0.1
};

//Funcion de activacion
float relu(float x) {
return max(0.0, x);
}

//Aqui se implementa la RNA del tipo Feedforward.
float predict_mpp(float input[INPUT_NEURONS]) {
float hidden[HIDDEN_NEURONS];
for (int i = 0; i < HIDDEN_NEURONS; i++) {
hidden[i] = 0;
for (int j = 0; j < INPUT_NEURONS; j++) {
hidden[i] += input[j] * input_weights[i][j];
}
hidden[i] = relu(hidden[i] + hidden_biases[i]);
}

float output[OUTPUT_NEURONS];
for (int i = 0; i < OUTPUT_NEURONS; i++) {
output[i] = 0;
for (int j = 0; j < HIDDEN_NEURONS; j++) {
output[i] += hidden[j] * output_weights[i][j];
}
output[i] += output_biases[i];
}

return output[0];
}

void setup() {
Serial.begin(9600);
}

void loop() {
//Aqui se leen los valores para voltage , corriente ,
irradiancia y temperatura en los puertos analogicos del arduino.
Puede Variar segun el tipo de microcontrolador.

float voltage = analogRead(A0);
float current = analogRead(A1);
float irradiance = analogRead(A2);
float temperature = analogRead(A3);

```

```
//Escalado y normalizacion de los datos de entrada dependiendo el preprocesamiento.  
  float input_data[INPUT_NEURONS] = {voltage, current, irradiance, temperature};  
// Predecir el MPP utilizando la red neuronal  
  float predicted_mpp = predict_mpp(input_data);  
  
//Se imprime el Punto de Maxima Potencia Calculado  
  Serial.print("Predicted_MPP:");  
  Serial.println(predicted_mpp);  
  
  delay(1000);  
}
```

---