



UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO

MAESTRIA EN ELÉCTRICIDAD

MODALIDAD: INFORME DE INVESTIGACIÓN

Título:

DISEÑO Y SIMULACIÓN DE UN SISTEMA DE TRACKING BASADO EN REDES NEURONALES PARA MANTENER LA MÁXIMA EFICIENCIA DE PANELES SOLARES.

Trabajo de Titulación previo a la obtención del título de Magister en Electricidad mención
Sistemas Eléctricos de Potencia.

Autor

Ing. Jessy Corina Tapia Palma PhD.

Tutor

Ing. Juan Carlos Astudillo Muñoz MsC.

LATACUNGA – ECUADOR

2023

AVAL DEL TUTOR

En mi calidad de Tutor del Trabajo de Titulación “Diseño y simulación de un sistema de tracking basado en redes neuronales para mantener la máxima eficiencia de paneles solares” presentado por Jessy Corina Tapia Palma, para optar por el título magíster en Electricidad mención Sistemas Eléctricos de Potencia

CERTIFICO

Que dicho trabajo de investigación ha sido revisado en todas sus partes y se considera que reúne los requisitos y méritos suficientes para ser sometido a la presentación para la valoración por parte del Tribunal de Lectores que se designe y su exposición y defensa pública.

Latacunga, julio 25, 2023




.....
Msc. Juan Carlos Astudillo Muñoz
CC.:1803218708


AVAL DEL TRIBUNAL

El trabajo de Titulación: “Diseño y simulación de un sistema de tracking basado en redes neuronales para mantener la máxima eficiencia de paneles solares”, ha sido revisado, aprobado y autorizado su impresión y empastado, previo a la obtención del título de Magíster en Electricidad mención Sistemas Eléctricos de Potencia; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.

Latacunga, julio 25, 2023



.....
MSc. Castillo Fiallos Jessica Nataly
CC.: 0604590216
Presidente del tribunal



.....
MSc. Jiménez Jiménez Diego Leonardo
CC.: 0503493702
Lector 2



.....
MSc. Quinatoa Caiza Carlos Iván
CC.: 0503287864
Lector 3

DEDICATORIA

A mi esposo Julio e hijos Elisa y Hernán por su paciencia, amor y apoyo incondicional, a ustedes mi dedicatoria por ser la motivación e inspiración fundamental en todas las decisiones tomadas.

Jessy Corina Tapia Palma

AGRADECIMIENTO

A Dios y a mi familia
quienes son el pilar primordial de mis proyectos.

A los docentes de la Universidad Técnica de Cotopaxi,
quiénes con su profesionalismo han encaminado
para cumplir con los objetivos de está maestría.

Jessy Corina Tapia Palma

RESPONSABILIDAD DE AUTORÍA

Quien suscribe, declara que asume la autoría de los contenidos y los resultados obtenidos en el presente trabajo de titulación.

Latacunga, Julio 25, 2023



.....
Jessy Corina Tapia Palma
C.I. 0502784259

RENUNCIA DE DERECHOS

Quien suscribe, cede los derechos de autoría intelectual total y/o parcial del presente trabajo de titulación a la Universidad Técnica de Cotopaxi.

Latacunga, Julio 25, 2023

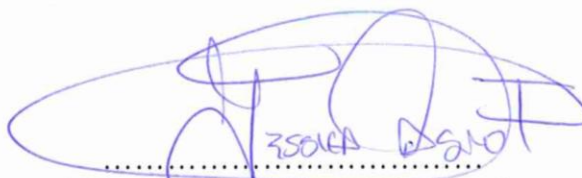


.....
Jessy Corina Tapia Palma
C.I. 0502784259

AVAL DEL PRESIDENTE DEL TRIBUNAL

Quien suscribe, declara que el presente Trabajo de Titulación “Diseño y simulación de un sistema de tracking basado en redes neuronales para mantener la máxima eficiencia de paneles solares”, contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, Julio 26, 2023



MSc. Castillo Fiallos Jessica Nataly
CC.: 0604590216

**UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO**

**MAESTRÍA ENELECTRICIDAD
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**

Título: Diseño y Simulación de un Sistema de Tracking Basado en Redes Neuronales para Mantener la Máxima Eficiencia de Paneles Solares.

Autor: Jessy Corina Tapia Palma

Tutor: Ing. Juan Carlos Astudillo Muñoz, Msc.

RESUMEN

Este trabajo de investigación se centra en el uso de redes neuronales artificiales (RNA) como una herramienta prometedora para mejorar la eficiencia y estabilidad de los sistemas solares fotovoltaicos. Aunque los sistemas fotovoltaicos aprovechan una fuente de energía limpia y renovable, enfrentan desafíos debido a las variaciones en la radiación solar, temperatura y condiciones ambientales. Estos factores ocasionan fluctuaciones en la corriente y tensión de salida de los paneles solares, afectando la potencia generada. Para abordar este problema, se requiere implementar estrategias de control que maximicen la extracción de potencia del campo fotovoltaico.

El enfoque principal de este trabajo es el punto de máxima potencia (MPP), que representa el punto óptimo de transferencia de potencia en la curva de características corriente-voltaje (I-V) de un panel solar. El desafío radica en adaptarse a las condiciones cambiantes y lograr un seguimiento preciso del MPP para mejorar la eficiencia del sistema. Aunque existen diferentes algoritmos de seguimiento propuestos, han mostrado limitaciones en términos de tasas de seguimiento y oscilaciones en estado estacionario. Para superar estas deficiencias, se exploran las aplicaciones de las RNA en el diseño de algoritmos de control. Las RNA se destacan por su alta respuesta dinámica y capacidad para adaptarse a condiciones no lineales. Sin embargo, obtener datos precisos de entrenamiento para el controlador es uno de los principales desafíos. En este estudio, se consideran variables importantes como radiación solar, temperatura y voltaje óptimo como entradas para el controlador.

PALABRAS CLAVE: Redes neuronales artificiales (RNA), Eficiencia, Sistemas solares fotovoltaicos, Punto de máxima potencia (MPP), Control basado en RNA

**UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO**

**MAESTRÍA EN ELECTRICIDAD
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**

Title: Design and Simulation of a Tracking System Based on Neural Networks to Maintain the Maximum Efficiency of Solar Panels

Author: Jessy Corina Tapia Palma.

Tutor: Juan Carlos Astudillo Muñoz, MsC.

ABSTRACT

This research focuses on the use of artificial neural networks (ANNs) as a promising tool to improve the efficiency and stability of photovoltaic solar systems. Although photovoltaic systems harness a clean and renewable energy source, they face challenges due to variations in solar radiation, temperature, and environmental conditions. These factors cause fluctuations in the current and voltage output of solar panels, impacting the generated power. To address this issue, the implementation of control strategies that maximize power extraction from the photovoltaic field is required.

The main focus of this work is the maximum power point (MPP), which represents the optimal power transfer point on the current-voltage (I-V) characteristic curve of a solar panel. The challenge lies in adapting to changing conditions and achieving precise MPP tracking to enhance system efficiency. While various tracking algorithms have been proposed, they have shown limitations in terms of tracking rates and steady-state oscillations. To overcome these deficiencies, the applications of ANNs in control algorithm design are explored. ANNs stand out for their high dynamic response and ability to adapt to non-linear conditions. However, obtaining accurate training data for the controller is one of the main challenges. This study considers important variables such as solar radiation, temperature, and optimal voltage as inputs for the controller.

KEYWORDS: Artificial neural networks (ANNs), Efficiency, Photovoltaic solar systems, Maximum power point (MPP), ANN-based control.

Yo, Lcda. Guevara Cordova Lourdes Jacqueline con cédula de identidad número 1803690922, Licenciada en Ciencias de la Educación mención Inglés con número de registro de la SENECYT 1010-08-850045; CERTIFICO haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: Diseño y Simulación de un Sistema de Tracking Basado en Redes Neuronales para Mantener la Máxima Eficiencia de Paneles Solares de Ing. Jessy Corina Tapia Palma aspirante a magister en Electricidad mención Sistemas Eléctricos de Potencia.

Latacunga, Julio 25, 2023



.....
Lcda. Lourdes Jacqueline Guevara Cordova
CC.: 1803690922

ÍNDICE DE CONTENIDOS

INTRODUCCIÓN	1
Antecedentes:	1
Planteamiento del problema:	3
Formulación del problema	4
Objetivo General	4
Objetivos Específicos:	4
Sistemas de tareas en relación a los objetivos específicos:	4
Justificación	6
Hipótesis	8
CAPÍTULO I.	9
FUNDAMENTACIÓN TEORICA-METODOLOGICA	9
1.1. Antecedentes de la investigación o fundamentación del estado del arte.-	9
1.2. Fundamentación Teórica.-	11
1.2.1 Sistema de Redes Neuronales Artificiales	11
1.2.2 Arquitectura ANN	13
1.2.3 Sistemas de energía solar fotovoltaica	14
1.2.4 Redes neuronales artificiales para el control de MPPT en sistemas fotovoltaicos	15
1.3. Fundamentación metodológica	17
1.3.1 Investigación de campo	17
1.3.2 Investigación bibliográfica	17
1.3.2 Investigación cuantitativa	18
1.4. Conclusiones	18
CAPÍTULO II.	19
PROPUESTA	19
2.1 Título del proyecto.	19

2.2 Objetivo del proyecto.	19
2.3 Descripción de la propuesta.	19
2.4 Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados	22
2.4.1 Modelado de celdas fotovoltaicas	22
2.4.2 Modelado de convertidor elevador (BC)	24
2.4.3. Uso de Redes Neuronales para control	25
2.4.4. Teorema de aproximación universal para redes neuronales artificiales	26
2.4.5 Arquitectura ANN de una capa oculta como aproximador universal	28
2.4.6 Algoritmo de optimización de error Levenberg–Marquardt	30
2.4.7 Obtención de datos para red neuronal	32
2.4.8 Parámetros del Panel Solar simulado	33
2.4.9 Algoritmo de seguimiento de Perturbación y Observación (P&O)	34
2.4.10 Algoritmo de seguimiento MPPT basado en redes neuronales	36
2.4.11 Metodología para selección de neuronas de las capas de la red neuronal	39
2.4.12 Diseño de simulación usando Matlab y Simulink	40
2.5 Conclusiones	44
CAPÍTULO III.	46
APLICACIÓN Y VALIDACIÓN DE LA PROPUESTA	46
3.1. Verificación de los valores de salida de Voltaje, Corriente y Potencia de sistema de generación usando paneles solares	56
3.2. Comparación de resultados entre MPTT neuronal y basado en algoritmo P&O	62
3.3. Análisis y Discusión de Resultados	64
3.4. Conclusiones del Capítulo III	70
CONCLUSIONES GENERALES	71
RECOMENDACIONES	72
Bibliografía	73

ÍNDICE DE FIGURAS

Figura 1: Modelo de una neurona artificial _____	12
Figura 2: Modelo Matemático de una Red Neuronal _____	13
Figura 3: Sistema SAPV autónomo con inversor MPPT _____	15
Figura 4: Diagrama de bloques de una ANN con controlador MPPT _____	16
Figura 5: Diagrama de configuración típica de un sistema fotovoltaico de 2 etapas _____	22
Figura 6: Circuito equivalente del sistema fotovoltaico _____	23
Figura 7: Curva característica P-V de un panel fotovoltaico _____	24
Figura 8: Explicación gráfica del teorema de aproximación universal _____	28
Figura 9: Arquitectura de una capa oculta de ANN como aproximador universal _____	29
Figura 10: API de Base de Datos POWER de la NASA _____	32
Figura 11: Diagrama de Flujo algoritmo P&O _____	35
Figura 12: Diagrama de Bloques de Simulación Propuesta _____	36
Figura 13: Diagrama de flujo control neuronal ANN _____	37
Figura 14: Ejecución de script de datos eléctricos de panel solar _____	40
Figura 15: Pseudocódigo creación conjunto datos de entrenamiento _____	41
Figura 16: Ejecución de script del convertidor BOOST _____	44
Figura 17: Diagrama de control neuronal MPTT _____	45
Figura 18: Arquitectura de la Red Neuronal para controlador MPPT _____	48
Figura 19: Gráfica de gradiente de error, parámetro μ y comprobación de validación tomado de software Matlab _____	51
Figura 20: Grafico MSE de entrenamiento, validación y prueba del entrenamiento de red neuronal _____	53
Figura 21: : Gráfica de histograma de error para 20 contenedores _____	54
Figura 22: Gráfico de regresión. a) Datos de Entrenamiento, b) Datos de Validación, c) Datos de Prueba, d) Modelo Ajustado _____	55
Figura 23: Potencia óptima según el nivel de irradiancia en kW/m ² _____	59
Figura 24: Perfil de Corriente del sistema de generación fotovoltaico para diferentes corrientes simuladas _	60
Figura 25: Perfil de Voltaje del sistema de generación fotovoltaico para diferentes corrientes simuladas ____	60
Figura 26: Perfil de Potencia del sistema de generación fotovoltaico para diferentes corrientes simuladas __	62
Figura 27: Comparación de Voltajes con carga variable con irradiancia variable; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O _____	62
Figura 28: Comparación de Corrientes con carga variable con irradiancia fija; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O _____	63
Figura 30: Comparación de Potencias carga variable con irradiancia variable; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O _____	64

Figura 29: Comparación de Potencias carga variable con irradiancia fija; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O _____ 65

ÍNDICE DE TABLAS

TABLA 1:	5
TABLA 2:	34
TABLA 3:	49
TABLA 4:	50
TABLA 5:	57
TABLA 6:	58

INTRODUCCIÓN

Antecedentes:

Muchos países ya están haciendo esfuerzos en la reducción de emisiones bajas de carbono y gases de efecto invernadero para lograr la neutralidad de carbono. El método que utiliza energía renovable es la política más importante para la neutralidad de carbono [1]. Entre las fuentes de energía renovable existentes, la fotovoltaica es un recurso prometedor que proporciona grandes cantidades de energía [2]–[4]. Además, el sistema de generación de energía PV (solar fotovoltaica) puede expandir fácilmente su capacidad y puede ser una alternativa a la contaminación ambiental. Además, se caracteriza por bajos costes de mantenimiento.

Sin embargo, la energía solar fotovoltaica enfrenta varios desafíos, incluidos los altos costos de instalación, la baja eficiencia y la generación de energía dependiente del clima [5]–[8]. Teniendo en cuenta las condiciones ambientales cambiantes, la eficiencia de los paneles solares está entre el 9% y el 17% [9]. Además, la dependencia climática de la energía solar hace que el sistema solar sea una fuente de energía inestable. Por lo tanto, una buena estrategia de control es esencial para garantizar el funcionamiento eficiente y seguro de los sistemas fotovoltaicos. Las curvas características Corriente – Voltaje (I-V) y Potencia – Voltaje (P-V) de un panel solar cambian de forma no lineal según la cantidad de radiación solar y la temperatura del módulo.

Un punto único en la curva P-V, llamado punto de máxima potencia (MPP), es donde se entrega la potencia óptima. Por lo tanto, se han propuesto diferentes algoritmos de seguimiento para el seguimiento del punto de máxima potencia (MPPT) en aplicaciones fotovoltaicas bajo diferentes condiciones de irradiación [10], [11]. Entre las tecnologías MPPT para la generación de energía fotovoltaica, la industria utiliza principalmente métodos de corriente de cortocircuito parcial, voltaje de circuito abierto parcial, perturbación y observación (P&O), escalada de colinas (HC) y conductancia incremental (IC) debido a su bajo costo [12], [13].

El funcionamiento general de un sistema fotovoltaico conectado a la red necesita una estrategia de control precisa para lograr lo siguiente:

- Una extracción de máxima potencia del campo fotovoltaico, mediante un módulo de control MPPT.
- El control de las corrientes inyectadas a la red o análogamente, en algunos casos, de la potencia activa y reactiva inyectada a la red.
- La regulación del voltaje del enlace de CC en el lado de entrada del inversor para rastrear el MPP.

Aunque el método MPPT básico se aplica ampliamente en la industria, no garantiza operaciones precisas bajo condiciones variables de insolación y sombra. Estos métodos tienen problemas importantes relacionados con bajas tasas de seguimiento y altas oscilaciones en estado estacionario. Por lo tanto, se han llevado a cabo investigaciones para superar las deficiencias de la tecnología existente mediante la aplicación de tecnología MPPT basada en computación suave (soft-computing). Los ejemplos típicos incluyen control de lógica difusa, control de modo deslizante, redes neuronales artificiales y algoritmos genéticos.

Estos métodos MPPT pueden superar las limitaciones de los algoritmos generales aplicando métodos computacionales y siguiendo el óptimo global. Sin embargo, la carga computacional y la complejidad de estos algoritmos computacionales son problemas inevitables [14]. Los investigadores han invertido esfuerzos en el desarrollo de algoritmos MPPT para mejorar la respuesta de los sistemas fotovoltaicos. Ghassami et al. en [15] informaron que se introdujo un algoritmo P&O MPPT mejorado para mejorar la eficiencia de seguimiento de los sistemas fotovoltaicos en condiciones de irradiación que cambian rápidamente. Sin embargo, las oscilaciones del sistema de estado estacionario exhiben respuestas de seguimiento lentas en los sistemas fotovoltaicos con oscilaciones altas.

Debido a la dependencia de los sistemas fotovoltaicos (PV) de las condiciones ambientales, su comportamiento es completamente no lineal. Por lo tanto, lograr el punto de máxima potencia en la curva no lineal de los sistemas fotovoltaicos enfrenta muchas dificultades. Aunque se recomiendan diferentes ideas para los controladores MPPT, el uso del controlador de Red Neuronal Artificial (ANN) es muy atractivo entre los investigadores debido a su alta respuesta dinámica y menos oscilaciones. Sin embargo, el mayor desafío para diseñar este tipo de controladores es obtener datos de entrenamiento precisos. La radiación y la

temperatura son dos variables de entrada importantes, mientras que el voltaje óptimo se considera para la salida en el método propuesto. Es por esta razón que este proyecto de investigación merece su investigación y simulación en el entorno ecuatoriano.

Planteamiento del problema:

El consumo de energía eléctrica se ha intensificado significativamente debido al masivo aumento de la población mundial. El uso y aplicación de las energías renovables resuelven una de las preocupaciones de la comunidad mundial. Porque el uso de combustibles fósiles ya no es suficiente, de todas las fuentes de energía renovable, la energía solar tiene el mejor futuro. A pesar de tener una fuente de energía limpia y renovable como lo es el sol, estos dispositivos presentan algunos inconvenientes con las variaciones de la radiación solar, los cambios en la temperatura y las condiciones ambientales. Cualquiera de los factores anteriormente mencionados, puede ocasionar que la corriente y la tensión de salida en un panel solar varíen continuamente, y a su vez la potencia entregada por el mismo. Finalmente, esto conlleva al mal funcionamiento del sistema ante una condición no deseada, por años se han utilizado baterías para mitigar este efecto, sin embargo, las baterías son componentes con alto valor que hacen que el costo de la energía producida aumente su valor [16].

Los paneles solares presentan un comportamiento no lineal en la curva potencia-tensión (P-V) la cual cambia para las diferentes condiciones de operación. En cada curva de irradiancia existe un punto de máxima potencia (MPP), el cual es el valor de transferencia máximo de potencia del panel solar para esa condición de operación. Esto quiere decir que el MPP tiene asociado valores de corriente y tensión diferentes para cada curva. El desplazamiento del MPP sobre estas curvas no lineales, hace que se requiera de algoritmos que permitan adaptarse ante las variaciones que se presentan continuamente y garanticen una respuesta adecuada de operación [17].

