

Intelligent hybrid MPPT control using ANFIS with real data training for a photovoltaic system: Case study in Cúcuta, Norte de Santander.

Jhon Lizarazo¹; Aldo Pardo García²; Ivaldo Torres Chávez³

¹First Author Servicio Nacional de Aprendizaje SENA, Colombia, jlizarazop@sena.edu.co

^{2,3}Second and Third Author's University of Pamplona, Colombia, apartdo13@unipamplona.edu.co,
ivaldo.torres@unipamplona.edu.co

Abstract– A maximum power point tracking (MPPT) system based on an adaptive neuro-fuzzy controller (ANFIS) trained with real irradiance and temperature data is proposed and experimentally validated, applied to a photovoltaic system operating under highly variable climatic conditions. Unlike most approaches reported in the literature, which use synthetic data and deterministic real-time platforms, this work integrates a double-diode model with measurements obtained using a class A pyranometer to build a training base that captures the stochastic nature of the tropical environment. The controller is implemented on a Raspberry Pi 5 running Linux and governs a 100 kHz Boost DC-DC converter connected to a 340 W photovoltaic array installed in Cúcuta, Colombia. The ANFIS estimates the optimal operating voltage from irradiance and temperature vectors. The experimental results show a tracking time of 100 ms compared to 240 ms for the conventional Perturb and Observe method, with a maximum static efficiency of 96.4% and a dynamic efficiency of 94.5% under fluctuating actual irradiance. The results demonstrate that intelligent MPPT controllers trained with real data can operate robustly on low-cost, non-deterministic embedded platforms.

Keywords-- Modeling and simulation of power systems, Control system design, Intelligent control of power systems, Control of renewable energy resources, Application of power electronics, Maximum Power Point Tracking, Power and Energy System.

Control MPPT híbrido inteligente mediante ANFIS con entrenamiento de datos reales para un sistema fotovoltaico: Caso de estudio en Cúcuta, Norte de Santander.

Jhon Lizarazo¹; Aldo Pardo García²; Ivaldo Torres Chávez³

^{1,3}First Author Servicio Nacional de Aprendizaje SENA, Colombia, jlizarazop@sena.edu.co

²Second and Third Author's University of Pamplona, Colombia, apartdo13@unipamplona.edu.co,
ivaldo.torres@unipamplona.edu.co

Resumen— *Se propone y valida experimentalmente un sistema de seguimiento del punto de máxima potencia (MPPT) basado en un controlador neuro-difuso adaptativo (ANFIS) entrenado con datos reales de irradiancia y temperatura, aplicado a un sistema fotovoltaico operando bajo condiciones climáticas altamente variables. A diferencia de la mayoría de los enfoques reportados en la literatura, los cuales emplean datos sintéticos y plataformas de tiempo real deterministas, este trabajo integra un modelo de doble diodo con mediciones obtenidas mediante un piranómetro clase A para construir una base de entrenamiento que captura la naturaleza estocástica del entorno tropical. El controlador se implementa en una Raspberry Pi 5 bajo sistema operativo Linux y gobierna un convertidor DC-DC tipo elevador de 100 kHz conectado a un arreglo fotovoltaico de 340 W instalado en Cúcuta, Colombia. El algoritmo ANFIS estima el voltaje óptimo de operación (V_{mpp}) a partir de vectores de irradiancia (G) y temperatura (T). Los resultados experimentales muestran un tiempo de seguimiento de 100 ms frente a 240 ms del método convencional Perturb and Observe, con una eficiencia estática máxima de 96.4 % y una eficiencia dinámica de 94.5 % bajo irradiancia real fluctuante. Los resultados demuestran que los controladores MPPT inteligentes entrenados con datos reales operan de forma robusta en plataformas embebidas no deterministas de bajo costo, habilitando su aplicación en microrredes fotovoltaicas reales.*

Palabras clave-- *Seguimiento del Punto de Máxima Potencia (MPPT), Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS), Convertidor DC-DC elevador, Raspberry Pi 5, Modelo de Doble Diodo, Piranómetro Clase A, Eficiencia Dinámica.*

I. INTRODUCCIÓN

Las fuentes empleadas para la producción de electricidad se clasifican en combustibles fósiles, energía nuclear y recursos renovables. Los suministros de origen fósil son no renovables debido a que su proceso de formación geológica requiere millones de años, resultando en una tasa de consumo significativamente superior a su velocidad de recuperación. La combustión de estos recursos genera gases de efecto invernadero (GEI) que impactan la salud humana y el equilibrio ecológico, impulsando la transición internacional hacia energías limpias como la solar fotovoltaica.

En consecuencia, la tendencia internacional actual prioriza la transición hacia energías limpias e inagotables, como la solar fotovoltaica, para garantizar un medio ambiente saludable y proteger el bienestar de las generaciones venideras [1]. Este escenario impulsa la urgencia académica de investigar métodos avanzados para optimizar el aprovechamiento de los recursos naturales disponibles[2].

La transición global hacia matrices energéticas descarbonizadas ha posicionado a la energía solar fotovoltaica (PV) como la fuente renovable más prometedora debido a su carácter inagotable y bajo impacto ambiental. No obstante, la naturaleza no lineal de las células fotovoltaicas y su dependencia crítica de variables estocásticas, como la irradiancia y la temperatura, limitan la eficiencia de conversión convencional, que suele oscilar en el 17% hasta un 31% en pruebas de laboratorio. Para mitigar estas pérdidas, es imperativo el desarrollo de sistemas de Seguimiento del Punto de Máxima Potencia (MPPT), capaces de ajustar dinámicamente la impedancia del sistema para maximizar la transferencia energética bajo cualquier condición atmosférica.

Aunque numerosos estudios reportan estrategias MPPT basadas en ANFIS con elevados niveles de eficiencia, la mayoría utiliza bases de datos sintéticas generadas a partir de modelos simplificados y se implementan en hardware determinista de tiempo real (DSP o FPGA). En consecuencia, el comportamiento de estos controladores bajo condiciones atmosféricas estocásticas reales, ruido de sensores y plataformas embebidas con sistemas operativos multipropósito (no deterministas) continúa siendo insuficientemente explorado. Este trabajo aborda dicha brecha mediante el entrenamiento de un controlador ANFIS con datos reales de irradiancia y temperatura adquiridos en campo, y su implementación en una plataforma embebida basada en Raspberry Pi 5 operando bajo Linux, validada experimentalmente en condiciones climáticas tropicales de alta variabilidad.

Las contribuciones principales de este artículo se resumen a continuación:

Entrenamiento con datos híbridos reales: Construcción de un conjunto de datos altamente representativo mediante la combinación del modelo físico de doble diodo y registros ambientales adquiridos en campo con un piranómetro Clase A (ISO 9060:2018) en Cúcuta, Colombia, capturando la variabilidad estocástica tropical.

Despliegue en plataforma no determinista: Validación experimental directa en una tarjeta embebida de bajo costo Raspberry Pi 5 bajo sistema operativo Linux, demostrando estabilidad operativa a pesar de las latencias del planificador del SO.

Evaluación comparativa rigurosa: Cuantificación experimental de los tiempos de asentamiento y eficiencias estáticas/dinámicas frente a algoritmos convencionales y avanzados bajo transitorios de irradiancia superiores a 300 W/m^2 .

II. MODELADO DEL SISTEMA.

A. Modelado del Arreglo Fotovoltaico.

Para caracterizar el arreglo fotovoltaico se implementó el modelo de doble diodo (Figura 1). A diferencia del modelo de diodo simple, esta representación ofrece una precisión superior al capturar los fenómenos de recombinación de carga de espacio de la celda, como se puede evidenciar en las ecuaciones 1,2,3 y 4, este estudio aprovecha la capacidad de procesamiento de la toolbox de Simscape de Matlab/simulink R2024a para gestionar la complejidad del modelo de doble diodo. Esto garantiza una base de datos de entrenamiento para el algoritmo ANFIS que integra de forma más robusta variables críticas como la irradiancia (G) y la temperatura de la celda (T). En [3] se aborda el modelamiento por medio de diodo simple a diferencia de [4], el cual menciona tres modelos de circuito equivalente de celdas solares para analizar el comportamiento soportado por la ecuación de Shockley para la corriente del diodo.




Fig. 1. Circuito equivalente de celda solar [5].

$$I = I_{PG} + I_{D1} + I_{D2} - \frac{V_{D1}}{R_{PL}} \quad (1)$$

$$I_{D1} = I_{D2} (e^{V_{D2}/\sigma_2 V_T} - 1) \quad (2)$$

$$V = V_D - IR_{SR} \quad (3)$$

$$V_T = \frac{N_s k T}{q} \quad (4)$$

I es la corriente en la carga, I_{PG} es la corriente generada por la irradiancia, I_{D1} corriente de saturación del diodo 1, I_{D2} corriente de saturación del diodo 2, R_{PL} la resistencia en

paralelo, V_T el voltaje térmico, V_{PVG} voltaje en la carga, N_s es el número de celdas en serie k es la constante de Boltzman, T es la temperatura en kelvin (K) y q es el valor de la carga eléctrica.

B. Caracterización del Panel e Instrumentación.

El modelado y la parametrización de las curvas I-V y P-V se desarrollaron en la toolbox Simscape Electrical de MATLAB/Simulink R2024a [6] (Figura 2), cabe resaltar que existe una diferencia entre un arreglo fotovoltaico y una celda fotovoltaica solar, donde la celda tiene el modelo de doble diodo y el PV array usa el modelo de diodo simple. En la figura 2 se muestran las características de los paneles adquiridos para la investigación El sistema físico utiliza un panel fotovoltaico Amerisolar AS-6P de 340 W [7].




Fig. 2. Caracterización panel solar Amerisolar AS.6P de 340W MATLAB/Simulink.

La medición de la irradiancia se llevó a cabo utilizando un piranómetro EKO MS-80S, el cual está categorizado como clase A bajo la normativa ISO 9060:2018 [7]. Este dispositivo integra un sensor de temperatura con sensor, conectado mediante bus RS-485/Modbus RTU. La calibración del instrumento de septiembre de 2024 garantiza una incertidumbre de medición inferior al $\pm 2\%$.

Para representar con precisión el comportamiento de los generadores fotovoltaicos en presencia de no uniformidades en la irradiancia, es necesario considerar la arquitectura de interconexión de los módulos. En [8] se presenta un modelo explícito para arreglos fotovoltaicos con estructuras de enlace cruzado (Total-Cross-Tied) en configuraciones irregulares, demostrando que la interacción entre celdas bajo distintas irradiancias genera múltiples puntos de máxima potencia dinámicos que demandan estrategias de control de MPPT con alta capacidad adaptativa.