En este sentido, las redes neuronales artificiales (RNA) se presentan como una herramienta prometedora para el diseño e implementación de estrategias de control que permitan mantener las condiciones de operación deseadas a la salida del sistema. La utilización de RNA en la optimización de la eficiencia del sistema fotovoltaico puede reducir el costo de la energía producida al evitar la necesidad de baterías costosas para mitigar las variaciones en

las condiciones de operación. Por lo tanto, el objetivo de este trabajo es explorar las aplicaciones de las RNA en el diseño de algoritmos de control para maximizar la transferencia de potencia y garantizar un funcionamiento estable y eficiente del sistema solar fotovoltaico.

Formulación del problema

¿En qué medida favorece implementar un algoritmo de redes neuronales artificiales para obtener máxima potencia de paneles solares en condiciones medioambientales y atmosféricas cambiantes?

Objetivo General

- Diseñar y simular un sistema tracking basado en redes neuronales para mantener la máxima eficiencia de paneles solares.

Objetivos Específicos:

- Revisar el estado del arte referente de los parámetros principales que influyen en el sistema tracking para mantener la máxima eficiencia de paneles solares.
- Modelar y simular los componentes del sistema de fotovoltaico con el fin de estimar su desempeño dentro de controladores basados en redes neuronales que realicen el seguimiento del punto de máxima.
- Evaluar el desempeño del controlador diseñado mediante diferentes escenarios de simulación para verificar su funcionamiento y establecer su grado de aplicabilidad.

Sistemas de tareas en relación a los objetivos específicos:

TABLA 1:
TAREAS Y RESULTADOS DE ACUERDO A OBJETIVOS ESPECÍFICOS

OBJETIVOS ESPECIFICOS	ACTIVIDADES	RESULTADOS DE LAS ACTIVIDADES	MEDIOS DE VERIFICACIÓN
<p>Revisar el estado del arte referente de los parámetros principales que influyen en el sistema tracking para mantener la máxima eficiencia de paneles solares.</p>	<ul style="list-style-type: none"> • Búsqueda de información en medios físicos y digitales de la eficiencia energética. • Indagación en textos argumentativos u obras impresas dedicadas a estudio de eficiencia energética. 	<ul style="list-style-type: none"> • Fundamentación técnico- teórica para el desarrollo de la investigación. • Metodología para la determinación de sistema tracking 	<ul style="list-style-type: none"> • Fuentes bibliográficas. • Procedimiento sistemático. • Ecuaciones.
<p>Modelar y simular los componentes del sistema de fotovoltaico con el fin de estimar su desempeño dentro de controlador es basados en redes neuronales que realicen el seguimiento del punto de máxima.</p>	<ul style="list-style-type: none"> • Implementación del modelo de panel solar usando Matlab/Simulink • Elaboración del algoritmo de control basado en redes neuronales para seguimiento del punto de máxima potencia en un modelo 	<ul style="list-style-type: none"> • Modelo matemático del panel solar implementado en Matlab/Simulink • Algoritmo basado en redes neuronales para seguimiento del punto de máxima potencia implementado en Matlab/Simulink 	<ul style="list-style-type: none"> • Bloque de función con modelo matemático de panel solar • Bloque de función con el algoritmo de control implementado con redes neuronales para seguimiento del punto de máxima potencia.

<p>Evaluar el desempeño del controlador diseñado mediante diferentes escenarios de simulación para verificar su funcionamiento y establecer su grado de aplicabilidad</p>	<ul style="list-style-type: none"> Resultados experimentales. 	<ul style="list-style-type: none"> Datos de validación obtenidas a partir de simulación en diferentes casos de funcionamiento 	<ul style="list-style-type: none"> Prueba estadística de validación de hipótesis basados en datos obtenidos
---	--	--	--

Elaborado por o fuente: Autora

Justificación

El presente trabajo de investigación busca converger el conocimiento obtenido de los sistemas eléctricos de potencia y su aplicación en el uso de las energías renovables, las cuales buscan resolver una de las preocupaciones de la comunidad mundial porque el uso de combustibles fósiles ya no es suficiente. La energía fotovoltaica (PV), en particular, genera luz y electricidad a partir de la energía del sol, y se va expandiendo rápidamente debido a las políticas de apoyo de los gobiernos y la drástica reducción de su costo. La Organización para la cooperación y el desarrollo económicos (OCDE) estima que para el 2050, los sistemas fotovoltaicos podrían proporcionar alrededor del 12% de la producción mundial de electricidad y evitar la emisión de 2,3 Gigatoneladas de dióxido de carbono a la atmósfera cada año [18].

Este trabajo se basa en la necesidad de buscar soluciones eficientes y estables para el suministro de energía eléctrica en un mundo que se enfrenta a una creciente demanda de energía. El uso de energías renovables se presenta como una alternativa prometedora, y entre ellas, la energía solar es una de las más accesibles y abundantes. Sin embargo, los paneles solares presentan una serie de desafíos, como las variaciones en la radiación solar y las condiciones ambientales, que pueden afectar su eficiencia y potencia entregada.

La conversión de energía solar a energía eléctrica es muy limitada debido a que el punto en que operan los paneles solares no siempre coincide con el MPP. Las metodologías elaboradas

para realizar un MPPT son muy variadas, sin embargo, las redes neuronales ANN sobresalen por su capacidad predictiva con respecto a una gran cantidad de datos de entrada con comportamientos no lineales, por esta razón una de las grandes ramas utilizadas es la predicción del punto máximo de poder con respecto a entradas del historial del comportamiento climático en el transcurso de un periodo largo de tiempo [19]. Las RNA, como herramientas de aprendizaje automático, tienen el potencial de proporcionar soluciones eficientes y estables para el control de los sistemas solares fotovoltaicos en el MPP. El uso de RNA permite la adaptación a las variaciones en tiempo real, lo que garantiza un funcionamiento estable y eficiente del sistema, reduciendo así el costo de la energía producida y mejorando la fiabilidad del sistema.

Además, la implementación de estrategias de control en sistemas solares fotovoltaicos utilizando redes neuronales artificiales puede contribuir al desarrollo y la innovación en el campo de la energía renovable. Las RNA se presentan como una herramienta versátil y adaptable, que puede ser aplicada en diferentes contextos y para distintos tipos de sistemas solares fotovoltaicos, desde pequeñas instalaciones en hogares y empresas, hasta grandes plantas solares. La implementación de estrategias de control en sistemas solares fotovoltaicos utilizando RNA también puede mejorar la integración de estas fuentes de energía renovable en la red eléctrica, lo que podría reducir la dependencia de los combustibles fósiles y mitigar los efectos del cambio climático.

Las ANN se utilizan en los controladores MPPT para predecir la salida de voltaje (V) o potencia (P) en cualquier momento. El valor calculado se compara con los valores instantáneos obtenidos para determinar el ciclo de carga. Las variables independientes como la temperatura (T) y Irradiancia (G) serán las variables de entrada de la primera capa de la red. Además, otras variables como V e I del panel se puede incluir como entrada. Las capas ocultas serán las encargadas de procesar a ellos. El rendimiento final dependerá del número de neuronas en las capas ocultas, la función de activación elegida y el algoritmo de entrenamiento deseado. Para aumentar aún más la precisión de la ANN, se debe recopilar una buena cantidadde datos para su procesamiento.

En definitiva, la implementación de estrategias de control basadas en redes neuronales artificiales para sistemas solares fotovoltaicos puede ser una alternativa eficiente, estable y

escalable para el suministro de energía eléctrica en un mundo que se enfrenta a una creciente demanda de energía. Además, la utilización de RNA en el control de sistemas solares fotovoltaicos puede contribuir al desarrollo y la innovación en el campo de la energía renovable, así como mejorar la integración de estas fuentes de energía en la red eléctrica. Por lo tanto, el estudio y la implementación de estrategias de control utilizando RNA en sistemas solares fotovoltaicos es un tema relevante y de interés para el campo de la energía renovable y para la sociedad en general.

Hipótesis

Si se realiza un sistema tracking basado en redes neuronales, se podrá mantener la máxima eficiencia de paneles solares

CAPÍTULO I.

FUNDAMENTACIÓN TEORICA-METODOLOGICA

1.1. Antecedentes de la investigación o fundamentación del estado del arte.-

Según [20], existen dos etapas principales para los sistemas fotovoltaicos. Una es convertir la tensión DC generada a una de tipo AC para ser conectada a la red; la otra realizar el seguimiento del MPP para maximizar la energía capturada de acuerdo a las condiciones ambientales en la que se encuentren los módulos fotovoltaicos. El MPP es seguido por medio de un dispositivo MPP Tracker (MPPT) basado en diversas técnicas de control. Esto debe hacerse en un rango amplio con la mayor eficiencia posible debido a las variaciones de la radiación durante el día y a las condiciones ambientales.

Diferentes técnicas han sido previamente propuestas para localizar el MPPT en un sistema solar fotovoltaico. La investigación de [21] presenta un algoritmo MPPT que hace uso de redes resilientes con retropropagación (Rprop-NN) y supervisión para limitar el cortocircuito I (Isc). Este método predice el MPP instantáneamente midiendo T y G, lo que le permite moverse a su punto óptimo de funcionamiento sin oscilaciones. La simulación se llevó a cabo en Software PSCAD/EMTDC y probado contra los algoritmos P&O e Incremental (InC). bajo condiciones de sombreado parcial, el algoritmo funcionó bien.

En el trabajo [22] los autores proponen el uso de ANN recurrente con entradas exógenas (NARX) para el control MPPT de un sistema fotovoltaico. Dado que la salida real de este tipo de red es encontrada durante la fase de entrenamiento, se desarrolló una arquitectura paralela/serie para obtenerlo. Los resultados se simularon usando Matlab/Simulink con una capa oculta de diez neuronas con una función de transferencia tangente-sigmoidea y para la capa de salida la función lineal simple. En [23] se realizó la implementación del algoritmo en Arduino Mega. Los resultados muestran que el algoritmo ANN es más eficiente que el algoritmo P&O para evitar pérdidas de energía. Los autores mencionan que el algoritmo P&O

es bueno en condiciones de baja radiación porque puede cargar la batería, por lo que recomiendan el uso híbrido de ambos algoritmos.

En [24] los autores proponen un algoritmo ANN feedforward con una capa oculta y tres neuronas con G, T y V como entrada mientras que I es la salida. Para aumentar la eficiencia de la red, utilizaron datos que ya mostraban variaciones en T y G porque ANN no son buenos para extrapolar propiedades. Se usaron doscientos datos de prueba para entrenar a los ANN, y los resultados muestran un buen desempeño al momento de calcular el MPP. además, el experimento se repitió, pero ahora con 500 pares de datos de prueba, se obtuvieron mejores resultados. Esto demuestra que cuantos más datos entrene, mejor será la respuesta de nuestro sistema. Aunque los resultados no son sorprendentes, la baja complejidad lo hace adecuado para su implementación en microcontroladores. Se proporciona el pseudocódigo para el algoritmo.

Se puede observar en [25] que los autores desarrollaron un algoritmo MPPT utilizando ANN recursiva de alto orden (RHONN), además de incluir un filtro Kalman extendido para optimizar los pesos. Los resultados se simulaban en Matlab utilizando la caja de herramientas de Simscape. Cuando G es aplicado al sistema, se puede ver como el algoritmo empieza a converger rápidamente y encuentra el MPP, alcanzando un error del 7% del MPP teórico. Un MPPT de modo deslizante de tiempo discreto algoritmo de control fue propuesto para realizar una comparación de rendimiento, y el algoritmo muestra una convergencia más estable entre el error medio y la desviación estándar.

En [26], este artículo presenta un algoritmo ANN MPPT con escaneo para predecir Global MPP (GMPP). Compararon este nuevo enfoque con un P&O mejorado con escaneo global y un InC modificado con ciclo de trabajo difuso y un estimador de cambios (FLE). La simulación se realizó en Simulink y mostró un tiempo de respuesta más rápido, hasta tres veces más rápido.

El artículo [27] presentan dos algoritmos para el control de MPPT usando ANN, el primero usando pasos fijos (fixstep) y el segundo usando pasos variables (variable-step). Las simulaciones muestran que usando el algoritmo de paso variable. Se obtienen buenos resultados incluso cuando hay condiciones atmosféricas cambiantes, y se obtienen mejores

tiempos de respuesta, en comparación con el que utiliza fix-step, que obtuvo resultados muy similares a los obtenidos mediante un simple P&O.

En [28] se desarrolló un modo deslizante de súper torsión con algoritmo ANN para el seguimiento MPP. Mencionan que dado que PVS en condiciones cambiantes (T/G) se comporta como un sistema, se requiere un controlador no lineal para asegurar MPP. Una ANN con tres ocultos se usaron capas y se usaron datos de referencia de las curvas I-V del panel para entrenar. Las simulaciones se realizaron en Matlab/Simulink y se afirma un rendimiento del 97%.

Basados en la revisión de bibliografía podemos determinar que el problema de esta tesis planteado es factible y es una oportunidad para simular este tipo de controladores basados en inteligencia artificial pero orientado a las características de irradiancia de la zona central del Ecuador.

1.2. Fundamentación Teórica. -

1.2.1 Sistema de Redes Neuronales Artificiales

La red neuronal construye modelos matemáticos imitando el procesamiento de datos de la red neuronal biológica, el uso de una red neuronal puede simular los comportamientos del sistema, que son complicados y no fáciles de modelar, sin la premisa de modelos matemáticos precisos; un modelo matemático de red neuronal artificial típico se compone de varias neuronas, como ilustra la Figura 1. La relación entre la entrada y salida de la neurona se muestra en la Ecuación (1); es una salida obtenida al multiplicar la entrada por el peso y luego se convierte a través de una función de activación. El llamado entrenamiento de redes neuronales significa cumplir con el resultado esperado modificando pesos y sesgos.

Las principales características de la Red Neuronal son las siguientes [25]:

Fase de entrenamiento. - A partir de un conjunto de datos se determinan los pesos para definir el modelo de la red neuronal. Se crean interacciones que calculan estos pesos tomando en cuenta los valores de entrenamiento, intentando minimizar el error entre la salida del sistema y el de la red. Durante el entrenamiento, ANN generalmente genera valores de peso iniciales entre +1 y -1 al azar. La función de pesos es similar al efecto de la sinapsis; si los pesos son




Figura 1: Modelo de una neurona artificial

mayores, las neuronas conectadas se activarán fácilmente, entonces el impacto en la red se hace más evidente; por el contrario, habrá un menor impacto en la red neuronal cuando los pesos sean menores.

Fase de prueba.- Esta fase realiza una comparación entre los valores deseados y los valores actuales de la fase de aprendizaje, a modo de validación para controlar que en el proceso no exista un sobreajuste y se pierda la generalización por parte de la red.

Una ANN entrenada puede analizar la información que se ha proporcionado y entregar proyecciones y respuestas a problemas posteriores. ANN adopta un enfoque diferente para resolución de problemas que los algoritmos de predicción convencionales. Son como los cerebros de seres humanos, y se adaptan a situaciones que no tienen soluciones algorítmicas claras, siendo capaces de manejar datos imprecisos. Se utilizan en varias aplicaciones que tienen datos importantes, como robótica, procesamiento de señales, reconocimiento de patrones y aplicaciones financieras. Esta ventaja les permite sobresalir en algunas áreas que los métodos convencionales a menudo encuentran difícil.

Además, las ANN se consideran modelos computacionales viables que se pueden aplicar a una variedad de problemas complejos. ANN juega un papel crítico en la predicción, clasificación, predicción y control de sistemas complejos (CPM), problemas de regresión [29].

$$Y = \sum W_i X_i - b \quad (1)$$

El modelo matemático de una red neuronal se indica en la Ecuación (1), donde X , W y b son entradas, peso y sesgo (bias), \sum es la sumatoria total de la multiplicación de entradas y pesos




Figura 2: Modelo Matemático de una Red Neuronal

y f es función de activación, su objetivo es asignar el valor S a la salida correspondiente, Y es salida, los resultados esperados de los usuarios, debería estar en el rango de $[1, n]$, donde n es el tamaño de los datos de entrada, para entender el modelo matemático del modelo de red neuronal se observa en la figura siguiente.

1.2.2 Arquitectura ANN

El tipo de conexiones, patrones o estructuras que tiene ANN se llama arquitectura, para la organización de las neuronas que se pueden agrupar en estructuras llamadas capas. Una ANN es un conjunto de estas capas. Este estudio utiliza una red neuronal de retropropagación.

Se pueden distinguir tres capas para los modelos básicos: la capa de entrada, la capa oculta capa o capas y, finalmente, la capa de salida. La capa de entrada es donde se reciben los datos, y estos pueden ser sensores que captan señales del entorno. La capa de salida es la respuesta a todos los procesos sinápticos dentro de la red, y puede ser un efector en el caso de un sistema robótico. La capa oculta es la encargada de llevar a cabo los procesos (cálculos, correcciones) que representan el entorno a modelar. Gracias a su estructura podemos hablar de redes de una sola capa (SLNN), compuestas de una sola capa de neuronas, y redes multicapa (MLNN), compuestas por múltiples nodos en varias capas. MLNN dependiendo de su flujo de datos puede ser unidireccional, donde la información solo va en una dirección,

y las redes recurrentes (RNN), donde la información puede ir en cualquier dirección, incluso desde la salida capa a la capa de entrada [25].

El cálculo de los pesos ANN no es una tarea sencilla. En general, la única solución que existe es prueba y error. Sin embargo, para algunos casos particulares como el siguiente, hay algunas aproximaciones. El número de neuronas de salida está relacionado con los problemas.

1.2.3 Sistemas de energía solar fotovoltaica

La temperatura (T) o temperatura ambiente se refiere a la temperatura exterior, que es la temperatura del aire "*normal*". En PVS, puede referirse a la temperatura a la que puede funcionar la celda o matriz fotovoltaica. Como cualquier componente electrónico, el rendimiento del panel puede verse afectado cuando se calienta demasiado. Por lo tanto, temperaturas más altas o más cálidas siempre significan menos potencia de salida del sistema; esta pérdida se puede cuantificar como "*coeficiente de temperatura*" e indicada por el fabricante del panel fotovoltaico y varía de un modelo a otro [24].

El efecto fotovoltaico (PVE) es el proceso por el cual la luz se transforma en electricidad. La propiedad de algunos materiales logra el proceso de absorción de fotones y emisión de electrones. Cuando se absorbe la radiación solar, su energía se transfiere a un electrón. Con esta energía, el electrón puede salir del átomo en el que se encuentra y así formar parte de una corriente en un circuito eléctrico [30].

La radiación solar (SI) mide la cantidad de radiación solar que cae sobre una superficie determinada, se mide en W/m^2 . Por otro lado, la Irradiancia solar (G) mide la cantidad de energía solar que llega a una superficie en un período de tiempo determinado y se mide en $Wh/m^2/día$.

Las celdas fotovoltaicas (PVC) son dispositivos electrónicos que convierten la luz solar en corriente continua, que fluctúan según la intensidad de la luz solar. Los PVC están hechos de películas delgadas de materiales semiconductores, en los que los electrones de valencia están más unidos al núcleo, pero con una pequeña cantidad de energía, se comportan como conductores. Para uso práctico, se requiere la conversión a voltajes deseados específicos a

corriente alterna(CA) a través de inversores. Los PVC múltiples generalmente se conectan para formar módulos, que están conectados para formar matrices. Los arreglos están conectados al inversor, que es el que produce energía al voltaje deseado [5].

El inversor fotovoltaico (PVI) es el núcleo de la fotovoltaica y pertenece a un gran grupo de convertidores estáticos. Se encarga de transformar la corriente continua (DC), que proviene del panel fotovoltaico, en corriente alterna (AC) compatible con los requerimientos de la carga, la cual es utilizada por baterías o dispositivos electrónicos más conocidos. PVI generalmente se divide en dos tipos: inversores autónomos (SAPV) en la Figura 3, que no están conectados a la red eléctrica, e inversores (GCPV) que están conectados a la red pública. Sin embargo, la diferencia ya no es evidente en la actualidad porque los sistemas modernos pueden operar en ambos sentidos en los ahora llamados inversores híbridos.

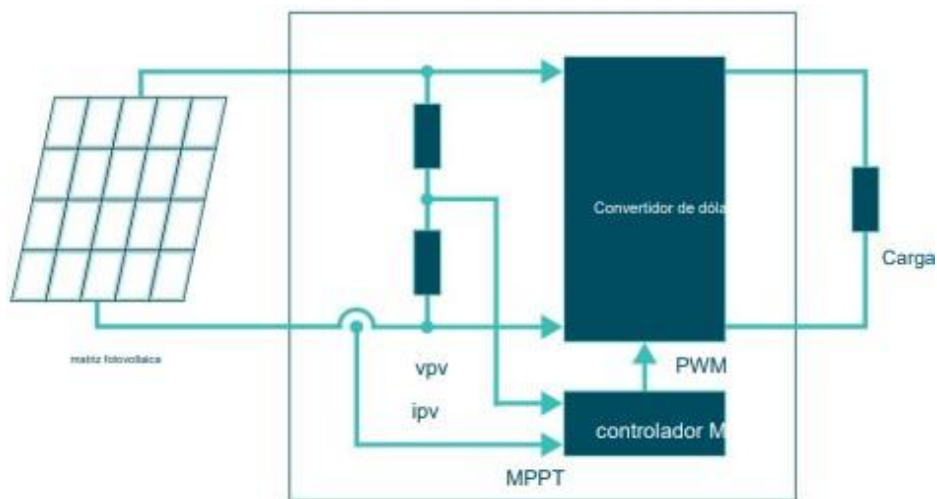


Figura 3: Sistema SAPV autónomo con inversor MPPT

1.2.4 Redes neuronales artificiales para el control de MPPT en sistemas fotovoltaicos

El control ANN MPPT ha sido ampliamente investigado en sistemas fotovoltaicos. ANN tiene la capacidad para realizar MPPT en condiciones atmosféricas uniformes y variables. Un diagrama general de su funcionamiento se muestra en la Figura 4.




Figura 4: Diagrama de bloques de una ANN con controlador MPPT

En el caso de los sistemas fotovoltaicos (SFV) es posible la optimización de etapas funcionales, en término de variables independientes, tal es el caso de la irradiancia, potencia recibida por unidad de superficie, y temperatura de los módulos, dando lugar a combinaciones de métodos de optimización . En esta área se ha detectado la necesidad de un modelo matemático que incorpore los parámetros del sistema, describa los componentes y su comportamiento, con el objetivo de definir el control dinámico aplicando coeficientes adaptativos, a partir de la identificación de correspondencia entre cada una de los subsistemas [7]

La importancia del método propuesto viene dada por una generalización estructural para reconfiguración inteligente y optimización dinámica de los coeficientes que inciden en las variables del modelo, a través de una ANN sobre FPGA, con arquitectura LFSR. Así como el diseño en hardware del método numérico de MPPT del SFV, a través de la sincronización entre las técnicas de optimización pasivas: interconexión del arreglo, concentración solar, que aumentan la eficiencia del panel FV, y técnicas activas: MPPT distribuido, inversores multinivel, reconfiguración dinámica (arreglo de relés), relocalización, recableado eléctrico, mediante la extrapolación de tecnología de hardware reconfigurable al sistema de potencia.

Adicional a técnicas innovadoras: arreglos ópticos configurables y modificación espectral de irradiancia (IR-mod) [10].

Comunmente, el sistema de seguimiento modifica la posición (de los ejes x,y) de los paneles del arreglo FV, a fin de obtener la mayor radiación solar incidente en su superficie. Sin embargo, este esquema incorpora un conjunto de motores y elementos móviles al arreglo que aumentan su complejidad y fallas probables del sistema. Por lo que se propone el estudio de alternativas, para mejorar las condiciones de irradiancia, a fin de extender el número de horas de sol pico (HSP), dejando fija la posición de los paneles de la estación terrena (disminuyendo el número de componentes), cuya función será el direccionamiento de la radiación solar, hacia el arreglo fotovoltaico distribuido. Todo esto sincronizado con el MPPT e incorporación de almacenamiento térmico y almacenamiento transitorio en ultra-condensadores (considerando el tiempo útil de baterías respecto a los paneles FV), recuperadores de calor regenerativo (RCR) en los paneles, para aumentar su eficiencia [20].

1.3. Fundamentación metodológica

El presente proyecto se basa en la investigación aplicada, debido a que se fundamenta en información y conocimientos con la finalidad de resolver un problema en específico. De esta manera para la elaboración del proyecto se utilizará las siguientes modalidades de investigación:

1.3.1 Investigación de campo

Se utilizará la investigación de campo partiendo del estudio de las horas de sol pico y el movimiento relativo de la fuente solar y desarrollar el controlador para maximizar la extracción de energía de los paneles solares considerando diferentes escenarios de simulación y poner a prueba la funcionalidad del controlador, mencionar el lugar en el que se realizará la investigación de campo.

1.3.2 Investigación bibliográfica

Se utilizará la investigación bibliográfica debido a que el proceso de recolección de información se llevará a cabo en diferentes bases de datos académicas de carácter nacional e internacional, adquiriendo de esta manera información relevante para la sustentación del tema propuesto en el presente proyecto, una vez recolectada la información se establecerá la

factibilidad que tiene el desarrollo de algoritmo seguidor del punto de máxima potencia (MPPT) basado en redes neuronales.

1.3.2 Investigación cuantitativa

Se utilizará este tipo de investigación debido a que se realizará una gran variedad de pruebas con la finalidad de desarrollar estrategias de control aplicado a sistemas fotovoltaicos de manera que precisen una extracción máxima de energía del panel solar al considerar condiciones atmosféricas variantes estableciéndose así las ventajas y desventajas de la aplicabilidad de un controlador basado en redes neuronales y establecer el porcentaje de reducción de los tiempos de carga de la batería.

1.4. Conclusiones

Aunque el neurocontrol no es nada nuevo, sigue teniendo un gran impacto en áreas de reciente auge como las energías renovables, con especial énfasis en los sistemas fotovoltaicos. Las simulaciones se realizaron utilizando la caja de herramientas Matlab/Simulink ANN.

Los controladores que utilizan ANN solo informaron una eficiencia promedio del 98%. Tienen la ventaja de tener un tiempo de convergencia muy rápido y son fáciles de implementar, y son muy efectivos en condiciones atmosféricas uniformes y variables. Su robustez proviene de que tan bien está entrenada la red, por lo que se necesitarán grandes cantidades de datos para la red. Si el sistema fotovoltaico falla por alguna razón, se puede entrenar con nuevos datos y seguir funcionando aceptablemente

CAPÍTULO II.

PROPUESTA

La energía renovable es una tecnología clave para lograr transiciones energéticas libres de carbono, y los sistemas de energía solar son uno de los recursos más confiables para lograrlo. Los sistemas de energía solar tienen una estructura simple y son económicos. Sin embargo, dependiendo de la irradiación de entrada, el algoritmo Seguimiento del Punto Máximo de Potencia (MPTT por sus siglas en inglés de Maximum Power Point Tracking) existente tiene desventajas debido a su respuesta transitoria lenta y vibración de estado estable. Por lo tanto, en este proyecto, se propone un algoritmo de control de salida máxima basado en un algoritmo de aprendizaje profundo que puede predecir la irradiancia de entrada. Este algoritmo de control permitirá optimizar el comportamiento del convertidor elevador DC-DC alimentado a una carga de corriente continua.

2.1 Título del proyecto.

Algoritmo MPTT optimizado basados en redes neuronales artificiales utilizando el pronóstico de irradiación y temperatura

2.2 Objetivo del proyecto.

Simular algoritmo MPTT optimizado basados en redes neuronales artificiales utilizando el pronóstico de irradiación y temperatura

2.3 Descripción de la propuesta.

Recientemente, una extensa investigación sobre algoritmos de aprendizaje profundo se centró en la excelente capacidad de aprendizaje de los datos históricos de interacción ambiental en lugar de los requisitos de los complejos modelos matemáticos de los sistemas

de control como en el método MPPT convencional [31], [32]. En el estudio de Kofinas et al. [33], determina que la inteligencia artificial es una herramienta potencial para resolver de manera óptima los problemas de control de MPPT debido a su menor tiempo de cálculo y mayor estabilidad de convergencia en comparación con los métodos metaheurísticos. En particular, la investigación que implementa el aprendizaje profundo para el control MPPT de los sistemas de conversión de energía solar se puede encontrar en [28], [34].

Sin embargo, este enfoque tiene la desventaja del recuento de datos. Kofinas et al. [33] utilizaron una combinación de 800 estados y 5 acciones para formar un espacio de acción estatal de 4000 acciones estatales, mientras que Hsu et al. [28] y Youssef [34] solo utilizaron cuatro estados. Como resultado, los sistemas con estados y espacios de trabajo grandes requerían períodos más largos para el cálculo. Además, se ha desarrollado un nuevo control MPPT basado en un algoritmo de aprendizaje profundo para sistemas fotovoltaicos en condiciones de sombra parcial [35] y se ha estudiado un enfoque de algoritmo de aprendizaje profundo para abordar el problema de seguimiento del punto de máxima potencia global [35], [36]. Sin embargo, en general, los principales inconvenientes de los métodos mencionados son que son cálculos rápidos y utilizan grandes cantidades de datos. En conclusión, el método propuesto en este artículo pudo implementar el algoritmo del modelo de aprendizaje profundo con un modelo aprendido simple.

La potencia de salida de la función MPPT de un sistema fotovoltaico puede controlarse mediante el convertidor elevador CC-CC (corriente continua-corriente continua) utilizando diferentes esquemas de control clásicos. Li et al. aplicó el esquema de control adaptativo de búsqueda de extremos (AESC) a un problema MPPT fotovoltaico, mientras que el modelo de espacio de estado se derivó a través de un método de promedio y la entrada de control fue la relación de trabajo del modulador de ancho de pulso del convertidor reductor CC-CC. La convergencia del sistema fotovoltaico estudiado a un entorno óptimo ajustable se confirmó mediante el uso de un método de control adaptativo basado en Lyapunov [37]. Farajdadian et al. diseñó un controlador de lógica difusa (FLC) para MPPT en un sistema fotovoltaico, mientras que las funciones de membresía difusa del controlador difuso se optimizaron utilizando el algoritmo firefly (FA) para generar el ciclo de trabajo adecuado [38]. Pervez et al. propuso un algoritmo de optimización novedoso basado en la exploración aleatoria del

espacio de búsqueda, conocido como algoritmo adaptativo jaya (Ajaya) [39]. Se incorporaron dos coeficientes adaptativos para MPPT con una tasa de convergencia rápida, menos fluctuaciones de potencia y alta estabilidad.

En este proyecto se propone un control MPTT basado en arquitecturas de redes neuronales de aprendizaje profundo que puede predecir la irradiancia de entrada. La generación de energía fotovoltaica se rige por dos factores principales: (i) el aumento de la irradiancia aumenta la cantidad de producción de energía y (ii) el aumento de la temperatura disminuye la cantidad de producción de energía. En consecuencia, la producción de energía fotovoltaica varía continuamente debido al cambio continuo en la cantidad de irradiación y al cambio continuo de temperatura a lo largo del día.

Para implementar este algoritmo se necesita un convertidor elevador DC-DC para controlar el ciclo de trabajo del IGBT en el convertidor. Un convertidor elevador es uno de los tipos más simples de convertidor de modo de conmutación. Este tipo de convertidor toma un voltaje de entrada y lo incrementa. El voltaje de salida del convertidor se ajusta de acuerdo al valor de voltaje deseado. El uso de este método garantizará que la resistencia del sistema fotovoltaico y la carga se igualen para lograr la mejor eficiencia.

El algoritmo basado en redes neuronales (ANN) es un controlador de red artificial no lineal que puede comportarse de manera similar al comportamiento de la red neuronal biológica humana. La relación entre la corriente y el voltaje en el campo fotovoltaico no es lineal, además los valores de irradiancia (G) y temperatura (T) están en continuo cambio, por lo que la necesidad de un controlador ANN para modelar las complejas relaciones no lineales entre las entradas y salidas del sistema fotovoltaico es esencial.

Este tipo de control basado en ANN logra una respuesta transitoria rápida y una estabilidad de estado estable. El modelo basado en ANN aplicado en este estudio se entrena en función de los resultados experimentales utilizando un panel fotovoltaico de 200 W, y el rendimiento del algoritmo propuesto se verificará comparando su rendimiento con el del algoritmo convencional de perturbación y observación (P&O) en diversas condiciones de irradiación de entrada.




Figura 5: Diagrama de configuración típica de un sistema fotovoltaico de 2 etapas

2.4 Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados

En esta sección se explicará detalladamente los métodos empleados para desarrollar la simulación de celdas fotovoltaicas y el convertidor aumentador (BC), para posteriormente explicar el proceso de simulación de redes neuronales y el proceso de entrenamiento.

2.4.1 Modelado de celdas fotovoltaicas

Las células fotovoltaicas son el componente principal de los sistemas de energía solar que los clientes pueden utilizar para convertir la energía solar en energía eléctrica. Las células solares se pueden combinar en paralelo y en serie para cambiar el voltaje de salida, la corriente y la clasificación del panel solar. Es decir, la potencia requerida por la carga se puede satisfacer configurando las celdas solares en serie y en paralelo.

La Figura 5 muestra la configuración de un sistema fotovoltaico típico. El sistema de energía solar consta de dos etapas. La celda solar emite un voltaje de DC que carga la batería a través de un convertidor de DC/DC, y el voltaje de la batería se conecta a la red a través de un inversor de AC. El modelo matemático del panel solar se puede representar mediante un modelo simplificado, y el modelo de circuito equivalente se muestra en la Figura 6.

La relación voltaje-corriente en un sistema fotovoltaico se puede describir de la siguiente manera de acuerdo con la Ecuación (2) y (3):

$$V_{PV} = \frac{A \cdot K \cdot T}{q} \ln \left(I_{ph} / I_{PV} + 1 \right)$$




Figura 6: Circuito equivalente del sistema fotovoltaico

$$I_{PV} = I_{ph} - I_{PVO} \left[\exp\left(\frac{q(V_{PV} + I_{PV}R_s)}{A \cdot K \cdot T}\right) - 1 \right] - \frac{V_{PV} + I_{PV}R_s}{R_{sh}} \quad (3)$$

Donde I_{PV} es la corriente de salida del panel o arreglo fotovoltaico, R_s y R_{sh} son las resistencias en serie y en derivación, respectivamente; I_{ph} es la fotocorriente de la celda fotovoltaica; A es el factor de idealidad p-n; I_{PVO} es la corriente de saturación inversa; K es la constante de Boltzmann ($1,38 \times 10^{-23}$ J/K); q es la carga electrónica (1.602×10^{-19} C); T es la temperatura de la celda (en Kelvin).

Para optimizar el factor de llenado, se maximiza la relación entre la fotocorriente y la corriente de saturación inversa mientras se minimizaba la resistencia en serie, R_s , y la resistencia de derivación máxima R_{sh} dentro de la celda fotovoltaica. Por lo tanto, se puede suponer que la resistencia en serie R_s está cerca de cero y la resistencia en derivación R_{sh} está cerca de infinito. Podemos simplificar (3) ignorando R_s y R_{sh} , como se muestra en la Ecuación (4)

$$I_{PV} = I_{ph} - I_{PVO} \left[\exp\left(\frac{q(V_{PV} + I_{PV}R_s)}{A \cdot K \cdot T}\right) - 1 \right] \quad (4)$$

Las características V-I típicas de un conjunto fotovoltaico de una celda solar se muestran en la Figura 7, muestra el rango de todos los voltajes aceptables frente a todas las corrientes aceptables y los cambios regidos por un rango de valores de G con una T constante. Observamos que a un voltaje máximo (V_m) la potencia es la máxima. Este es el punto de

máxima potencia de las características fotovoltaicas que necesitamos rastrear usando el controlador basado en ANN y el algoritmo MPPT




Figura 7: Curva característica P-V de un panel fotovoltaico

La Figura 7 muestra el cambio en el punto de máxima salida según el cambio en la irradiación. Es decir, el método propuesto puede calcular el voltaje de referencia de la generación de energía solar y obtener el punto de salida máxima a partir de la cantidad de irradiación basada en el valor previsto.

2.4.2 Modelado de convertidor elevador (BC)

El sistema de conversión de energía (DC-DC) es el vínculo que conecta la celda solar y el inversor de red. El sistema de conversión de energía (DC-DC) se utiliza para aumentar los voltajes de DC y para el funcionamiento óptimo de los paneles solares [30, p.]. Siendo la frecuencia del interruptor (ω) interpretado por los siguientes valor:

$$w = \begin{cases} 0 & \text{interruptor abierto} \\ 1 & \text{interruptor cerrado} \end{cases}$$

El modelo dinámico del convertidor de potencia (DC-DC) se puede expresar de la siguiente manera según se muestra en las Ecuaciones (5) y (6).

$$\frac{di_{dc}}{dt} = \frac{V_{PV} - V_o}{L} + \omega \frac{V_o}{L} \quad (5)$$

$$\frac{dV_o}{dt} = \frac{i_{dc}}{C_{out}} - \omega \frac{i_{dc}}{C_{out}} \quad (6)$$

Aquí, V_o es el voltaje de DC de salida DC-DC e i_{dc} es la corriente del inversor de la red. El voltaje de salida del convertidor de potencia (DC-DC) se puede expresar como una función del voltaje de entrada V_{pv} y la relación de trabajo del interruptor del convertidor (D). L representa un inductor de conversión de energía y C_{out} representa el capacitor del filtro de salida.

Según la referencia de generación de energía solar y los voltajes de salida, la relación D del convertidor DC-DC se puede calcular de la siguiente manera (Ver Ecuación 7):

$$D = 1 - \frac{V_{pv}}{V_o} \quad (7)$$

El método propuesto basado en la relación de trabajo calculada tiene la ventaja de poder seguir con precisión el punto de salida máxima, incluso si la cantidad de irradiación cambia, puede seguir rápidamente el punto de salida máxima. Puede mitigar las desventajas del método convencional ampliamente utilizado: ondulación de voltaje de estado estable y velocidades de seguimiento lentas de los transitorios.

Para convertir corriente DC en CA, se implementa un modulador de ancho de pulso (PWM) en la simulación. Este tipo de inversor se usa para generar voltajes de CA que tienen magnitudes variables y frecuencias variables. Este método está designado por pulsos de amplitud constante, donde el ancho del pulso se modula para adquirir el control del voltaje de salida.

2.4.3. Uso de Redes Neuronales para control

En los últimos años, en el caso de los sistemas computacionales, los enfoques de Redes Neuronales Artificiales (ANNs) se presentan como uno de los candidatos más importantes debido a los múltiples beneficios que brindan sobre los sistemas computacionales tradicionales.