C. Diseño de Convertidor DC- DC tipo Elevador.

Dentro de los sistemas de acondicionamiento de potencia, los convertidores DC-DC se clasifican fundamentalmente en

topologías aisladas (Flyback, Forward, Push-Pull, Half-Bridge y Full-Bridge) y no aisladas (Reductor, Elevador, Reductor-Elevador, entre otras) [8]. En el diseño y control de convertidores de potencia aplicados a acondicionamiento energético, las topologías DC-DC no aisladas como elevadora, reductora-elevadora o Cúk requieren esquemas de control robustos ante la no linealidad de las fuentes de generación. En [9] se analiza el control por modos deslizantes en convertidores DC-DC/AC para garantizar estabilidad dinámica frente a perturbaciones de entrada, lo que respalda la necesidad de implementar algoritmos de control adaptativos como ANFIS frente a la variabilidad estocástica de la irradiancia solar.

En la presente investigación, se implementó un convertidor tipo elevador debido a su capacidad intrínseca para elevar la tensión del arreglo fotovoltaico, el cual opera con un voltaje de circuito abierto V_{oc} de 46.1 V y una tensión de máxima potencia (V_{mp}) de 37.5 V. Dado que la aplicación exige alimentar una carga resistiva con un voltaje constante de 166 V para la estabilización del bus de corriente continua (CC), la topología elevadora resulta ser la más eficiente para este diferencial de potencial. La configuración del circuito detallada en la Figura 3 resalta la integración de un MOSFET como elemento activo de conmutación para la gestión dinámica del ciclo útil [7].

Las ecuaciones de diseño tradicionales para convertidores DC-DC tipo elevador observadas en [2] no caracterizan integralmente los sistemas de generación fotovoltaica, debido a la volatilidad intrínseca de la tensión suministrada por el módulo. Al no ser una fuente de voltaje constante, el cálculo del ciclo de trabajo mediante relaciones estáticas resulta impreciso, lo que obliga a emplear estrategias de control dinámicas que se ajusten a las fluctuaciones de la entrada.

$$D = \frac{V_{out} - V_{in}}{V_{out}} \quad (5)$$

En la relación del inductor se encuentra también un valor dependiente del V_{in} y la I_L .

$$L = \frac{V_i * D}{\Delta I_L * f_s} \quad (6)$$

$$\Delta I_L = \frac{(0.2 - 0.4) I_o V_o}{V_i} \quad (7)$$

$$C = \frac{I_o * D}{f_s * \Delta V_o} \quad (8)$$

La arquitectura del sistema experimental se fundamenta en la integración de los componentes de hardware seleccionados durante la fase de diseño, cuya topología se encuentra validada rigurosamente en el esquema detallado de la Figura 3. Esta configuración física permite la transición del modelado teórico a la validación empírica bajo condiciones operativas reales.




Fig. 3. Diagrama esquemático del convertidor DC-DC tipo elevador implementado ($L = 350\mu H$, $C_{in} = 470\mu F$, $C_{out} = 80\mu H$).

En la Figura 4 se muestra los componentes del sistema experimental, la unidad de procesamiento central se fundamenta en una Raspberry Pi 5 ejecutando Python v3.12, plataforma seleccionada por su alta capacidad para gestionar algoritmos de inteligencia artificial. El sistema integra un piranómetro EKO MS-80S clase A con sensor de temperatura embebido para la captura de variables atmosféricas, cuya comunicación se garantiza mediante un bus RS485 con emulación serial vía USB. A diferencia de arquitecturas convencionales, esta implementación emplea sensores de alta precisión para la retroalimentación de corriente y voltaje, operando bajo un software de adquisición [10], diseñado para gestionar señales single-ended de +3.3V con una restricción de seguridad de 2.15V impuesta por el aislador galvánico AMC0311. Los registros se capturan a una frecuencia de 10 Hz, tasa técnicamente justificada dado que la frecuencia de conmutación del MOSFET (100 kHz) es órdenes de magnitud superior [11], permitiendo una toma de decisiones estable frente a las latencias típicas de un hardware con sistema operativo.

III. METODOLOGÍA O PROCEDIMIENTOS

En [12] y [13] se clasifican las técnicas de MPPT de acuerdo a diferencias en implementación. Para [12] existen cuatro grupos principales que son: métodos clásicos, métodos de optimización, métodos avanzados y métodos híbridos; sin embargo, para [13] la clasificación en métodos offline y online, cada uno con arquitecturas diferentes. Se tomarán las técnicas online de P&O y basadas en Inteligencia artificial, según el postulado hecho por [10] para un convertidor Buck a diferencia de este estudio se realizará para un convertidor elevador. El uso de técnicas de inteligencia artificial en sistemas de energía renovable no solo abarca el seguimiento del máximo punto de potencia en el convertidor, sino también la optimización y dimensionamiento estático y dinámico de los recursos de generación híbrida y almacenamiento [14]. Esto demuestra el papel transversal que desempeñan las arquitecturas inteligentes en la gestión energética eficiente.

La ejecución del proyecto se estructuró en tres fases secuenciales que permitieron la transición desde el modelado teórico hasta la validación empírica en condiciones ambientales reales en Cúcuta, Colombia.

En la primera etapa, se empleó la herramienta MATLAB/Simulink para caracterizar el comportamiento dinámico del arreglo fotovoltaico acoplado a un convertidor DC-DC tipo elevador, asegurando la fidelidad del sistema. Segunda fase, los resultados de la simulación sirvieron como base de datos para el entrenamiento de un controlador inteligente basado en un sistema de inferencia neuro-difuso (ANFIS), el cual combina la capacidad de aprendizaje de las redes neuronales con la flexibilidad de la lógica difusa.

Finalmente, se implementó el sistema físico para contrastar la precisión del algoritmo MPPT frente a la variabilidad estocástica de la irradiancia y la temperatura, utilizando una arquitectura de control estandarizada y hardware de bajo costo. En la figura 5 se muestra el diagrama de bloques de la estructura general de un sistema solar fotovoltaico con un convertidor elevador [15]




Fig. 4. Diagrama de bloques en Simscape Electrical para simulación de algoritmo ANFIS.

La Figura 4 presenta la modelación en el entorno MATLAB/Simulink de un convertidor DC-DC elevador operado mediante el algoritmo convencional de Perturbación y Observación (P&O). Como técnica clásica de seguimiento por búsqueda de gradiente, este método exhibe deficiencias críticas, tales como oscilaciones persistentes en el estado estable alrededor del Punto de Máxima Potencia (MPP) [16]. Con el fin de evaluar la respuesta transitoria del controlador, el sistema fue sometido a variaciones de irradiancia en escalones de 300W/m², permitiendo cuantificar la operación de su eficiencia ante cambios climáticos abruptos.




Fig. 5. Diagrama de Bloques simulación Sistema PV y convertidor DC-DC en Simscape Matlab/Simulink R2024a.




Fig. 6. Resposta del sistema MPPT ante escalones de irradiancia, temperatura Constante.

La Figura 5 detalla la respuesta del sistema ante variaciones discretas de irradiancia, implementadas en escalones de 300W/m² para evaluar la robustez del algoritmo de control. Se observa una correlación lineal entre la densidad de flujo solar y la corriente del panel, registrando valores de 2.8, 5.6, 8.3 y 9.1 A para irradiancias de 300, 600, 900 y 1000W/m², respectivamente. Mientras que la tensión del arreglo PV se mantuvo estable cerca de los 36 V, valor consistente con el punto de máxima potencia (V_{mp}) reportado en la ficha técnica, el convertidor elevador logró elevar el voltaje de salida a niveles progresivos de 85, 92, 160 y 170 V para una carga constante de 10 Ω . En consecuencia, la potencia total obtenida (100 a 330 W) confirma que el sistema opera con una eficiencia cercana al 90%, validando el comportamiento del controlador en escenarios de irradiancia y temperatura fluctuantes[17].

IV. DISEÑO CONTROLADOR ANFIS PARA MPPT

El sistema ANFIS constituye una arquitectura de computación inteligente que fusiona la capacidad adaptativa de las Redes Neuronales Artificiales (ANN) con la transparencia de la Lógica Difusa de Takagi-Sugeno. Este modelo es una herramienta estándar en el control de sistemas no lineales, ya que segmenta las variables de entrada en conjuntos difusos para mapear salidas precisas mediante funciones de pertenencia en la etapa de defuzzificación [18].

En el diseño del algoritmo MPPT, se definen la irradiancia (G) y la temperatura (T) como las variables de entrada críticas para la unidad de procesamiento. A partir de estos parámetros, el controlador calcula y emite un ciclo útil optimizado (señal PWM) que establece el voltaje de referencia necesario para converger en el punto de máxima potencia del sistema [19]. La Figura 5 detalla el flujo operativo de la técnica ANFIS, ilustrando la interconectividad sistémica entre los dispositivos de sensado y la etapa de conversión de potencia [20].

A diferencia de los estudios fundamentados exclusivamente en simulación, que reportan velocidades de seguimiento entre 5.8ms [21], 11 ms [22] y 46 ms [23], el despliegue experimental de algoritmos MPPT inteligentes exige hardware con alta capacidad de procesamiento. Mientras que dispositivos especializados como la serie C2000 de TI han logrado tiempos de asentamiento de 160 ms[24], esta investigación se centra en la implementación sobre una Raspberry Pi 5. A pesar de la latencia introducida por el núcleo de Linux, el sistema propuesto procesa datos estocásticos de irradiancia y temperatura para orquestar la toma de decisiones del algoritmo ANFIS. El objetivo final es optimizar la señal de control PWM del MOSFET, garantizando que un hardware de bajo costo pueda ofrecer un rendimiento comparable al de las tarjetas de adquisición industriales. También en [25] se reportan resultados validados físicamente con una tarjeta compacRIO y labview con tiempos de 220ms para el seguimiento.

La ejecución operativa del algoritmo ANFIS se estructura en cinco niveles jerárquicos diseñados para procesar dinámicamente vectores de irradiancia y temperatura ambiental [26]. En la capa inicial de fuzzificación, las entradas se transforman en conjuntos lingüísticos mediante funciones de pertenencia (típicamente gaussianas), mientras que la segunda y tercera capa gestionan la fuerza de disparo de las reglas y la normalización de los pesos de activación. Durante la etapa de defuzzificación (cuarta capa), el sistema computa los parámetros consecuentes refinados mediante aprendizaje neuronal, culminando en una sumatoria agregada (quinta capa) que establece el voltaje de referencia óptimo. Esta señal se compara con el estado operativo actual para modular el ciclo útil (PWM) del convertidor DC-DC, permitiendo un acople de impedancias preciso que maximiza la transferencia de energía desde la fuente fotovoltaica hacia la carga [27].