Los controladores MPPT mejoran el rendimiento del sistema fotovoltaico. En este sentido, los nuevos controladores ANNs se han considerado apropiados en muchos trabajos porque pueden resolver problemas específicos complejos y mal definidos sin modelos matemáticos precisos mientras que los enfoques tradicionales no obtuvieron la precisión, eficiencia o velocidad adecuada [24], [40], [41].

ANN se conoce como un sistema de procesamiento de información. La red neuronal artificial se ha introducido como un enfoque importante para estimar un sistema no lineal, que se puede aproximar utilizando redes neuronales multicapa. Es importante tener en cuenta que estas redes multicapa muestran resultados más apropiados en comparación con otros enfoques [29], [42]. Aquí, con respecto al control del proceso MPPT, se aplica la red neuronal de avance. La red neuronal debe entrenarse de forma intermitente con respecto a los atributos de los paneles fotovoltaicos que se basan en el modelo matemático conocido de esos dispositivos, así como en los cambios climáticos.

2.4.4. Teorema de aproximación universal para redes neuronales artificiales

El teorema de aproximación universal es la base teórica de por qué funcionan las redes neuronales. En pocas palabras, establece que una red neuronal con una capa oculta que contiene un número suficiente pero finito de neuronas puede aproximarse a cualquier función continua con una precisión razonable, bajo ciertas condiciones para las funciones de activación (a saber, que deben ser de tipo sigmoide o RELU).

Formulado en 1989 por George Cybenko[43] solo para activaciones sigmoideas y probado por Kurt Hornik[44] en 1991 para aplicarse a todas las funciones de activación (la arquitectura de la red neuronal, no la elección de la función, fue el impulsor detrás del rendimiento), su descubrimiento fue lo que ha permitido que este tipo de arquitecturas sea usado en varias aplicaciones industriales.

Sin embargo, lo más importante es que el teorema es una explicación reveladora de por qué las redes neuronales parecen comportarse de manera tan inteligente. Comprenderlo es un paso clave para desarrollar una comprensión sólida y profunda de las redes neuronales.

Este teorema nos indica que cualquier función continua en un conjunto compacto (acotado, cerrado) se puede aproximar mediante una función por partes. Sin embargo, Cybenko fue más específico acerca de esta función por partes, ya que podría ser constante, consistiendo esencialmente en varios pasos ajustados a la función. Con suficientes regiones constantes ("pasos"), uno puede estimar razonablemente la función dentro de los límites en los que se da.

Sobre la base de esta aproximación, se podría construir una red delegando cada neurona en un "*paso*". Usando los pesos y sesgos como "*puertas*" para determinar qué entrada cae y, por lo tanto, qué neurona debe activarse, una red neuronal con un número suficiente de neuronas podría estimar una función simplemente dividiéndola en varias regiones constantes.

Para las entradas que caen en la sección delegada de una neurona, al aumentar el peso a valores enormes, el valor final se acerca a 1 (cuando se evalúa usando la función sigmoide). Si no cae en la sección, mover el peso hacia el infinito negativo producirá un resultado final cercano a 0. Usando la función sigmoidea como una especie de "procesador" para determinar el grado de presencia de una neurona, cualquier función se puede aproximar casi perfectamente, dada una abundancia de neuronas. En el espacio multidimensional, Cybenko generalizó esta idea, cada neurona "*controlando*" un hipercubo de espacio dentro de una función multidimensional.

El punto clave del teorema de aproximación universal es que, en lugar de crear relaciones matemáticas complejas entre la entrada y la salida, utiliza manipulaciones lineales simples para dividir la función complicada en muchas piezas pequeñas y menos complicadas, cada una de las cuales es tomada por una neurona (Ver Figura 8).

Desde la prueba inicial de Cybenko, se han compuesto muchos desarrollos adicionales, como probar el Teorema de Aproximación Universal para diferentes funciones de activación, como RELU, que es ilimitado (en un lado), o con varias arquitecturas (recurrente, convolucional, etc.).

Independientemente, todas estas exploraciones se centran en una idea: las redes neuronales encuentran fuerza en los números. Cada neurona vigila un patrón o área del espacio de características, cuyo tamaño está determinado por el número de neuronas en la red. Cuantas menos neuronas haya, más espacio necesitará cada una para vigilar y, por lo tanto, la




Figura 8: Explicación gráfica del teorema de aproximación universal

capacidad de aproximación disminuirá. Sin embargo, con más neuronas, independientemente de la función de activación, cualquier función puede ensamblarse con muchos fragmentos pequeños.

Del teorema de aproximación universal, entendemos que las redes neuronales son estimadores complejos ocultos bajo una apariencia de multidimensionalidad, lo que hace que su capacidad, que parecería ordinaria en dos o más tres dimensiones, parecen impresionantes. Por supuesto, el teorema de aproximación universal asume que el diseñador de la ANN puede agregar neuronas hasta el infinito, lo cual no es factible en la práctica. Además, tampoco es práctico jugar con todas las combinaciones casi infinitas de parámetros para que una red neuronal encuentre la que funciona mejor. Sin embargo, es cierto que el teorema también asume que *solo hay una capa oculta, y que a medida que se agregan más capas ocultas, el potencial de complejidad y, por lo tanto, la aproximación universal crece exponencialmente*: las neuronas de la segunda capa buscan patrones dentro de los patrones.

En cambio, depende de la intuición y la experiencia de los ingenieros de aprendizaje automático construir arquitecturas de redes neuronales que se adapten al problema dado, de modo que puedan aproximarse bien al espacio multidimensional, sabiendo que dicha red existe, pero también para equilibrar qué tan realista es la factura computacional es. El teorema les permite a los ingenieros de aprendizaje automático saber que siempre habrá una solución.

2.4.5 Arquitectura ANN de una capa oculta como aproximador universal

Hablando matemáticamente, cualquier arquitectura de red neuronal tiene como objetivo encontrar cualquier función matemática $y = f(x)$ que pueda asignar atributos (x) a la salida

(y). La precisión de esta función, es decir, el mapeo, difiere según la distribución del conjunto de datos y la arquitectura de la red empleada. La función $f(x)$ puede ser arbitrariamente compleja. El teorema de aproximación universal nos dice que las redes neuronales tienen una especie de universalidad, es decir, no importa qué sea $f(x)$, hay una red que puede acercarse aproximadamente al resultado. Este resultado es válido para cualquier número de entradas y salidas.

Al incluir una cantidad n de neuronas en una sola capa oculta, una red neuronal puede aproximar una entrada de x para cualquier función, $f(x)$. Esta función debe ser continua, si la función no es continua, una red neuronal de una sola capa oculta no se aproxima fácilmente ni con precisión a $f(x)$. En otras palabras, una sola red neuronal de capa oculta puede aproximar cualquier función continua de x con cualquier grado de precisión. Ver Figura 9.

Para evitar la memorización de la contaminación por ruido, error de medición, etc., y para mejorar la capacidad de predicción de datos ocultos, se debe utilizar la menor cantidad posible de capas ocultas en una red neuronal. Una razón para usar más de 1 capa oculta es cuando el entrenamiento se personaliza para un tipo especial de problema para el cual el

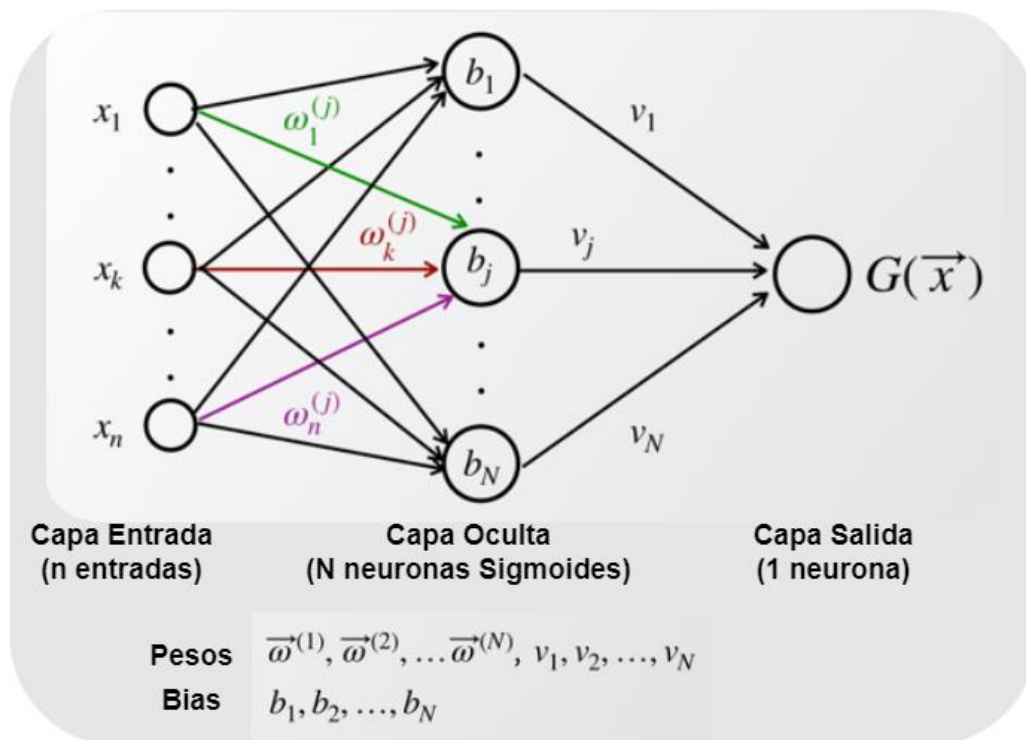


Figura 9: Arquitectura de una capa oculta de ANN como aproximador universal

papel de cada capa tiene un significado físico o matemático particular, para el problema que este proyecto soluciona no es necesario tener más de una capa oculta por la baja complejidad del proceso.

Para diseñar la arquitectura de capas de una red neuronal que puede ser del tipo (i) Capa Entrada – Capa Oculta- Capa Salida (I-H-O) o (ii) Capa Entrada – Capa Oculta 1- Capa Oculta 2 - Capa Salida (I-H1-H2-O) se debe observar que la cantidad de ecuaciones de entrenamiento sea mucho mayor que la cantidad de pesos desconocidos (incluidos los sesgos) a estimar. La metodología seguida para el diseño de la red neuronal es la siguiente:

El conjunto de datos debe subdividirse en datos de entrenamiento (N_{train}), datos de evaluación (N_{val}), y datos de prueba (N_{tst}), siendo el conjunto de mayor tamaño el de entrenamiento. El número de ecuaciones de entrenamiento se da por la Ecuación 8:

$$N_{eq} = N_{trn} \times O \quad (8)$$

Donde N_{eq} es el número de ecuaciones, N_{trn} el número de épocas de entrenamiento y O es el número de salidas del sistema. El número de neuronas que tiene la capa oculta (H) y un valor práctico para N_{trn} se da por ensayo y error.

En arquitectura con una capa oculta el número de pesos estimados de la capa (N_w) se da por la Ecuación 9.

$$N_w = (I + 1) * H + (H + 1) * O \quad (9)$$

Para mitigar el ruido de medición, es deseable tener un sistema sobredeterminado de acuerdo a $N_{eq} \gg N_w$ y adicionalmente se debe cumplir la siguiente Ecuación 10 para asegurar que la red converja rápidamente siempre y cuando se conozca o asuma el valor de N_{trn}

$$H \ll (N_{eq} - O)/(I + O + 1) \quad (10)$$

2.4.6 Algoritmo de optimización de error Levenberg–Marquardt

En matemáticas y computación, el algoritmo de Levenberg-Marquardt (LMA o LM), también conocido como el método de mínimos cuadrados amortiguados (DLS), se utiliza para resolver problemas de mínimos cuadrados no lineales. Estos problemas de minimización surgen especialmente en el ajuste de curvas de mínimos cuadrados.

LMA se usa en muchas aplicaciones de software para resolver problemas genéricos de ajuste de curvas. Sin embargo, como ocurre con muchos algoritmos de ajuste, el LMA solo encuentra un mínimo local, que no es necesariamente el mínimo global. El LMA interpola entre el algoritmo de Gauss-Newton (GNA) y el método de descenso de gradiente. El LMA es más robusto que el GNA, lo que significa que en muchos casos encuentra una solución incluso si comienza muy lejos del mínimo final.

Al igual que los métodos cuasi-Newton, el algoritmo de Levenberg-Marquardt se diseñó para aproximarse a la velocidad de entrenamiento de segundo orden sin tener que calcular la matriz hessiana. Cuando la función de rendimiento tiene la forma de una suma de cuadrados (como es típico en el entrenamiento de redes feedforward), entonces la matriz hessiana se puede aproximar como expresa la Ecuación 11:

$$H = J^T J \quad (11)$$

Donde J es la matriz Jacobiana que contiene la primera derivada de los errores de la red con respecto a los pesos y sesgos(bias). Dentro de este algoritmo el gradiente puede calcularse mediante la expresión 12:

$$g = J^T e \quad (12)$$

Siendo e el vector de errores de la red. La matriz jacobiana se puede calcular mediante una técnica estándar de retropropagación [45] que es mucho menos compleja que calcular la matriz hessiana. El algoritmo de Levenberg-Marquardt utiliza esta aproximación a la matriz de Hesse en la siguiente actualización tipo Newton (Ver Ecuación 13):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (13)$$

Cuando el escalar μ es cero, este es solo el método de Newton, usando la matriz hessiana aproximada. Cuando μ es grande, se convierte en un descenso de gradiente con un tamaño de paso pequeño. El método de Newton es más rápido y más preciso cerca de un mínimo de error, por lo que el objetivo es cambiar al método de Newton lo más rápido posible. Por lo tanto, μ disminuye después de cada paso exitoso (reducción en la función de rendimiento) y aumenta solo cuando un paso tentativo aumentaría la función de rendimiento. De esta forma, la función de rendimiento siempre se reduce en cada iteración del algoritmo. Este algoritmo

es el método más rápido para entrenar redes neuronales feedforward de tamaño moderado (hasta varios cientos de pesos)

2.4.7 Obtención de datos para red neuronal

Los modelos de pronóstico para la irradiancia solar se construyeron sobre datos de series temporales históricas. Estos datos se pueden obtener a través de estaciones terrestres o conjuntos de datos basados en satélites. Debido a la disponibilidad limitada de estaciones terrestres, los datos satelitales se utilizaron en este trabajo. La base de datos satelital usada es POWER Data Access Viewer (POWER DAV) desarrollado por la NASA [46], que es de acceso abierto con cobertura a largo plazo.




Figura 10: API de Base de Datos POWER de la NASA

Se recogen los datos por horas del día de la irradiancia [Kwhr/m^2] y la temperatura [$^{\circ}\text{C}$] durante todos los meses del 2021 para todos los tipos de superficie del cielo en la ciudad de Latacunga con una latitud de -0.93521 y longitud de -78.61554 (Ver Figura 10). El formato de recolección de datos es un archivo de datos separados por comas (.csv).

En cuanto a la irradiancia solar, los datos proporcionados por la base de datos generalmente están normalizados a la llamada "Irradiancia Extraterrestre" (ETR), que es la cantidad de energía solar que llegaría a la parte superior de la atmósfera de la Tierra si no hubiera ningún tipo de absorción o dispersión atmosférica. La irradiancia solar en la superficie de la Tierra

es menor que la irradiancia extraterrestre debido a la absorción y dispersión atmosférica, así como a otros factores, como la inclinación y la orientación del sol, la altitud y la cobertura de nubes.

En cuanto a la temperatura, los datos proporcionados por Power DAV están normalizados a valores medios o desviaciones estándar para permitir una mejor comparación y análisis. Esto puede ser útil para identificar patrones climáticos o tendencias a lo largo del tiempo.

El Sol experimenta ciclos solares que se repiten aproximadamente cada 11 años, durante los cuales su actividad aumenta y disminuye. Durante la fase alta del ciclo solar, la actividad solar es más intensa, lo que significa que hay más manchas solares y explosiones solares. Por el contrario, durante la fase baja del ciclo, la actividad solar es más tranquila, con menos manchas solares y explosiones.

En teoría, durante la fase baja del ciclo solar, la cantidad de radiación solar que llega a la Tierra debería ser menor en comparación con la fase alta. Esto se debe a que durante la fase alta, la actividad solar produce más radiación y energía que se irradia hacia la Tierra. Sin embargo, durante la fase baja, la actividad solar es más tenue, lo que resulta en una cantidad ligeramente reducida de radiación solar alcanzando nuestro planeta.

Es importante destacar que esta teoría asume que los datos de irradiancia solar no sufren una variación considerable en un período de 11 años. Esto significa que, si no hay otros factores importantes que influyan en la irradiancia solar, podemos esperar ver una correlación entre la actividad solar y la cantidad de radiación solar que llega a la Tierra durante el ciclo de 11 años.

2.4.8 Parámetros del Panel Solar simulado

El panel solar seleccionado es de la marca Soltech con el modelo 1STH-215-p, este tipo de panel es muy usado a nivel nacional. Se puede simular varios paneles solo cambiando sus características en programación. Se usa un solo panel con el objetivo de poder ser implementado el control a futuro. Las características eléctricas se indican en la Tabla 2.

TABLA 2:
ESPECIFICACIONES DEL PANEL SOLAR

Parámetros	Valores
Potencia Pico-Pico (P_{pk})	189.4 (W)
Voltaje en Circuito Abierto (V_{oc})	36.3 (V)
Voltaje en máxima potencia (V_{MPP})	29 (V)
Corriente en máxima potencia (I_{MPP})	7.35 (A)
Corriente en corto circuito (I_{sc})	7.84 (A)
Coefficiente de temperatura de I_{sc} (α)	0.102 (%/°C)
Coefficiente de temperatura de V_{oc} (β)	-0.36099(%/°C)

Los factores que afectan a la generación de voltaje-corriente de un panel solar son la temperatura de operación, pérdidas debido a la reflexión, suciedad en módulos, sombras, eficiencia de conversión, etc. Por cada grado de incremento de temperatura en el módulo la producción de energía decreta en un 0.5% aproximadamente. La temperatura nominal para determinar la potencia, voltaje y corriente son 25 °C con una irradiancia de 1000 W/m². Para calcular el Voltaje de máxima potencia basado en la temperatura del panel solar (V_{MPP_TCELL}) se usa la Ecuación 14:

$$V_{MPP_TCELL} = V_{MPP} + \beta_{V/oC} \times (T_{nom} - 25) \quad (14)$$

Siendo T_{nom} la temperatura nominal de ensayos a 25°C. El coeficiente de temperatura de V_{oc} (β) debe estar en unidades de Voltaje dividido para grados Centígrados (V/oC) para realizar el cálculo de este coeficiente actualizando las unidades de medida se tiene la Ecuación 15:

$$\beta_{V/oC} = V_{oc} \cdot \frac{\beta_{%/C}}{100} \quad (15)$$

Una vez obtenido β en (V/oC) se utiliza la Ecuación 14 para obtener el Voltaje en máxima potencia usando todos los valores de temperatura que se obtienen de la base de datos POWER, este vector de voltajes basados en el cambio de temperatura es usado como salida en el entrenamiento de la ANN.

2.4.9 Algoritmo de seguimiento de Perturbación y Observación (P&O)

Este método se usa comúnmente para extraer el Punto de Máxima Potencia (MPP) debido a su simplicidad. El P&O se ha introducido de acuerdo con la variación del voltaje de PV, así

como la variación en el ciclo de trabajo (D) del convertidor de DC-DC, y considerando las influencias en la potencia del panel de salida.




Figura 11: Diagrama de Flujo algoritmo P&O

En este algoritmo se utiliza este enfoque, se agrega una perturbación menor para permitir que cambie la potencia del módulo fotovoltaico. La potencia de salida fotovoltaica se mide y compara periódicamente. Este algoritmo hace que se altere el voltaje del módulo fotovoltaico o del conjunto. El voltaje se aumenta o se reduce para determinar si la potencia del módulo fotovoltaico ha aumentado o disminuido. Cuando un cambio en el voltaje provoca un cambio en la potencia, el punto de operación del módulo fotovoltaico está a la izquierda del MPP. Como resultado, se requiere una mayor perturbación a la derecha para alcanzar el MPP. Si un aumento en el voltaje reduce la potencia, el punto de operación del módulo fotovoltaico está a la derecha del MPP, lo que requiere una mayor perturbación a la izquierda para alcanzar

el MPP. El algoritmo P&O adoptado para el controlador de carga se muestra en la Figura 11 como un diagrama de flujo. Este algoritmo es usado como un mecanismo de comparación para observar las ventajas y desventajas del algoritmo ANN propuesto.

2.4.10 Algoritmo de seguimiento MPPT basado en redes neuronales

El sistema fotovoltaico debe aplicar el algoritmo MPPT para operar cerca de la potencia máxima, dependiendo de las entradas ambientales de Temperatura [T] e Irradiación [°G]. Entre los métodos MPPT del sistema fotovoltaico existentes, el método convencional tiene muchas ventajas, como la simplicidad de la implementación del control y la configuración simple; sin embargo, la ondulación del voltaje puede aumentar en el punto óptimo según el incremento del voltaje. También tiene la desventaja de que el seguimiento puede ser extremadamente lento durante los períodos transitorios.

Por lo tanto, en este estudio, aplicamos un algoritmo basado en redes neuronales como aproximador universal usando solo una capa oculta usando la arquitectura (I-H-I) para predecir el voltaje V_{MPP_TCELL} y, en función del error obtenido, calculamos directamente la relación de trabajo (D) del generador PWM. Como el punto de salida máxima cambia según




Figura 12: Diagrama de Bloques de Simulación Propuesta




Figura 13: Diagrama de flujo control neuronal ANN

la iluminancia del sistema de generación de energía solar y la temperatura del panel solar, siempre es posible calcular rápidamente la relación de trabajo para seguir el punto de salida máxima prediciendo el voltaje óptimo del sistema. La Figura 12 muestra el esquema de la simulación usando bloques.

Este algoritmo hace que se altere el voltaje DC del convertidor elevador (Boost Converter) basado en el V_{MPP} del panel solar. El voltaje se aumenta o se reduce de acuerdo a la irradiancia del sistema y a la temperatura del panel solar. El algoritmo inicia midiendo el

voltaje (V_{PV}) y corriente (I_{PV}) del panel solar. Usando ANN se predice el V_{MPP_TCELL} , se calcula el error de voltaje siendo la diferencia entre el V_{PV} y V_{MPP_TCELL} . Una vez que la red neuronal ha realizado la predicción del valor V_{MPP_TCELL} , se calcula el error de voltaje restando el valor medido V_{PV} del valor predicho V_{MPP_TCELL} . Si el error es cero, significa que el panel solar está operando en el punto de máxima potencia, por lo que no es necesario realizar ajustes en el ciclo de trabajo del PWM y se mantiene constante.

En caso de que el error sea diferente de cero, se necesita un mecanismo para ajustar el ciclo de trabajo del PWM y acercar el voltaje del panel al punto de máxima potencia. Para esto, se implementa un control que actúa en función del error. El proceso de predicción del VMPP, cálculo del error y ajuste del voltaje se repite continuamente en un ciclo para mantener el panel solar en el punto de máxima potencia a medida que las condiciones de irradiancia y temperatura cambian.

Si el error de voltaje es mayor que cero, significa que el voltaje del panel está por debajo del punto de máxima potencia, y es necesario aumentarlo para acercarlo al VMPP. En este caso, se utiliza una acción integral que acumula los errores de voltaje a lo largo del tiempo y realiza una corrección acumulativa para eliminar el error en estado estacionario. El nuevo ciclo de trabajo del PWM (modulación por ancho de pulso) se calcula sumando el ciclo de trabajo anterior con la integral del error.

Por otro lado, si el error de voltaje es menor que cero, indica que el voltaje del panel está por encima del punto de máxima potencia, y es necesario reducirlo para acercarlo al VMPP. En este caso, se utiliza una acción proporcional que ajusta el ciclo de trabajo del PWM de acuerdo con el error. El nuevo ciclo de trabajo se calcula como 1 menos el valor de tensión del punto de máxima potencia (V_{MPP_TCELL}) dividido por el voltaje de salida nominal del panel solar. Es importante mencionar que la eficacia del control basado en redes neuronales para MPPT depende de la precisión de la red neuronal en la predicción del VMPP y del algoritmo de control utilizado para ajustar el voltaje del panel. Este algoritmo se aprecia en la Figura 13.

Los datos de irradiancia y temperatura se encuentran dentro de un rango conocido y ya están en escalas comparables, la normalización no necesaria en este caso específico. La normalización puede ayudar a reducir el impacto de valores atípicos o extremadamente

grandes en el rendimiento del modelo, ya que estos valores se "escalan" para ajustarse al mismo rango que las demás características. En este caso específico no es necesario ya que al ser una predicción simple para la red neuronal su tiempo de convergencia es rápido.

2.4.11 Metodología para selección de neuronas de las capas de la red neuronal

La selección del número de neuronas en una capa oculta de una red neuronal es una tarea importante y puede influir en el rendimiento y la capacidad de generalización del modelo. A continuación, se presenta una metodología general para seleccionar el número de neuronas en una capa oculta.

La metodología usada empieza con un número conservador de neuronas, para comenzar, es recomendable usar un número conservador de neuronas en la capa oculta, como, por ejemplo, 5 o 10 neuronas. Esto ayudará a evitar el sobreajuste inicial y permitirá una exploración más segura de la topología de la red. Se entrena y evalúa el modelo, es decir el entrenar la red neuronal con el número conservador de neuronas en la capa oculta utilizando un conjunto de entrenamiento y evaluarla en un conjunto de validación o prueba. Observar el rendimiento del modelo, incluyendo la precisión y el error en las predicciones.

El siguiente paso es aumentar gradualmente el número de neuronas. Si el rendimiento del modelo no es suficiente, considera aumentar gradualmente el número de neuronas en la capa oculta. Agrega una cantidad razonable de neuronas adicionales, como 5 o 10 más. Se debe evaluar el nuevo modelo, es decir, se vuelve a entrenar el modelo con el nuevo número de neuronas en la capa oculta y evalúa su rendimiento en el conjunto de validación o prueba y se compara los resultados con el modelo anterior.

Si el rendimiento mejora, se continúa aumentando gradualmente el número de neuronas y evaluando el modelo en cada paso. Siempre se debe tener en cuenta que agregar más neuronas aumentará la complejidad del modelo y puede aumentar el riesgo de sobreajuste. Finalmente, se debe detenerse en el punto óptimo, esto es, continuar aumentando el número de neuronas hasta que se observe que el rendimiento en el conjunto de validación o prueba deja de mejorar o incluso empeora. En ese punto, se ha llegado al número óptimo de neuronas para la capa oculta.

Es importante recordar que la selección del número de neuronas puede variar según la complejidad y la naturaleza del problema en particular. Es posible que algunos problemas requieran más neuronas para capturar patrones complejos, mientras que otros se beneficiarán de una estructura más simple.

2.4.12 Diseño de simulación usando Matlab y Simulink

Para iniciar el diseño de la simulación se define las variables que son utilizadas en un modelo de paneles solares. Las variables $I_{SCS} = 7.84$ [A], $I_{MPS} = 7.35$ [A], $V_{OCS} = 36.3$ [V] y $V_{MPS} = 29$ [V] son valores nominales del panel, es decir, la corriente y voltaje de cortocircuito, corriente y voltaje máximo de potencia, voltaje y corriente de circuito abierto, y la máxima tensión del panel, respectivamente.

Las variables $\text{Alpha} = 0.102$ [$A/^{\circ}C$] y $\text{Beta} = -0.36099$ [$V/^{\circ}C$] son coeficientes de temperatura que se utilizan para ajustar las características eléctricas del panel según la temperatura ambiente. La variable $G_s = 1000$ [W/m^2] representa la irradiancia estándar que se utiliza para especificar la potencia nominal del panel y $T_s = 25$ $^{\circ}C$ es la temperatura estándar de referencia. Ver Figura 14.




Figura 14: Ejecución de script de datos eléctricos de panel solar

En esta primera parte del código se establece las características eléctricas nominales del panel solar y los coeficientes de temperatura necesarios para ajustar estas características según las condiciones ambientales en las que el panel se encuentra operando. Estas variables se

utilizarán posteriormente en el modelo para calcular la corriente, el voltaje y la potencia de

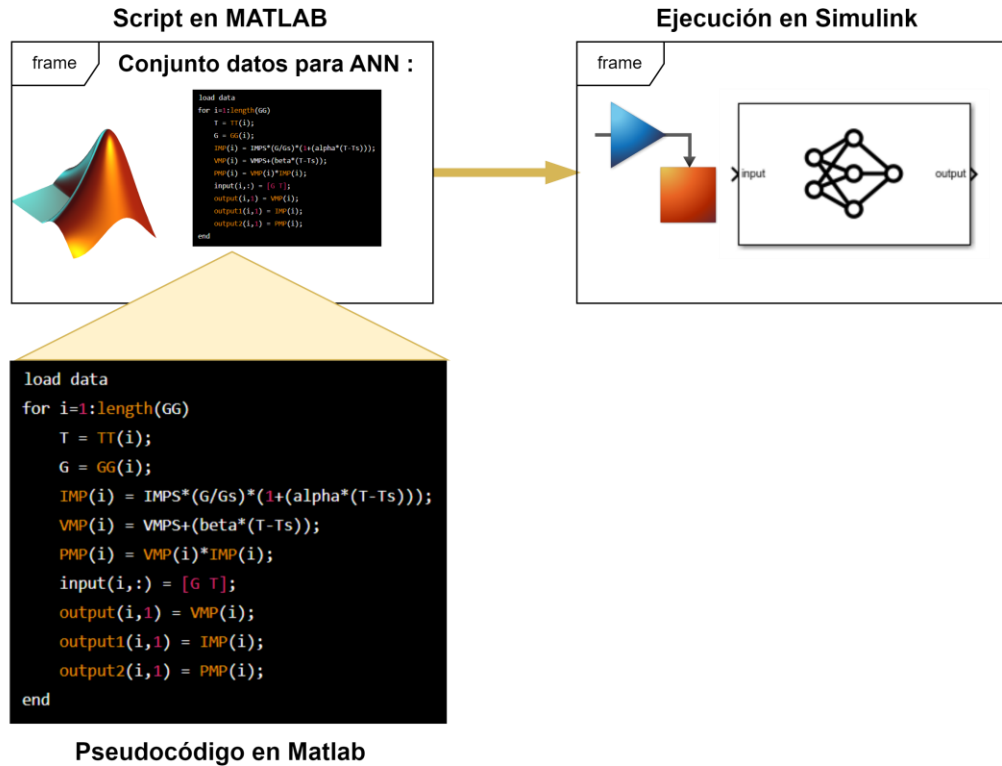


Figura 15: Pseudocódigo creación conjunto datos de entrenamiento

salida del panel en función de la irradiancia y la temperatura.

Los datos obtenidos de temperatura e irradiancia obtenidos de la base de datos POWER se ingresan en formato de vectores a una variable global llamada data. Se ejecuta un bucle for para cada valor en el vector de irradiación (GG) y temperatura (TT). En cada iteración, se calculan la corriente máxima, el voltaje máximo y la potencia máxima del panel solar para la irradiación y la temperatura dadas. Luego, se almacenan estos valores en los vectores IMP, VMP y PMP, respectivamente. También se almacenan la irradiación y la temperatura en la matriz de entrada (input) y los valores de voltaje, corriente y potencia en las matrices de salida (output, output1 y output2). Ver Figura 15.

La salida "output" contiene la máxima tensión de punto de máxima potencia (VMP) para cada valor de irradiancia y temperatura en el conjunto de datos. Esta salida, junto con las entradas de irradiancia y temperatura correspondientes, se pueden utilizar como conjunto de

datos de entrada y salida para entrenar una red neuronal para el control del punto de máxima potencia (MPPT).

En el entrenamiento de la red neuronal, la irradiancia y la temperatura se utilizan como entradas para la red neuronal, mientras que la máxima tensión de punto de máxima potencia (VMP) se utiliza como la salida deseada. La red neuronal ajusta sus pesos y sesgos internos durante el entrenamiento para producir una salida que se acerque lo más posible a la salida deseada.

Una vez que se ha entrenado la red neuronal, se puede utilizar para controlar el punto de máxima potencia (MPPT) de un panel solar en tiempo real utilizando medidas de irradiancia y temperatura en tiempo real como entradas. La red neuronal producirá una salida correspondiente a la tensión de punto de máxima potencia (VMP) deseada para maximizar la potencia entregada por el panel solar.

La elección de los parámetros del sistema es crítica para obtener un buen funcionamiento del convertidor BOOST. En este caso, se utilizaron parámetros tales como la potencia de salida, el voltaje de entrada y salida, la frecuencia de conmutación, el cambio máximo permitido en el voltaje y la corriente del inductor y el capacitor, y la resistencia de carga. Estos parámetros están interrelacionados y deben ser cuidadosamente seleccionados para asegurar que el convertidor funcione de manera eficiente y estable. La simulación permite ajustar estos parámetros y evaluar su impacto en el comportamiento del sistema, lo que es crítico para obtener un buen diseño. Los parámetros son:

- $P = 213.15$ [W]: Este parámetro representa la potencia de salida deseada del convertidor BOOST. Es importante tener en cuenta la potencia requerida para la carga para seleccionar adecuadamente los componentes del convertidor.
- $V_{in} = 29$ [V]: Representa el voltaje de entrada del convertidor BOOST. Es el voltaje dado por el panel solar que se utilizará para el sistema.
- $f_s = 10e3$ [Hz]: Es la frecuencia de conmutación del convertidor BOOST. La frecuencia de conmutación afecta directamente a la eficiencia del sistema y al tamaño de los componentes del circuito.
- $V_{out} = 58$ [V]: Representa el voltaje de salida deseado del convertidor BOOST. En este caso, se ha elegido un voltaje de salida dos veces mayor que el voltaje de entrada.

- $I_{outmax} = P/V_{out}$: Calcula la corriente máxima de salida del convertidor BOOST. Se calcula dividiendo la potencia de salida entre el voltaje de salida.
- $delIL = 0.01 \times I_{outmax} \times (V_{out}/V_{in})$: Muestra el cambio máximo permitido en la corriente de inductor del convertidor BOOST. Este parámetro se utiliza para seleccionar el valor adecuado del inductor.
- $delvout = 0.01 \times V_{out}$: Sirve para calcular el cambio máximo permitido en el voltaje de salida del convertidor BOOST. Se utiliza para seleccionar el valor adecuado del capacitor.
- $L = \frac{(V_{in} \times (V_{out} - V_{in}))}{(delIL \times fs \times V_{out})}$: Este parámetro representa el valor del inductor necesario para el convertidor BOOST. Se selecciona teniendo en cuenta los parámetros anteriores y la frecuencia de conmutación.
- $C = \frac{(I_{outmax} \times (1 - (V_{in}/V_{out})))}{(fs \times delvout)}$: Representa el valor del capacitor necesario para el convertidor BOOST. Se selecciona teniendo en cuenta los parámetros anteriores y la frecuencia de conmutación.
- $R = \frac{V_{out}}{I_{outmax}}$: Representa el valor de la resistencia de carga del convertidor BOOST. Se calcula dividiendo el voltaje de salida entre la corriente máxima de salida.

El script del convertidor permite modificar el valor de la frecuencia de conmutación para ver cómo afecta a la respuesta del sistema. Esto permite realizar ajustes y mejoras en el diseño antes de implementarlo en la simulación en Simulink. Ver Figura 16.

El modelo del sistema fotovoltaico que se muestra en la Figura 17 se implementó en Matlab/Simulink. Para evaluar el rendimiento del algoritmo MPPT propuesto, se simuló sistemas fotovoltaicos bajo varios perfiles de irradiancia solar (p. ej., rampas, ondas sinusoidales y perfiles de irradiancia diaria), asumiendo una temperatura ambiente fija de 25 C. Se realizó una comparación con el algoritmo convencional existente de P&O para resaltar las ventajas de la estrategia MPPT propuesta. El método MPPT existente utiliza incrementos de voltaje para alcanzar el punto de salida máximo. Dado que existen ventajas y desventajas según el tamaño del incremento de voltaje, en este documento se aplican el incremento de voltaje que cambia mucho y el incremento de voltaje que tiene cambios mínimos. El

algoritmo existente aplica un algoritmo de paso grande con un incremento de voltaje grande

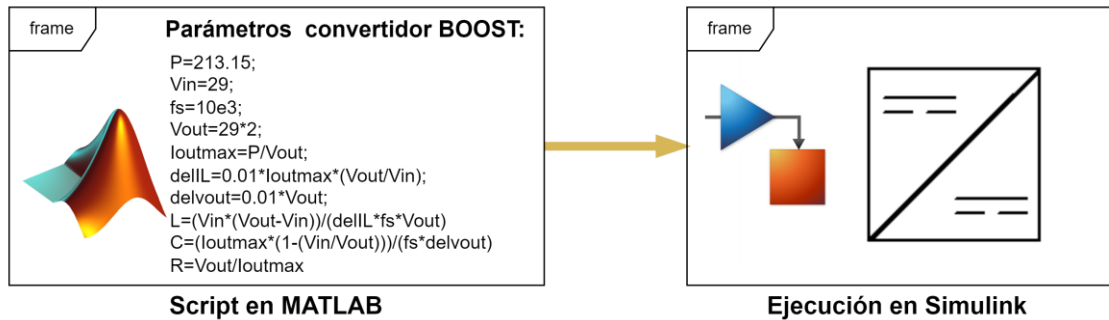


Figura 16: Ejecución de script del convertidor BOOST

y un algoritmo de paso corto con un incremento de voltaje pequeño. En general, el algoritmo de control de potencia máxima basado en aprendizaje profundo propuesto muestra una eficiencia MPPT y un rendimiento dinámico mejorados en comparación con los algoritmos existentes.

2.5 Conclusiones

Aunque el neurocontrol no es nada nuevo, continúa teniendo un impacto poderoso en áreas recientemente en auge, como las energías renovables, con un énfasis particular en los sistemas fotovoltaicos.

Los controladores que utilizan ANN tienen una eficiencia promedio del 98%. Tienen la ventaja de tener un tiempo de convergencia muy rápido y son fáciles de implementar, y son muy efectivos en condiciones atmosféricas uniformes y variables. Su robustez proviene de qué tan bien está entrenada la red, por lo que se necesitarán grandes cantidades de datos para la red. Si el sistema fotovoltaico falla por alguna razón, se puede entrenar con nuevos datos y seguir funcionando aceptablemente. Podría haber complicaciones al usar paneles fotovoltaicos de diferentes marcas combinados al momento de entrenar la red.