La función de pertenencia que mejor se comportó en cuanto a la reducción del error cuadrático es de tipo sugeno de 8 para la primera entrada y 6 para la segunda que es la temperatura del sistema como se puede observar en la figura 11.

TABLA I. Construcción del Conjunto de datos de entrenamiento de algoritmo ANFIS.

Elemento	Descripción
Fuente	Simscape + Piranómetro real
# muestras	231211 W/m ²
G rango	100 – 1200 W/m ² Paso 1 W/m ²
T rango	Ej: 19–59 °C Paso 2°C
Muestreo	0.1 s
Split	70% train, 15% val, 15% test
Error	RMSE

El desempeño de un controlador ANFIS depende críticamente de la calidad y representatividad de los datos de entrenamiento. En este trabajo se adoptó una estrategia híbrida

que combina modelado físico de alta fidelidad con mediciones ambientales reales, con el fin de capturar tanto la estructura no lineal del sistema fotovoltaico como la naturaleza estocástica del entorno operativo. “Eficiencia medida bajo condiciones de irradiancia reales.”

En primer lugar, el generador fotovoltaico fue modelado mediante el modelo de doble diodo implementado en la toolbox Simscape Electrical de MATLAB/Simulink, el cual permite una representación más precisa de los fenómenos de recombinación y pérdidas internas que los modelos de un solo diodo. Este modelo fue parametrizado de acuerdo con las especificaciones eléctricas del panel Amerisolar AS-6P de 340 W y validado frente a sus curvas I–V y P–V suministradas por el fabricante.

Posteriormente, se incorporaron mediciones reales de irradiancia (G) y temperatura de la celda (T) adquiridas mediante un piranómetro EKO MS-80S clase A, el cual garantiza una incertidumbre inferior al ± 2 % conforme a la norma ISO 9060:2018. Estas señales se registraron en campo bajo condiciones climáticas reales en Cúcuta, Colombia, caracterizadas por alta variabilidad y frecuentes transiciones de nubosidad. De este modo, el conjunto de datos de entrenamiento refleja no solo las relaciones físicas del panel, sino también la dinámica estocástica del recurso solar.

Para cada par (G,T) el modelo de doble diodo fue utilizado para calcular el voltaje de máxima potencia V_{mpp} y la potencia asociada, construyendo así un conjunto de datos supervisado de la forma:

$$D = \{G_i, T_i, V_{MPPI}\}_{i=1}^N$$

Donde N es el número total de muestras adquiridas.

Las señales de irradiancia y temperatura fueron filtradas mediante un filtro paso bajo digital para eliminar ruido de medición y picos espurios, manteniendo intacta la dinámica relevante para el control MPPT. Posteriormente, los datos fueron normalizados en el rango [0,1] para evitar dominancia numérica durante el proceso de aprendizaje.

El conjunto de datos se dividió aleatoriamente en tres subconjuntos: 70% para entrenamiento, 15% para validación y 15% para prueba. Esta partición permite evaluar la capacidad de generalización del modelo y evita el sobreajuste, un aspecto crítico en aplicaciones de control en tiempo real.

El sistema ANFIS se diseñó con dos entradas (irradiancia G y temperatura T) y una salida (voltaje óptimo de referencia V_{ref}). Las funciones de pertenencia de las entradas se seleccionaron de tipo gaussiano debido a su suavidad y buena capacidad de interpolación en sistemas no lineales.

Tras un proceso de optimización empírica, se adoptaron ocho funciones de pertenencia para la irradiancia y seis para la temperatura, lo que genera un total de 48 reglas difusas tipo Takagi–Sugeno. Esta estructura proporciona un compromiso

adecuado entre precisión de aproximación y complejidad computacional, condición indispensable para su ejecución en hardware embebido.

El entrenamiento ANFIS se realizó mediante el algoritmo híbrido estándar, que combina mínimos cuadrados para estimación de los parámetros consecuentes y retro-propagación del error para el ajuste de los parámetros de las funciones de pertenencia. La función objetivo a minimizar fue el error cuadrático medio entre el voltaje de referencia estimado por el ANFIS y el valor Real de V_{mpp} obtenido del modelo físico y las mediciones:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (V_{MPPi} - V_{refi})^2}$$

El proceso de entrenamiento se detuvo cuando el error de validación alcanzó un mínimo o cuando se cumplió el criterio de convergencia, evitando el sobrecalentamiento.




Fig. 7. Diagrama de flujo de algoritmo MPPT-ANFIS.




Fig. 8. Estructura de capas del modelado con ANFIS en Matlab.

Una vez entrenado de acuerdo a la figura 8, el modelo ANFIS fue exportado a una estructura computacional compatible con Python y ejecutado en una Raspberry Pi 5. En operación en

línea, el sistema recibe los valores de irradiancia y temperatura y estima el voltaje de referencia óptimo, el cual es utilizado para modular el ciclo útil del convertidor DC–DC elevador mediante una señal PWM.

Esta arquitectura permite que el controlador se adapte dinámicamente a variaciones rápidas de irradiancia y temperatura, garantizando el seguimiento del máximo punto de potencia incluso bajo condiciones de alta incertidumbre ambiental.

IV. IMPLEMENTACIÓN DE CONTROLADOR ANFIS PARA MPPT.

La validación experimental del sistema propuesto se llevó a cabo bajo condiciones climáticas reales en la ciudad de Cúcuta, Colombia (7.87° N, 72.48° O), una región caracterizada por alta irradiancia promedio y rápidas transiciones de nubosidad. Estas condiciones constituyen un escenario particularmente exigente para los algoritmos MPPT, ya que generan múltiples máximos locales y gradientes abruptos en la curva potencia–voltaje del arreglo fotovoltaico.

El controlador ANFIS entrenado con datos híbridos (modelo de doble diodo y mediciones reales de irradiancia–temperatura) fue comparado directamente con el algoritmo clásico de Perturbación y Observación (P&O) utilizando el mismo hardware, convertidor elevador y perfil atmosférico. Esta comparación controlada permite aislar el efecto del algoritmo de seguimiento y evaluar su comportamiento bajo incertidumbre ambiental real.

Ante escalones rápidos de irradiancia de hasta 300 W/m², el controlador ANFIS demostró una capacidad superior para identificar y seguir el máximo punto de potencia. El tiempo promedio de convergencia hacia el MPP fue de aproximadamente 100 ms, mientras que el algoritmo P&O requirió alrededor de 240 ms bajo las mismas condiciones. Esta mejora del 58% en velocidad de seguimiento es particularmente relevante en climas tropicales, donde las transiciones de irradiancia ocurren con alta frecuencia y penalizan de forma significativa la energía capturada cuando se emplean métodos basados en búsqueda por gradiente.

La reducción del tiempo de asentamiento se debe a la naturaleza predictiva del ANFIS, que utiliza el mapeo no lineal aprendido entre irradiancia, temperatura y voltaje óptimo, evitando las oscilaciones inherentes a los algoritmos clásicos o de escalada. En contraste, P&O presentó fluctuaciones persistentes alrededor del MPP.

El sistema alcanzó una eficiencia estática máxima de 96.4 % cuando las condiciones de irradiancia se estabilizaron, valor que confirma la capacidad del controlador ANFIS para mantener el punto de operación cercano al MPP real. La eficiencia dinámica, evaluada durante transitorios rápidos de

irradiancia, fue de 94.5%, reflejando la penalización introducida por los cambios bruscos en la potencia disponible y por las latencias inherentes al hardware de adquisición y procesamiento.

Si bien estos valores son ligeramente inferiores a los reportados en estudios basados en DSP o FPGA bajo condiciones de laboratorio controladas, es importante destacar que en este trabajo la eficiencia se mide bajo irradiancia real, sensores físicos y un sistema operativo no determinista. En este contexto, los resultados obtenidos son altamente competitivos y demuestran que un controlador MPPT inteligente entrenado con datos reales puede operar de manera robusta incluso en plataformas embebidas de bajo costo.

Durante pruebas experimentales en las que se introdujeron transiciones rápidas de nubosidad, el controlador ANFIS logró converger consistentemente hacia el máximo punto de potencia, mientras que el algoritmo P&O quedó atrapado en máximos locales durante intervalos apreciables.

Este comportamiento se explica por el entrenamiento del ANFIS con un conjunto de datos que incluye la variabilidad real de irradiancia y temperatura, permitiéndole internalizar patrones no lineales que no están disponibles para los métodos basados únicamente en perturbaciones incrementales. El conjunto de datos está disponible bajo solicitud.

La implementación sobre una Raspberry Pi 5 ejecutando Linux introduce latencias variables asociadas a la planificación de procesos y a la adquisición de señales a 12 Hz. A pesar de esta limitación, el sistema mantuvo una respuesta dinámica estable, lo que demuestra que el controlador ANFIS es suficientemente robusto para operar en plataformas no deterministas sin degradación severa del desempeño. Este resultado es especialmente relevante para aplicaciones de microrredes y sistemas fotovoltaicos distribuidos, donde el uso de hardware de bajo costo es un requisito fundamental para la escalabilidad.

En comparación con implementaciones ANFIS reportadas en plataformas de tiempo real dedicadas, que alcanzan tiempos de seguimiento del orden de 160–220 ms, el sistema propuesto logra una respuesta de 100 ms utilizando una arquitectura de menor costo y mayor incertidumbre temporal. Aunque no alcanza los récords de velocidad observados en simulación pura, la presente implementación constituye una de las pocas validaciones experimentales de un MPPT inteligente entrenado con datos reales y desplegado en un entorno operativo no ideal.

En consecuencia, la principal contribución de este trabajo no radica únicamente en mejorar métricas tradicionales de MPPT, sino en demostrar que el aprendizaje neuro-difuso basado en datos ambientales reales permite trasladar el control avanzado desde laboratorios altamente instrumentados hacia plataformas embebidas accesibles, habilitando su adopción en

sistemas fotovoltaicos reales expuestos a incertidumbre climática.




Figura 10. Resultado de condición de alta variabilidad con algoritmo P&O en raspberry Pi 5.




Figura 11. Resultado de controlador ANFIS ante condiciones de cambios rápidos en la irradiancia.

IV. CONCLUSIONES

Este trabajo presentó y validó experimentalmente un sistema de seguimiento del punto de máxima potencia (MPPT) basado en un controlador neuro-difuso adaptativo (ANFIS) entrenado con datos reales de irradiancia y temperatura y desplegado en una plataforma embebida de bajo costo operando bajo un sistema operativo no determinista. A diferencia de la mayoría de los enfoques reportados en la literatura, que se apoyan en datos sintéticos y hardware de tiempo real, la arquitectura propuesta fue evaluada bajo condiciones climáticas reales caracterizadas por alta variabilidad, proporcionando una visión más fiel del desempeño de los algoritmos inteligentes en aplicaciones fotovoltaicas prácticas.