Figura 17: Diagrama de control neuronal MPPT

CAPÍTULO III.

APLICACIÓN Y VALIDACIÓN DE LA PROPUESTA

Para sistemas no lineales, las redes neuronales aplicados a controladores MPPT ofrece la mejor respuesta. En este sentido, la red neuronal está basado en el algoritmo de retropropagación. El modelo de red neuronal utilizado en controladores MPPT se basa en el algoritmo de retropropagación, el cual permite entrenar la red para inferir los valores de corriente y voltaje del panel solar en función de los cambios en las condiciones ambientales. Es importante destacar que este modelo de red neuronal se considera una caja negra, ya que no requiere información completa sobre el marco no lineal del sistema, sino que se enfoca en inferir los valores necesarios para realizar el seguimiento del punto de máxima potencia.

En la construcción inicial de la Red Neuronal Artificial (ANN), se decidió utilizar 10 neuronas en la capa oculta (H). El cálculo del número de pesos (Nw) necesario para esta ANN se realizó mediante la Ecuación 9, donde la capa de entrada (I) tiene 2 neuronas. Al reemplazar estos valores en la ecuación, se obtuvo un resultado de $Nw = 41$.

Para el proceso de entrenamiento de la red, se eligió un valor de $Ntrn$ igual a 1000 épocas de entrenamiento. Este valor es ampliamente utilizado en el entrenamiento de redes neuronales, especialmente en casos donde se busca que la ANN funcione como un aproximador universal, es decir, que pueda adaptarse a diferentes tipos de problemas y funciones.

Sin embargo, durante el proceso de entrenamiento y evaluación, se encontró que la precisión de la ANN no era suficiente para las necesidades específicas del problema. Por lo tanto, se siguió la metodología propuesta en el punto 2.4.11 para mejorar la precisión del modelo. Luego de experimentar con diferentes configuraciones de la red, se llegó a la conclusión de que aumentar el número de neuronas en la capa oculta a 20 resultó en una mejora significativa en la precisión de las predicciones.

El incremento en el número de neuronas permitió que la ANN capturara patrones más complejos y sutiles presentes en los datos, lo que se tradujo en una capacidad de

generalización más efectiva y una mayor precisión en las predicciones del valor de tensión del punto de máxima potencia (V_{MPP_TCELL}) del panel solar.

Se calcula el número de ecuaciones de entrenamiento basado en la ecuación 8, dando como resultado número de ecuaciones de entrenamiento se da por la Ecuación 8:

$$N_{eq} = 4344 (\text{datos de entrenamiento}) * 1 (\text{neuronas capa salida}) = 4344$$

Se calcula el número de pesos estimados de la capa (N_w) dado en la Ecuación 9. Se tiene como resultado

$$N_w = (2 + 1) * 20 + (20 + 1) * 1 = 81$$

Comparando los valores podemos inferir que $N_{eq} \gg N_w$ validando la arquitectura seleccionada de capa de entrada – capa oculta – capa de salida (I-H-O). Al aumentar el número de neuronas en la capa oculta a 20, se buscó mejorar la capacidad de la red para aprender y representar de manera más precisa la relación entre las variables de entrada (irradiancia y temperatura) y el valor objetivo (V_{MPP_TCELL}). Este ajuste permitió obtener una ANN con una precisión óptima para el problema específico del MPPT de paneles solares.

En este estudio, se utilizó una arquitectura de red neuronal para el controlador MPPT que consta de una capa de entrada, una capa oculta con 20 neuronas y activación sigmoide, y una capa de salida con activación del tipo ReLU (Rectified Linear Unit), a través de las cuales se genera la relación de trabajo. Los datos externos se reciben en forma de irradiancia en la región de entrada.

La función de activación sigmoide se utiliza comúnmente en redes neuronales debido a su capacidad para mapear los valores de entrada en un rango de 0 a 1. Esta función es especialmente útil en la capa de entrada y oculta de la red neuronal, ya que permite la normalización de los datos de entrada, lo que facilita el proceso de entrenamiento y mejora la precisión de la red.

En cuanto a la función de activación ReLU, se utiliza comúnmente en la capa de salida de las redes neuronales debido a su capacidad para generar valores no negativos y ser computacionalmente eficiente. Esta función es especialmente útil en aplicaciones de control en las que se requiere una salida no negativa, como en el caso de la MPPT para paneles solares. La utilización de funciones de activación sigmoide en las capas de entrada y oculta,

y ReLU en la capa de salida, permite una mayor eficiencia y precisión en el proceso de entrenamiento de la red neuronal. Estas funciones de activación también permiten una mejor escalabilidad y capacidad de generalización en aplicaciones de control, lo que se traduce en un mejor desempeño y resultados más precisos. Esta técnica se muestra en la figura 8




Figura 18: Arquitectura de la Red Neuronal para controlador MPPT

Para entrenar esta red neuronal se utilizaron 3040 datos, lo que equivale al 70% del conjunto total de datos. Además, se usaron 652 datos distintos para su validación y otros 652 datos diferentes para la prueba. Estos últimos representan el 15% del conjunto total de datos. El objetivo de este enfoque fue evitar que la red neuronal simplemente memorizara los datos y, en su lugar, aprendiera a inferir y generalizar los resultados. De esta manera, se pudo romper la linealidad del sistema y garantizar que la red neuronal tuviera una capacidad de inferencia efectiva para aplicaciones del mundo real.

El error cuadrático medio (MSE) y la regresión del modelo neuronal se muestran en la Tabla 1. El error cuadrático medio (MSE, por sus siglas en inglés) es una medida de la calidad del ajuste de una red neuronal a los datos de entrenamiento. El MSE se calcula como la media

de los cuadrados de las diferencias entre los valores reales y los valores predichos por la red neuronal para cada punto de datos. Un MSE bajo indica que la red neuronal ha ajustado bien los datos de entrenamiento y puede generalizar de manera efectiva a datos no vistos.

El parámetro R (regresión) es una medida de la bondad del ajuste de una red neuronal a los datos de entrenamiento. El valor de R varía entre -1 y 1, donde un valor cercano a 1 indica un ajuste muy bueno y un valor cercano a -1 indica un ajuste muy pobre. El valor de R también indica la correlación entre los valores reales y los valores predichos por la red neuronal. Un valor de R alto indica una correlación fuerte y, por lo tanto, una mayor confianza en la capacidad de la red neuronal para generalizar a datos no vistos. El MSE muestra el vínculo entre los resultados y los objetivos, mientras que la regresión revela la diferencia cuadrática promedio entre los resultados y los objetivos. Una asociación cercana está representada por un valor de regresión de uno, mientras que una relación aleatoria está representada por un valor de regresión de “0”. Ver TABLA 3.

TABLA 3:
PROCESO DE MSE Y REGRESIÓN PARA ENTRENAMIENTO, VALIDACIÓN Y TESTEO.

Procedimiento	Nro. de Muestras	MSE	Regresión
Entrenamiento	3040	1.1308e-09	1
Validación	652	1.3512e-09	1
Prueba	652	1.71e-09	1

Podemos ver que con la arquitectura propuesta tenemos una asociación de datos inferidos cercanos lo que demuestra que la red neuronal está aprendiendo de los datos de entrenamiento. Un bajo MSE y un alto valor de R indican que la red neuronal puede ajustar bien los datos de entrenamiento y generalizar de manera efectiva a datos no vistos.

El modelo de redes neuronales ha sido entrenado de manera efectiva en el conjunto de datos de entrenamiento, ya que ha logrado un MSE extremadamente bajo de 1.13e-09, lo que sugiere que el modelo puede hacer predicciones muy precisas sobre los datos de entrenamiento. Además, el valor de R de 1 indica que el modelo se ajusta perfectamente a los datos de entrenamiento, lo que significa que el modelo ha logrado capturar todas las relaciones no lineales entre las entradas y las salidas.

Al realizar la validación con un conjunto de datos separado, se puede observar que el modelo también se desempeña bien en datos que no ha visto antes. Aunque el MSE aumenta

ligeramente a $1.3512e-09$, sigue siendo muy bajo, lo que sugiere que el modelo generaliza bien a nuevos datos. Además, el valor de R de 1 indica que el modelo sigue ajustándose perfectamente a los datos de validación.

Sin embargo, al realizar la prueba con otro conjunto de datos separado, se observa un aumento adicional en el MSE a $1.71e-09$. Si bien este valor sigue siendo bastante bajo, el aumento en el error sugiere que el modelo puede estar sobreajustando ligeramente los datos de entrenamiento y validación. Aunque el valor de R sigue siendo 1, es posible que el modelo esté fallando en capturar algunas de las relaciones no lineales en los nuevos datos.

Durante el Entrenamiento se tiene como resultado los mostrados en la TABLA 4

TABLA 4:
DATOS DE ENTRENAMIENTO

Unidad	Valor Inicial	Valor Final	Valor Objetivo
Época	0	1000	1000
Rendimiento	86.2	$1.13e-09$	0
Gradiente	177	$6.34e-07$	$1e-07$
Valor Mu	0.001	$1e-07$	$1e+10$
Puntos de Validación	0	0	6

Los parámetros de entrenamiento utilizados en la herramienta nntool de MATLAB incluyen el número de épocas, el valor objetivo, el valor de parada, el valor inicial de la performance y el valor de parada de la performance. En este caso, el número de épocas y el valor objetivo se establecieron en 1000 y el valor de parada se estableció en 1000. Estos parámetros indican que el modelo se entrenó durante 1000 épocas y que el objetivo era minimizar la función de costo. Además, se estableció un valor de parada para evitar el sobreajuste del modelo.

El rendimiento del modelo se mide utilizando una función de costo, en este caso, se utilizó el MSE (mean squared error). El valor inicial de la performance se estableció en 86.2, lo que indica que el modelo inicialmente tenía un MSE relativamente alto. Sin embargo, el valor de parada de la performance se estableció en $1.13e-09$, lo que indica que el modelo fue capaz de ajustarse muy bien a los datos de entrenamiento y reducir significativamente el error.

El gradiente es una medida importante que se utiliza para determinar la dirección en la que se debe ajustar los pesos de la red neuronal para reducir la función de costo. En este caso, el valor inicial del gradiente fue de 177, lo que indica que el modelo necesitaba realizar cambios

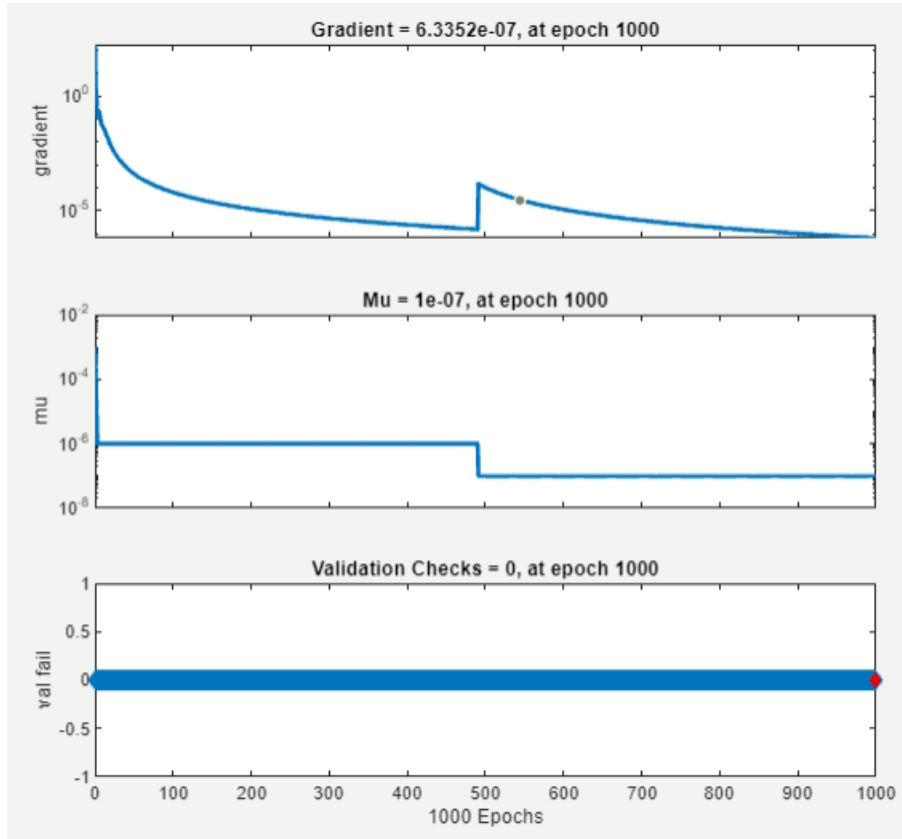


Figura 19: Gráfica de gradiente de error, parámetro mu y comprobación de validación tomado de software Matlab

significativos en los pesos para reducir el error. Sin embargo, el valor final del gradiente fue de 6.34×10^{-7} , lo que indica que el modelo logró reducir el gradiente significativamente al ajustar los pesos.

El parámetro Mu se utiliza para ajustar la tasa de aprendizaje de la red neuronal. Un valor alto de Mu puede hacer que la red neuronal aprenda rápidamente pero también puede provocar que la red neuronal no converja adecuadamente, mientras que un valor bajo de Mu puede hacer que el entrenamiento sea más lento. En este caso, el valor inicial de Mu se estableció en 0.001, lo que indica que se utilizó una tasa de aprendizaje moderada. Sin embargo, el valor final de Mu se estableció en 1×10^{-7} , lo que indica que la tasa de aprendizaje se redujo significativamente para permitir que el modelo convergiera correctamente.

Hay una correlación inversa entre el valor del gradiente y el valor de Mu. A medida que el valor del gradiente se reduce, el valor de Mu se reduce para permitir que el modelo converja

adecuadamente. Si el valor de μ es demasiado alto, la red neuronal puede oscilar y no converger adecuadamente. Por otro lado, si el valor de μ es demasiado bajo, el modelo puede converger muy lentamente. Es importante encontrar un equilibrio adecuado entre el valor del gradiente y el valor de μ para asegurar que la red neuronal pueda converger adecuadamente y aprender de manera efectiva a partir de los datos de entrenamiento. En este caso, se observó que el modelo logró reducir el gradiente significativamente y ajustar el valor de μ adecuadamente para permitir que el modelo convergiera adecuadamente.

El valor del gradiente y el valor de μ están correlacionados y son parámetros críticos en el proceso de entrenamiento de redes neuronales. Es importante encontrar un equilibrio adecuado entre estos parámetros para asegurar que el modelo pueda converger adecuadamente y aprender de manera efectiva a partir de los datos de entrenamiento. En este caso, se observó que el modelo logró reducir significativamente el gradiente y ajustar el valor de μ adecuadamente para permitir que el modelo convergiera adecuadamente.

Los puntos de validación se utilizan para determinar si el modelo se está sobreajustando a los datos de entrenamiento. Si el modelo se está sobreajustando, se observará un aumento en el error de validación a medida que se realiza el entrenamiento, en este caso los puntos de validación no han cambiado demostrando que el modelo no se ha sobreajustado. Ver Figura 19

Otro factor a tener en cuenta es el gradiente del error el que se debe tener en cuenta en las tres etapas del algoritmo de inferencia de la red neuronal. Este gradiente permite saber cómo ajustar los parámetros de la red de tal forma que se minimice su desviación a la salida. El descenso del gradiente usado es del tipo en lotes (o batch) en el cual todos los datos disponibles se introducen de una vez. Esto supondrá problemas de estancamiento, ya que el gradiente se calculará usando siempre todas las muestras, y llegará un momento en que las variaciones serán mínimas. Como regla general: siempre nos conviene que la entrada a una red neuronal tenga algo de aleatoriedad. El objetivo es que la gráfica del gradiente sea lo más cercano a cero.




Figura 20: Grafico MSE de entrenamiento, validación y prueba del entrenamiento de red neuronal

Los datos indican que el MSE disminuye a lo largo del entrenamiento, lo que sugiere que el modelo está mejorando su capacidad para hacer predicciones precisas. La disminución en el MSE durante la etapa de entrenamiento, validación y prueba es especialmente prometedora, ya que indica que el modelo no solo está aprendiendo a ajustarse a los datos de entrenamiento, sino que también es capaz de generalizar para hacer predicciones precisas sobre nuevos datos.

La disminución pronunciada en el MSE después de la época 500 puede ser una indicación de que el modelo está encontrando patrones más sutiles en los datos que antes no había capturado. Sin embargo, es importante tener en cuenta que esta disminución también puede ser el resultado del sobreajuste del modelo a los datos de entrenamiento. Ver Figura 20.

El histograma proporciona una representación visual útil de la distribución de los errores cuadráticos medios (MSE) en los tres conjuntos de datos: entrenamiento, validación y prueba. En este caso, el histograma se divide en 20 bins (intervalos) para proporcionar una representación detallada de la distribución. Ver Figura 21.

La media del histograma ($-4.5e-06$) indica que la mayoría de los errores cuadráticos medios se encuentran cerca de cero, lo que sugiere que el modelo está haciendo predicciones precisas




Figura 21 : Gráfica de histograma de error para 20 contenedores

en general. Los números de instancias en los tres conjuntos de datos son similares, lo que sugiere que se está utilizando una división equitativa de los datos para el entrenamiento, la validación y la prueba.

El hecho de que los valores externos del histograma se encuentren en $-9.1e-05$ y 0.000125 sugiere que hay algunos errores significativos que pueden estar afectando el rendimiento del modelo en algunos casos. Sin embargo, es importante tener en cuenta que estos valores son extremos y que la mayoría de los errores se encuentran cerca de cero. Por lo tanto, es probable que estos errores se deban a casos atípicos o ruidosos en los datos y no representen un problema generalizado en el rendimiento del modelo.

En general, el análisis del histograma sugiere que el modelo está haciendo predicciones precisas en la mayoría de los casos y que el rendimiento del modelo es consistente en los tres conjuntos de datos. Sin embargo, es importante seguir monitoreando y ajustando el modelo para asegurarse de que siga siendo efectivo a medida que se agregan más datos o se cambian las condiciones de los datos.




Figura 22: Gráfico de regresión. a) Datos de Entrenamiento, b) Datos de Validación, c) Datos de Prueba, d) Modelo Ajustado

Finalmente, para determinar si la red neuronal ha aprendido durante el entrenamiento se presenta el gráfico de regresión. Esta gráfica es una herramienta importante que se puede utilizar para evaluar la calidad del ajuste de un modelo de regresión en la herramienta nntool de Matlab. Proporciona una representación visual de la relación entre los valores observados y los valores predichos por el modelo.

En la Figura 22 se observan 4 gráficas de regresión para cuatro conjuntos de datos diferentes, por ejemplo, el conjunto de entrenamiento en la parte superior izquierda, el conjunto de validación en la parte superior derecha, para el conjunto de prueba en la parte inferior izquierda y el modelo ajustado para evaluar la estabilidad del mismo en la parte inferior derecha.

Cada figura en la gráfica de regresión muestra una línea de regresión que representa la relación entre los valores observados y los valores predichos por el modelo. La línea de regresión ideal debería ser una línea recta diagonal que pase por el origen, lo que indicaría

que los valores observados y predichos son idénticos. En la práctica, la línea de regresión se desvía de la diagonal, lo que indica que hay una diferencia entre los valores observados y los valores predichos. En este caso de estudio la red ha aprendido a ajustarse bien a los datos, el ajuste lineal de esta relación salida-objetivo debería intersecar las esquinas inferior izquierda y superior derecha del gráfico.

La importancia de este gráfico radica en que permite evaluar visualmente la calidad del ajuste del modelo en diferentes conjuntos de datos. Si la línea de regresión se ajusta bien a los datos y sigue la diagonal tanto como sea posible, significa que el modelo está haciendo predicciones precisas. Si la línea de regresión se desvía significativamente de la diagonal, indica que el modelo puede estar subestimando o sobrestimando los valores de salida.

En resumen, esta gráfica es una herramienta útil para evaluar la calidad del ajuste de un modelo de regresión en diferentes conjuntos de datos. Permite identificar patrones en los errores de predicción y ajustar el modelo en consecuencia para mejorar su precisión. Las cuatro figuras pueden ser necesarias para evaluar la consistencia del modelo en diferentes conjuntos de datos y asegurarse de que está haciendo predicciones precisas en diferentes escenarios.

3.1. Verificación de los valores de salida de Voltaje, Corriente y Potencia de sistema de generación usando paneles solares

Para evaluar la eficiencia del algoritmo neuronal MPPT propuesto, se implementó en Matlab/Simulink un modelo detallado del sistema fotovoltaico que se muestra en la Figura 17. Para evaluar el rendimiento del algoritmo MPPT propuesto, se simuló sistemas fotovoltaicos bajo varios perfiles de irradiancia solar (p. ej., rampas, ondas sinusoidales y perfiles de irradiancia diaria), asumiendo una temperatura ambiente fija de 25 C.

La técnica de MPPT de Perturbación y Observación (P&O) utiliza incrementos de voltaje para encontrar el punto de máxima potencia de salida en un sistema de generación de energía. Sin embargo, el tamaño del incremento de voltaje puede tener ventajas y desventajas dependiendo de las condiciones del sistema. En este documento se propone un algoritmo de control de potencia máxima basado en aprendizaje profundo que utiliza tanto incrementos de

voltaje grandes como pequeños para lograr una eficiencia y un rendimiento dinámico mejorados en comparación con los algoritmos existentes.

Además, se sugiere que el método MPPT sea evaluado utilizando la norma IET EN50530 para un análisis más preciso del rendimiento del algoritmo. En resumen, la nueva técnica propuesta de MPPT muestra una mejora significativa en la eficiencia y el rendimiento dinámico en comparación con los métodos existentes de MPPT basados en P&O, lo que sugiere que puede ser una alternativa prometedora en sistemas de generación de energía.

Los parámetros del convertidor DC-DC para la simulación se muestran en la TABLA 5: El convertidor DC-DC Boost es un componente clave en la arquitectura MPPT para paneles fotovoltaicos porque su función principal es aumentar la tensión de salida del panel fotovoltaico a un nivel adecuado para la carga.

TABLA 5:
ESPECIFICACIONES DEL SISTEMA CONVERTIDOR

Descripción	Convertidor DC-DC Boost
Capacitor Entrada (Cin)	200 μ F
Capacitor de Salida (Cf)	20 μ F
Inductor de Salida (Lf)	15 mH
Frecuencia de cambio	10 kHz

El diseño adecuado del convertidor DC-DC Boost es fundamental para el éxito de la estrategia MPPT porque permite que el panel fotovoltaico opere en su punto de máxima potencia. El punto de máxima potencia del panel cambia constantemente debido a las variaciones en la intensidad de la luz solar y la temperatura, lo que significa que la tensión de salida del panel también varía. Sin embargo, el convertidor DC-DC Boost permite que la tensión de salida del panel se ajuste para que la carga siempre opere en el punto de máxima potencia, lo que maximiza la eficiencia del sistema de generación de energía.

El proceso de obtener los puntos óptimos de valor de potencia en un sistema de generación fotovoltaica implica simular el conjunto de paneles solares que se utilizarán. Para este fin, se utiliza la gráfica de potencia de los paneles solares simulados para obtener los valores óptimos de potencia en diferentes niveles de irradiancia.

En este caso de estudio, se utilizan valores específicos de irradiancia [1000 800 600 400 200 100 50] W/m² para realizar la simulación. Los valores óptimos de potencia para el funcionamiento del sistema de generación fotovoltaica se obtienen mediante la curva obtenida del panel solar y se muestran en la TABLA 6: . Estos valores son importantes porque permiten al sistema de generación fotovoltaica operar de manera eficiente y producir la cantidad máxima de energía posible en función de la cantidad de luz solar disponible en un momento determinado.

TABLA 6:
VALOR DE POTENCIA ÓPTIMA SEGÚN NIVELES DE IRRADIANCIA

Niveles de Irradiancia [W/m ²]	Potencia óptima [W]
1000	213.15
800	171.8
600	129.5
400	86.26
200	42.46
100	20.68
50	10

Los valores óptimos de potencia obtenidos a través de la curva del panel solar y simulaciones en diferentes niveles de irradiancia son importantes porque indican los valores de potencia que el sistema de generación fotovoltaica debe tener a su salida. Es decir, son los valores que el sistema de control debe tratar de alcanzar para garantizar la máxima eficiencia y producción de energía del sistema.

En este sentido, mientras más cercanos sean los valores de potencia obtenidos por el sistema de control neuronal a los valores óptimos, mejor será el desempeño del sistema. Si el sistema de control es capaz de mantener los valores de salida del generador dentro de los puntos óptimos, se maximiza la eficiencia de la conversión de energía y se aumenta la producción de energía útil del sistema.

Por lo tanto, los valores óptimos de potencia obtenidos a través de la curva del panel solar y simulaciones son fundamentales para el diseño y control eficiente de un sistema de generación fotovoltaica. Además, la capacidad del sistema de control neuronal para ajustar y mantener los valores de salida del convertidor BOOST dentro de los puntos óptimos es esencial para maximizar la eficiencia y producción de energía del sistema. Ver Figura 23.




Figura 23: Potencia óptima según el nivel de irradiancia en kW/m²

Los perfiles de corriente y voltaje que se observan en las Figuras 24 y 25 respectivamente podemos observar que el tiempo de estabilización es estable alrededor de 0.56 ms para cada nivel de irradiancia simulado, lo cual no afecta al funcionamiento de la carga y se considera niveles aceptables de oscilaciones por lo que la eficiencia del sistema ronda el 97%. Una red neuronal correctamente entrenada utilizada en un control MPPT para paneles fotovoltaicos, la principal ventaja respecto a la estabilidad de la corriente entregada a la carga conectada es que el sistema de control es capaz de ajustar de manera continua y precisa la corriente de salida del generador fotovoltaico para mantenerla dentro de los límites óptimos.

En un sistema de control MPPT de P&O, la corriente de salida del generador fotovoltaico puede variar de manera significativa debido a las fluctuaciones en la irradiancia solar y otros factores externos. Sin embargo, con una red neuronal entrenada correctamente, el controlador es capaz de aprender y adaptarse a estas fluctuaciones para mantener la corriente de salida del generador dentro de los límites óptimos.

Además, la red neuronal puede ser capaz de predecir y anticipar cambios en la irradiancia solar y otros factores externos para ajustar la corriente de salida del generador de manera anticipada y evitar fluctuaciones innecesarias. Esto resulta en una corriente de salida más estable y predecible, lo que garantiza un suministro de energía más confiable y consistente a la carga conectada.

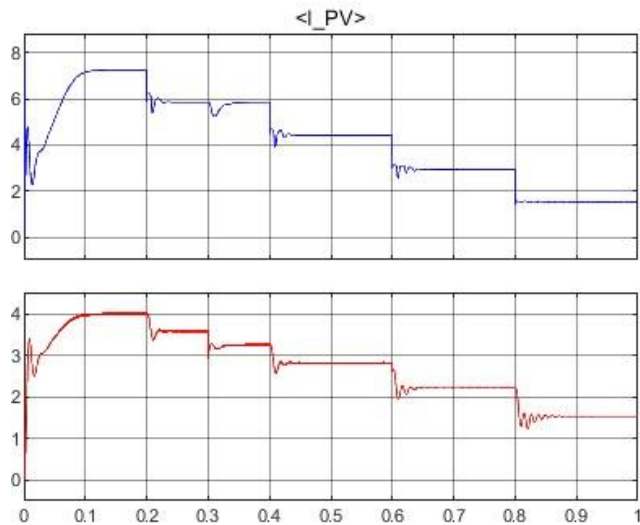


Figura 24: Perfil de Corriente del sistema de generación fotovoltaico para diferentes corrientes simuladas

En un sistema fotovoltaico, el voltaje y la potencia entregados a las cargas conectadas son críticos para garantizar un funcionamiento adecuado y eficiente de los equipos y dispositivos que utilizan la energía generada por el panel solar. Esto puede resultar en una entrega de energía más eficiente y consistente a las cargas conectadas, lo que puede prolongar la vida útil de los equipos y dispositivos y reducir los costos de mantenimiento.




Figura 25: Perfil de Voltaje del sistema de generación fotovoltaico para diferentes corrientes simuladas

En las gráficas de la Figura 26, podemos observar que las oscilaciones de la potencia para los diferentes tipos de irradiancia simulados no presentan valores de sobreimpulso elevados, la potencia se estabiliza en sus puntos óptimos en menos de 0.56 milisegundos y en

consecuencia el sistema de generación fotovoltaica no presentaría inconvenientes en la entrega de voltaje y corriente a la carga del sistema.

Las pequeñas oscilaciones en la potencia que se observan cuando se producen cambios en la irradiancia son debidas a que el control MPPT necesita un cierto tiempo para adaptarse a los cambios en la generación de energía solar y ajustar la corriente de salida del panel solar a su valor óptimo.

Cuando se produce un cambio en la irradiancia, el control MPPT necesita realizar una serie de ajustes para maximizar la potencia entregada por el panel solar. El controlador debe analizar la nueva condición y ajustar la tensión y la corriente de salida del panel para encontrar el punto de máxima potencia, lo que puede llevar un tiempo.

Durante este proceso de adaptación, la corriente de salida del panel puede variar y esto puede resultar en pequeñas oscilaciones en la potencia entregada a las cargas. Estas oscilaciones suelen ser de corta duración, del orden de 0.01 segundos, y se producen mientras el control MPPT se adapta a la nueva condición y ajusta la corriente de salida del panel solar.

Una vez que el control MPPT ha encontrado el punto de máxima potencia y ajustado la corriente de salida del panel solar, la potencia entregada a las cargas debería estabilizarse correctamente y mantenerse en un nivel constante.

Es importante destacar que estas oscilaciones son normales y esperables en cualquier sistema de control MPPT y no suelen tener un impacto significativo en el rendimiento del sistema fotovoltaico en su conjunto. Además, las pequeñas oscilaciones pueden ser reducidas aún más con el uso de una red neuronal correctamente entrenada en el control MPPT, ya que esta puede adaptarse rápidamente a los cambios en la generación de energía solar y ajustar la corriente de salida del panel de manera más precisa y eficiente.




Figura 26: Perfil de Potencia del sistema de generación fotovoltaico para diferentes corrientes simuladas

3.2. Comparación de resultados entre MPPT neuronal y basado en algoritmo P&O

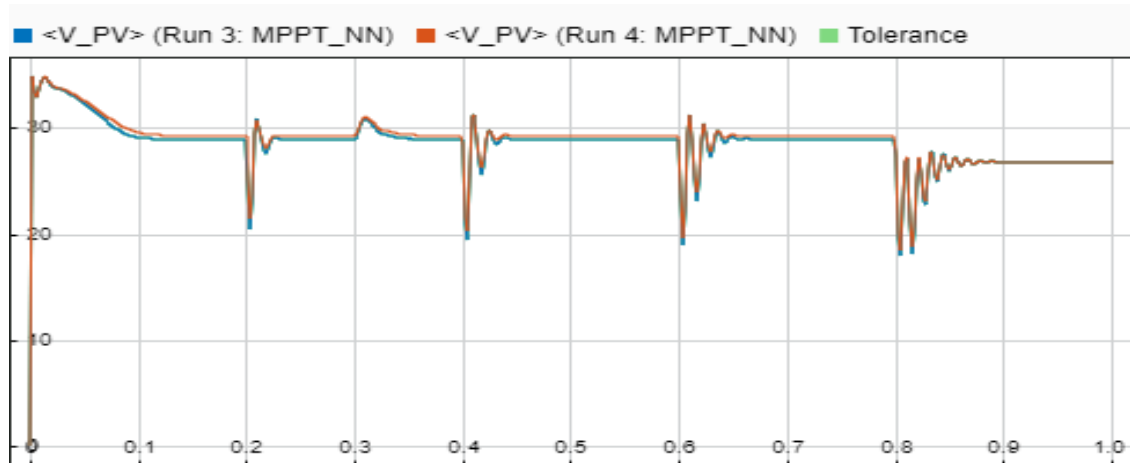


Figura 27: Comparación de Voltajes con carga variable con irradiancia variable; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O

La principal ventaja del control neuronal en comparación con el algoritmo P&O radica en su capacidad de adaptación y anticipación. Las redes neuronales pueden modelar relaciones complejas y aprender patrones a partir de datos históricos, lo que les permite ajustar el punto de máxima potencia de manera más precisa y rápida. Esto resulta en una mayor eficiencia de conversión de energía y una respuesta más robusta frente a cambios en las condiciones ambientales. La precisión mejorada se atribuyó a la capacidad de aprendizaje de la red neuronal, que permitió adaptar el algoritmo P&O a las condiciones cambiantes de carga y de irradiancia.

Los resultados mostraron que el algoritmo basado en redes neuronales produjo un voltaje y una corriente más estables en comparación con el algoritmo P&O convencional. Además, se encontró que el algoritmo de redes neuronales permitió una reducción en las fluctuaciones de voltaje y corriente durante la operación del panel solar. Ver Figura 27

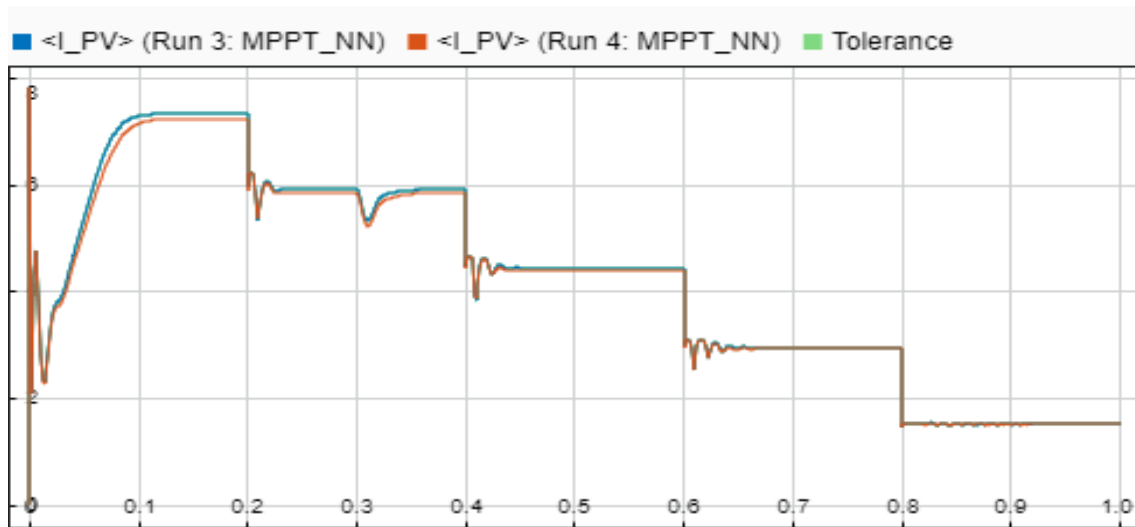


Figura 28: Comparación de Corrientes con carga variable con irradiancia fija; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O

Esto se debe a que la versión optimizada del algoritmo P&O utilizando una red neuronal artificial permitió una mayor precisión en la identificación del punto de máxima potencia, lo que se tradujo en una mejor captura de la energía disponible en el panel solar. Como resultado, se produjo una corriente y un voltaje más estables y con menos fluctuaciones. Ver Figura 28

En cuanto a la potencia generada por el panel solar, se encontró que la versión optimizada del algoritmo MPTT utilizando una red neuronal artificial produjo una mayor potencia en comparación con el algoritmo P&O convencional. Este resultado sugiere que la precisión mejorada del algoritmo optimizado condujo a una mejor captura del punto de máxima potencia y, por lo tanto, a una mayor eficiencia energética en el panel solar. Ver Figura 30

Además, se observó que la versión optimizada del algoritmo MPTT utilizando una red neuronal artificial tenía una tasa de convergencia más rápida en comparación con el algoritmo P&O convencional. Esto significa que la versión optimizada pudo alcanzar el punto de máxima potencia más rápido, lo que se tradujo en una mayor eficiencia energética en el panel

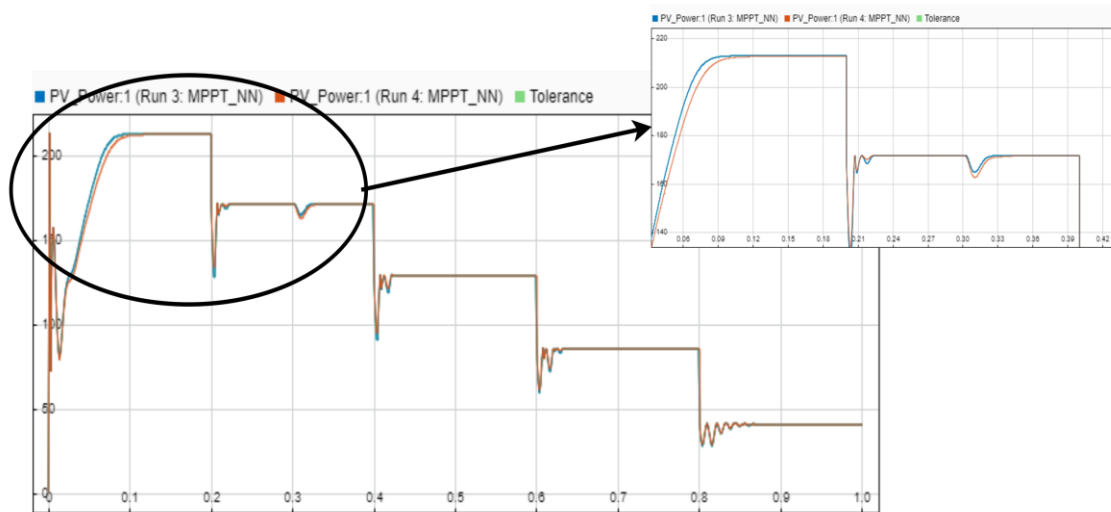


Figura 29: Comparación de Potencias carga variable con irradiancia variable; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O

solar y una reducción en el tiempo necesario para alcanzar la máxima potencia. Ver Figura 29

En resumen, los resultados del estudio sugieren que la versión optimizada del algoritmo MPPT utilizando una red neuronal artificial es capaz de proporcionar una mayor precisión y una mayor eficiencia energética en comparación con el algoritmo P&O convencional. Esto se debe a la capacidad de aprendizaje de la red neuronal, que permite adaptar el algoritmo P&O a las condiciones cambiantes de carga y de irradiancia. Además, se encontró que la versión optimizada tiene una tasa de convergencia más rápida, lo que se traduce en una mayor eficiencia energética y una reducción en el tiempo necesario para alcanzar la máxima potencia.