Los resultados experimentales demostraron que el controlador ANFIS logra una reducción significativa del tiempo de seguimiento del punto de máxima potencia frente al algoritmo convencional de Perturbación y Observación, alcanzando tiempos de convergencia del orden de 100 ms bajo irradiancia real fluctuante. Asimismo, se obtuvo una eficiencia estática

máxima de 96.4 % y una eficiencia dinámica de 94.5 %, lo que confirma la capacidad del sistema para mantener una operación cercana al máximo punto de potencia incluso en presencia de transitorios atmosféricos rápidos y latencias propias del hardware y del sistema operativo Linux.

La integración de un modelo fotovoltaico de doble diodo con mediciones reales de un piranómetro clase A permitió construir una base de entrenamiento representativa de la dinámica física y estocástica del recurso solar, dotando al controlador ANFIS de una capacidad predictiva superior frente a métodos basados exclusivamente en búsqueda incremental. Esta característica fue clave para mejorar la estabilidad del sistema durante cambios abruptos de irradiancia.

Desde una perspectiva práctica, los resultados confirman que los algoritmos MPPT basados en inteligencia artificial pueden ejecutarse de manera fiable en plataformas embebidas de bajo costo, sin requerir procesadores de tiempo real dedicados, siempre que sean entrenados con datos que reflejen adecuadamente las condiciones ambientales reales. Esto abre una vía viable para la implementación de control avanzado en microrredes fotovoltaicas distribuidas y en entornos donde la robustez frente a la incertidumbre climática es más relevante que el desempeño bajo condiciones idealizadas.

En conjunto, este trabajo aporta una validación experimental de que el aprendizaje neuro-difuso basado en datos reales permite trasladar el control inteligente del laboratorio a sistemas fotovoltaicos reales, contribuyendo al desarrollo de soluciones MPPT más resilientes, escalables y económicamente accesibles para la transición energética.

Para garantizar la reproducibilidad científica y promover el desarrollo de algoritmos de control inteligente en sistemas fotovoltaicos, el conjunto de datos de entrenamiento y prueba utilizado en este trabajo compuesto por 231,211 mediciones reales de irradiancia y temperatura capturadas en Cúcuta, Colombia, se encuentra públicamente disponible en el repositorio de acceso abierto Zenodo. DOI: <https://doi.org/10.5281/zenodo.18703123>.

AGRADECIMIENTO/RECONOCIMIENTO

Este trabajo ha sido realizado gracias al apoyo del programa de becas de formación de talento especializado del ministerio de Ciencia y tecnología e Innovación en Colombia Minciencias, La universidad de pamplona y el Servicio Nacional de Aprendizaje quienes aportaron infraestructura y software de simulación.

REFERENCES

- [1] M. H. Rashid, *Power Electronics Devices, Circuits & Applications 4/E*, Fourth Edi. USA, Florida, 2014.
- [2] M. H. Rashid, *Power Electronics Handbook*, Fifth. Florida, United States, 2024.
- [3] Y. García Figueredo, F. García Reina, and J. A. Martín Alfonso, "Mathematical model for the determination of volt-ampere characteristics in solar photocells.," *Rev. Colomb. Tecnol. Av.*, 2022, doi: 10.24054/rcta.v2i40.2358.
- [4] B. Yang, R. Xie, and Z. Guo, "Maximum Power Point Tracking Technology for PV Systems: Current Status and Perspectives," *Energy Eng. J. Assoc. Energy Eng.*, vol. 121, no. 8, pp. 2009–2022, 2024, doi: 10.32604/ee.2024.049423.
- [5] N. Priyadarshi, S. M. Mueen, M. S. Bhaskar, and F. Azam, "An improved standalone photovoltaic system with hybrid dual integral sliding mode and model predictive control for MPPT," no. October 2021, pp. 1–15, 2023, doi: 10.1049/rpg2.12665.
- [6] Mathworks, "SimScape™ Electrical™ Toolbox™ User 's Guide R 2024 a," pp. 1–12004, 2024.
- [7] N. Hernández Díaz, A. Pardo Garcia, E. N. Sánchez Camperos, and C. J. Vega, "Implementación De Un Módulo Para El Control Y Gestión Del Almacenamiento De Energía En Una Microrred Eléctrica," *Rev. Colomb. Tecnol. Av.*, vol. 1, no. 37, pp. 91–98, 2023, doi: 10.24054/rcta.v1i37.1258.
- [8] J. D. Bastidas Rodriguez, C. A. Ramos-Paja, and A. J. Saavedra-Montes, "Arreglos fotovoltaicos con estructura cruzada con configuración irregular : un modelo," pp. 73–77, 2024, doi: <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/2821>.
- [9] C. A. Ramos Paja, S. I. Serna Garcés, and A. J. Saavedra-Montes, "Rectificador Elevador / Reductor con Corrección de Factor de Potencia basado en un convertidor Cuk y control por modos deslizantes," 2025, doi: <https://doi.org/10.24054/rcta.v2i46.3525>.
- [10] A. A. Alzubaidi, L. A. Khaliq, H. S. Hamad, W. K. Al-Azzawi, M. S. Jabbar, and T. A. Shihab, "MPPT implementation and simulation using developed P&O algorithm for photovoltaic system concerning efficiency," *Bull. Electr. Eng. Informatics*, vol. 11, no. 5, pp. 2460–2470, 2022, doi: 10.11591/eei.v11i5.3949.
- [11] A. Zouhri, "Advanced Perturb and Observe Algorithm for Maximum Power Point Tracking in Photovoltaic Systems With Adaptive Step Size," *J. Autom. Mob. Robot. Intell. Syst.*, vol. 18, no. 3, pp. 55–60, 2024, doi: 10.14313/JAMRIS/3-2024/22.
- [12] M. Abdel-Salam, M. T. EL-Mohandes, and M. Goda, "History of maximum power point tracking," *Green*

- Energy Technol.*, pp. 1–29, 2020, doi: 10.1007/978-3-030-05578-3_1.
- [13] H. P. Nguyen, T. T. Nguyen, M. P. Le, and T. N. Tran, “Experimental platforms consisting of software-in-the-loop, hardware-in-the-loop and power-hardware-in-the-loop for developing MPPT charge controller for photovoltaic system,” *Sol. Energy*, vol. 298, no. May, p. 113666, 2025, doi: 10.1016/j.solener.2025.113666.
- [14] O. Gualdrón, R. Laguado, and E. Florez, “Dimensionamiento óptimo de un sistema híbrido de energía solar-eólica y banco de baterías utilizando inteligencia artificial,” *Rev. Colomb. Tecnol. Av.*, pp. 152–159, 2022, doi: 10.24054/rcta.v2i40.2363.
- [15] M. Khan, M. A. Raza, M. Faheem, S. A. Sarang, M. Panhwar, and T. A. Jumani, “Conventional and artificial intelligence based maximum power point tracking techniques for efficient solar power generation,” *Eng. Reports*, vol. 6, no. 12, pp. 1–47, 2024, doi: 10.1002/eng2.12963.
- [16] A. M. Eltamaly and H. M. H. Farh, *PV characteristics, performance and modelling*. 2020. doi: 10.1007/978-3-030-05578-3_2.
- [17] S. Ngo, C. S. Chiu, T. D. Ngo, and C. T. Nguyen, “A novel hybrid method based MPP tracking design using boost converter for solar power systems,” *Int. J. Power Electron. Drive Syst.*, vol. 15, no. 1, pp. 506–517, 2024, doi: 10.11591/ijpeds.v15.i1.pp506-517.
- [18] D. Zhang and T. Chen, “Scikit-ANFIS: A Scikit-Learn Compatible Python Implementation for Adaptive Neuro-Fuzzy Inference System,” *Int. J. Fuzzy Syst.*, vol. 26, no. 6, pp. 2039–2057, 2024, doi: 10.1007/s40815-024-01697-0.
- [19] S. A. Sarang *et al.*, “Maximizing solar power generation through conventional and digital MPPT techniques: a comparative analysis,” *Sci. Rep.*, vol. 14, no. 1, pp. 1–18, 2024, doi: 10.1038/s41598-024-59776-z.
- [20] A. Alice Hepzibah and K. Premkumar, “ANFIS current–voltage controlled MPPT algorithm for solar powered brushless DC motor based water pump,” *Electr. Eng.*, vol. 102, no. 1, pp. 421–435, 2020, doi: 10.1007/s00202-019-00885-8.
- [21] E. H. M. Ndiaye, A. Ndiaye, and M. Faye, “Experimental Validation of PSO and Neuro-Fuzzy Soft-Computing Methods for Power Optimization of PV installations,” *8th Int. Conf. Smart Grid, icSmartGrid 2020*, pp. 189–197, 2020, doi: 10.1109/icSmartGrid49881.2020.9144790.
- [22] L. Farah, A. Haddouche, and A. Haddouche, “Comparison between proposed fuzzy logic and anfis for MPPT control for photovoltaic system,” *Int. J. Power Electron. Drive Syst.*, vol. 11, no. 2, pp. 1065–1073, 2020, doi: 10.11591/ijpeds.v11.i2.pp1065-1073.
- [23] A. K. Devarakonda, N. Karuppiah, T. Selvaraj, P. K. Balachandran, R. Shanmugasundaram, and T. Senjyu, “A Comparative Analysis of Maximum Power Point Techniques for Solar Photovoltaic Systems,” *Energies*, vol. 15, no. 22, pp. 1–30, 2022, doi: 10.3390/en15228776.
- [24] S. Rajput and M. Averbukh, “A Method to Search Global Maxima by Permanent Monitoring of Voltage and Current of each PV Panel,” *2020 22nd Eur. Conf. Power Electron. Appl. EPE 2020 ECCE Eur.*, pp. 1–7, 2020, doi: 10.23919/EPE20ECCEEurope43536.2020.9215943.
- [25] B. Meryem, N. Ahmed, and F. Ahmed, “Simulation and Implementation of a Modified ANFIS MPPT Technique,” *Adv. Technol. Innov.*, vol. 5, no. 4, pp. 230–247, 2020, doi: 10.46604/aiti.2020.4987.
- [26] M. I. S. Guerra, F. M. U. de Araújo, M. Dhimish, and R. G. Vieira, “Assessing maximum power point tracking intelligent techniques on a pv system with a buck–boost converter,” *Energies*, vol. 14, no. 22, 2021, doi: 10.3390/en14227453.
- [27] A. M. Farayola, A. N. Hasan, and A. Ali, “Use of MPPT techniques to reduce the energy pay-back time in PV systems,” *2018 9th Int. Renew. Energy Congr. IREC 2018*, no. Irec, pp. 1–6, 2018, doi: 10.1109/IREC.2018.8362553.