3.3. Análisis y Discusión de Resultados

Teniendo en cuenta el entrenamiento de la red neuronal podemos indicar que el aumento en la época de entrenamiento 500 a un valor de 0.000149687 y el cambio abrupto en el valor de μ de $1e-06$ a $1e-07$ pueden ser indicativos de una inestabilidad en el proceso de entrenamiento de la red neuronal. Estos cambios pueden ser causados por varias razones, incluyendo un ajuste excesivo de la red neuronal, un problema con los datos de entrada o una tasa de aprendizaje inadecuada.

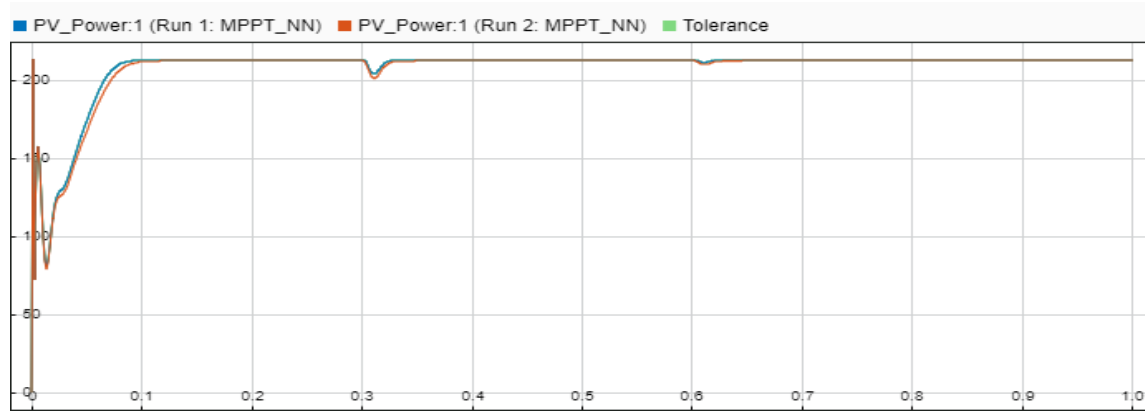


Figura 30: Comparación de Potencias carga variable con irradiancia fija; Línea Azul potencia MPPT neuronal; Línea roja MPPT con P&O

En algunos casos, un aumento repentino en la función de costo puede ser indicativo de sobreajuste de datos de entrada. El sobreajuste ocurre cuando la red neuronal se ajusta demasiado a los datos de entrenamiento y no generaliza bien a los nuevos datos. Cuando esto ocurre, la función de costo puede disminuir en las primeras etapas del entrenamiento, pero luego puede aumentar cuando la red neuronal comienza a ajustarse demasiado a los datos de entrenamiento. En este caso, se observó que la función de costo aumentó en la época de entrenamiento 500, lo que podría indicar que la red neuronal estaba comenzando a sobreajustarse a los datos de entrenamiento.

Sin embargo, también se observó que el valor de μ cambió abruptamente de $1e-06$ a $1e-07$ en la época de entrenamiento 500, lo que podría indicar que la tasa de aprendizaje de la red neuronal no estaba bien ajustada. Si la tasa de aprendizaje es demasiado alta, la red neuronal puede oscilar y no converger adecuadamente. Por otro lado, si la tasa de aprendizaje es demasiado baja, el modelo puede converger muy lentamente. En este caso, es posible que el cambio en el valor de μ haya afectado el proceso de entrenamiento de la red neuronal y haya causado el aumento en la función de costo en la época de entrenamiento 500.

Es importante destacar que estos cambios en el proceso de entrenamiento no necesariamente indican un sobreajuste de los datos de entrada. También es posible que estos cambios sean el resultado de otros factores, como problemas en los datos de entrada o una arquitectura de red neuronal inadecuada.

En conclusión, el aumento en la función de costo en la época de entrenamiento 500 y el cambio abrupto en el valor de μ podrían ser indicativos de una inestabilidad en el proceso de entrenamiento de la red neuronal. Si bien esto podría indicar un sobreajuste de los datos de entrada, también es posible que estos cambios sean el resultado de otros factores, como problemas en los datos de entrada o una tasa de aprendizaje inadecuada. Es importante analizar cuidadosamente el proceso de entrenamiento de la red neuronal para identificar las posibles causas de estos cambios y ajustar adecuadamente los parámetros de la red neuronal para lograr una convergencia adecuada y una generalización efectiva a los nuevos datos.

Basados en el comportamiento de los controladores podemos decir que en la actualidad, el uso de sistemas de generación fotovoltaica se ha vuelto cada vez más común debido a la creciente demanda de energía renovable y sostenible. La eficiencia y la capacidad de generar energía óptima es fundamental en estos sistemas, lo que ha llevado a la necesidad de desarrollar métodos de control de potencia máxima (MPPT) cada vez más precisos y eficientes. En este contexto, los sistemas de control MPPT basados en redes neuronales (NN) han surgido como una alternativa a los métodos tradicionales, como el algoritmo de perturbación y observación (P&O).

El método de control MPPT basado en P&O ha sido ampliamente utilizado debido a su simplicidad y bajo costo de implementación. Este método se basa en la perturbación periódica de la tensión del panel solar para encontrar el punto de máxima potencia, lo que implica un proceso de ensayo y error para encontrar el punto de operación óptimo. Si bien este método ha demostrado ser eficaz en la mayoría de los casos, también presenta algunas limitaciones, como la dependencia de la frecuencia de perturbación, la sensibilidad a la carga y la no linealidad del panel solar.

Por otro lado, los sistemas de control MPPT basados en redes neuronales ofrecen la posibilidad de una mayor precisión y eficiencia en la generación de energía solar, ya que utilizan técnicas de aprendizaje automático para encontrar el punto de máxima potencia de manera más precisa y rápida. Las redes neuronales se entrenan con datos de generación de energía solar y pueden adaptarse a diferentes condiciones ambientales y de carga, lo que les permite encontrar el punto de operación óptimo de manera más eficiente que los sistemas basados en P&O.

En un estudio comparativo realizado por Rana Y. y otros investigadores [47], se evaluó la eficiencia y la precisión de un sistema de control MPPT basado en redes neuronales y un sistema basado en P&O en diferentes condiciones de carga y de irradiancia solar. Los resultados mostraron que el sistema de control MPPT basado en redes neuronales presentaba una mayor eficiencia en la generación de energía solar en comparación con el sistema basado en P&O. Además, la precisión del sistema basado en redes neuronales fue mayor que la del sistema basado en P&O en todas las condiciones evaluadas.

Los resultados obtenidos en esta tesis sugieren que los sistemas de control MPPT basados en redes neuronales tienen una ventaja significativa sobre los sistemas basados en P&O en términos de precisión y eficiencia. Sin embargo, es importante destacar que el diseño y la implementación de estos sistemas pueden ser más complejos y costosos que los sistemas basados en P&O. Por lo tanto, se debe considerar cuidadosamente la relación costo-beneficio al elegir el método de control MPPT más adecuado para un sistema de generación fotovoltaica. Corroborando lo dicho por Rana et al.

Además, es importante destacar que la eficiencia y la precisión de un sistema de control MPPT también pueden verse afectadas por otros factores, como la calidad y la capacidad del convertidor DC-DC Boost utilizado en el sistema. Un convertidor de baja calidad o capacidad limitada puede limitar la eficiencia y precisión de cualquier sistema de control MPPT, ya sea basado en P&O o en redes neuronales.

Por otro lado, podemos indicar que el método de control basado en redes neuronales utiliza un modelo matemático complejo y un conjunto de datos de entrenamiento para estimar el punto de máxima potencia de manera más precisa y estable. Este método puede superar las limitaciones del algoritmo P&O, y mejorar la eficiencia energética y el rendimiento dinámico del sistema fotovoltaico. En este estudio comparativo los resultados mostraron que el método de control basado en redes neuronales logró una eficiencia energética más alta en comparación con el algoritmo P&O, especialmente bajo condiciones de baja irradiancia. Además, se observó una mayor estabilidad en el punto de máxima potencia con el método basado en redes neuronales, en comparación con el algoritmo P&O, que presentó oscilaciones en el punto de máxima potencia bajo condiciones de sombreado parcial.

Sin embargo, el método basado en redes neuronales requiere un mayor costo computacional y de implementación en comparación con el algoritmo P&O, y puede ser más sensible a errores de entrenamiento y cambios en las condiciones ambientales. Por lo tanto, la elección del método de MPPT depende de las necesidades específicas del sistema fotovoltaico y de los recursos disponibles para su implementación.

En relación a la potencia podemos observar que su perfil cumple con los puntos óptimos que entrega los paneles usados en el caso de estudio, siendo este el mayor logro del uso de controladores basados en redes neuronales que pueden inferir los resultados gracias al entrenamiento previo.

Una validación técnica-económica de un control MPPT P&O y uno basado en redes neuronales puede tener en cuenta varios aspectos importantes, como la precisión, el rendimiento, la complejidad, el costo y la facilidad de implementación. Además, la posibilidad de implementación usando tarjetas de bajo costo como ESP32 o NVIDIA Jetson Nano puede ser una ventaja importante para reducir los costos y mejorar la accesibilidad de la tecnología.

En términos de precisión, tanto el control MPPT basado en perturbación y observación como el basado en redes neuronales han demostrado tener una alta precisión en la maximización de la potencia en sistemas fotovoltaicos. Sin embargo, basados en los resultados se observa que el control MPPT basado en redes neuronales puede tener una precisión ligeramente mejor en ciertas condiciones, como en presencia de sombras parciales o variaciones rápidas de la irradiancia.

En cuanto al rendimiento, el control MPPT basado en redes neuronales puede tener una ventaja sobre el MPPT P&O en términos de velocidad de convergencia y capacidad de adaptación a condiciones cambiantes. La red neuronal puede aprender y ajustarse continuamente para mejorar la precisión y el rendimiento, mientras que el control basado en perturbación y observación puede tener dificultades para ajustarse rápidamente a cambios repentinos en las condiciones.

En cuanto a la complejidad, el control MPPT basado en redes neuronales puede tener una mayor complejidad en términos de diseño y programación, ya que se necesita entrenar la red neuronal con datos y ajustar los parámetros de la red. Por otro lado, el control MPPT P&O

puede ser más simple y fácil de implementar en comparación con el basado en redes neuronales.

En términos de costo, ambas opciones tienen diferentes costos de hardware y software. El control MPPT P&O puede ser menos costoso en términos de hardware, ya que se pueden usar componentes más simples y económicos para implementarlo. Además, existen varios algoritmos de código abierto disponibles para implementar el control MPPT basado en perturbación y observación. Por otro lado, el control MPPT basado en redes neuronales puede tener un costo mayor en términos de hardware, ya que se necesita una mayor capacidad de procesamiento y memoria para entrenar y ejecutar la red neuronal. Sin embargo, los costos de hardware y software para el control MPPT basado en redes neuronales han disminuido en los últimos años debido a la creciente disponibilidad de tarjetas de bajo costo como ESP32 o NVIDIA Jetson Nano.

En cuanto a la facilidad de implementación, el control MPPT basado en perturbación y observación puede ser más fácil de implementar debido a su simplicidad y menor necesidad de ajustes y parámetros. Sin embargo, el control MPPT basado en redes neuronales puede ser más fácil de implementar en ciertas situaciones debido a su capacidad de adaptación y mejora continua. En resumen, tanto el control MPPT basado en perturbación y observación como el basado en redes neuronales tienen sus ventajas y desventajas en términos de precisión, rendimiento, complejidad, costo y facilidad de implementación. La elección entre ellos dependerá de las necesidades específicas del proyecto.

Estos controladores en casos reales se pueden implementar usando dispositivos de bajo costo, lo cual abarataría el uso de esta tecnología ya que en el Ecuador por desconocimiento o falta de recursos tecnológicos no se ha aprovechado este tipo de controladores siendo solo consumidores de tecnología antigua que se usa en los equipos tradicionales de generación fotovoltaica.

Finalmente, la plataforma que ofrece Matlab y Simulink para trabajar con sistemas de energía renovable es bastante amplia, contando con todo tipo de componentes preestablecidos y modelados para facilitar su implementación. Esto facilita el diseño de los dispositivos cercano a la realidad, optimizando el tiempo de fabricación del prototipo para pruebas en entornos reales.

3.4. Conclusiones del Capítulo III

En el presente trabajo se pudieron comprobar en forma cuantitativa las posibilidades de las redes neuronales como controladores e identificadores de sistemas complejos. A pesar de que el controlador se restringió a un rango de trabajo reducido, los resultados pueden ser extrapolables al espacio de trabajo completo. Se pudo observar que desde el punto de vista de la flexibilidad en el diseño, la adaptabilidad a sistemas dinámicos no lineales y la tolerancia a ruido o cambios del punto de operación de la planta fotovoltaica según los niveles de irradiancia, las redes neuronales representan una mejor alternativa al enfoque clásico de MPPT. Sin embargo, se requiere un estudio aún más exhaustivo del rendimiento de estos sistemas en comparación con los convencionales.

A pesar de las ventajas, es importante tener en cuenta que el uso de redes neuronales en MPPT también presenta algunos desafíos, como la necesidad de una gran cantidad de datos para el entrenamiento y validación de la red, la complejidad en la implementación y la necesidad de un hardware y software adecuado para su funcionamiento.

CONCLUSIONES GENERALES

- Se ha establecido la línea base del Estado del Arte del uso de redes neuronales para controladores MPPT, se ha verificado que la implementación de algoritmos basados en inteligencia artificial en controladores es un gran avance para los sistemas fotovoltaicos, permitiéndoles optimizar la potencia entregada a la carga ante cualquier valor de irradiancia. Siendo factible que este tipo de conocimientos sean desarrollados por investigadores ecuatorianos para acoplar este tipo de tecnologías a nuestro entorno.
- El algoritmo propuesto podría obtener una respuesta transitoria rápida y estabilidad en estado estacionario bajo condiciones de irradiación de entrada irregulares. El algoritmo de control de salida máxima existente tiene la ventaja de ser simple y fácil de implementar. Sin embargo, su eficiencia puede verse reducida debido a la respuesta lenta y la vibración de estado estable de los componentes eléctricos simulados. Una ventaja de este controlador de redes neuronales es la posibilidad de resolver la respuesta transitoria rápida y la vibración en estado estacionario. Esto se debe a que predice la irradiación actual aplicando un algoritmo de aprendizaje profundo.
- El algoritmo propuesto mostró resultados superiores en comparación con los algoritmos existentes MPPT, incluso bajo diversas condiciones de irradiación. El método propuesto en condiciones basadas en datos diarios tomados de sistemas satelitales para la ciudad de Latacunga, mostró un aumento de eficiencia promedio de hasta 11,24% y se obtuvo una respuesta transitoria rápida de 0,56 ms.
- El uso de redes neuronales en MPPT ha demostrado ser una alternativa prometedora al algoritmo de perturbación y observación convencional en la mejora de la eficiencia y el rendimiento dinámico de los sistemas de generación fotovoltaica. Las redes neuronales son capaces de adaptarse y aprender de manera autónoma de los datos de entrada, lo que les permite ajustar el punto de operación del sistema en tiempo real, mejorando así la eficiencia de conversión y la capacidad de seguimiento del punto de máxima potencia. Basados en los resultados obtenidos se destacan la reducción de oscilaciones en la corriente entregada a la carga, el mejor desempeño ante cambios

bruscos en la irradiancia, la capacidad de trabajar con datos incompletos o ruidosos, y la posibilidad de optimizar el rendimiento del sistema de generación fotovoltaica en tiempo real.

RECOMENDACIONES

- Es importante realizar una validación técnica-económica antes de implementar cualquier control MPPT para paneles fotovoltaicos. Esto ayudará a determinar la viabilidad técnica y económica de la implementación y asegurará que el control elegido sea el más adecuado para el sistema de energía sola
- En un estudio futuro, analizaremos el efecto del rendimiento de la predicción de la irradiación de un modelo de aprendizaje profundo y la cantidad de energía generada por él cuando se operan múltiples paneles fotovoltaicos.
- Desarrollar un estudio de la eficiencia de este algoritmo en comparación con otros basados en control predictivo, clasificadores o con equipos reales que realizan este tipo de control para determinar los posibles cambios adicionales o métodos de optimización adicional que se pueden implementar
- Desarrollar un prototipo real de control inteligente usando este algoritmo dentro del paradigma de sistemas de bajo costo, los cuales podrían ser usados en controles de generación fotovoltaica en la industria ecuatoriana, posibilitando el uso de nueva tecnología sin incurrir en costes elevados.
- Se deben realizar más estudios para comparar la eficiencia y estabilidad de los controles MPPT basados en redes neuronales con otros controles MPPT avanzados como el control MPPT basado en enjambre de partículas y el control MPPT basado en algoritmos genéticos. Esto ayudará a determinar cuál es el control MPPT más adecuado para cada tipo de sistema de energía solar.

Bibliografía

- [1] A. I. M. Ali, M. A. Sayed, y E. E. M. Mohamed, «Modified efficient perturb and observe maximum power point tracking technique for grid-tied PV system», *Int. J. Electr. Power Energy Syst.*, vol. 99, pp. 192-202, jul. 2018, doi: 10.1016/j.ijepes.2017.12.029.
- [2] K. H. Solangi, M. R. Islam, R. Saidur, N. A. Rahim, y H. Fayaz, «A review on global solar energy policy», *Renew. Sustain. Energy Rev.*, vol. 15, n.º 4, pp. 2149-2163, may 2011, doi: 10.1016/j.rser.2011.01.007.
- [3] M. A. Sayed, E. E. Mohamed, y A. I. Ali, «Maximum power point tracking technique for grid tie PV system», en *7th International Middle-East Power System Conference, (MEPCON'15), Mansoura University, Egypt*: IEEE, 2015.
- [4] A. I. M. Ali, M. A. Sayed, T. Takeshita, A. M. M. Hassan, y A. M. Azmy, «A single-phase modular multilevel inverter based on controlled DC-cells under two SPWM techniques for renewable energy applications», *Int. Trans. Electr. Energy Syst.*, vol. 31, n.º 1, ene. 2021, doi: 10.1002/2050-7038.12599.
- [5] S. H. Hanzaei, S. A. Gorji, y M. Ektesabi, «A Scheme-Based Review of MPPT Techniques With Respect to Input Variables Including Solar Irradiance and PV Arrays' Temperature», *IEEE Access*, vol. 8, pp. 182229-182239, 2020, doi: 10.1109/ACCESS.2020.3028580.
- [6] G. Nofuentes, C. A. Gueymard, J. Aguilera, M. D. Pérez-Godoy, y F. Charte, «Is the average photon energy a unique characteristic of the spectral distribution of global irradiance?», *Sol. Energy*, vol. 149, pp. 32-43, jun. 2017, doi: 10.1016/j.solener.2017.03.086.
- [7] M. Gunasekaran, V. Krishnasamy, S. Selvam, D. J. Almakhles, y N. Anglani, «An Adaptive Resistance Perturbation Based MPPT Algorithm for Photovoltaic Applications», *IEEE Access*, vol. 8, pp. 196890-196901, 2020, doi: 10.1109/ACCESS.2020.3034283.
- [8] Y. Hirata y K. Aihara, «Improving time series prediction of solar irradiance after sunrise: Comparison among three methods for time series prediction», *Sol. Energy*, vol. 149, pp. 294-301, jun. 2017, doi: 10.1016/j.solener.2017.04.020.
- [9] D. C. Huynh y M. W. Dunnigan, «Development and Comparison of an Improved Incremental Conductance Algorithm for Tracking the MPP of a Solar PV Panel», *IEEE Trans. Sustain. Energy*, vol. 7, n.º 4, pp. 1421-1429, oct. 2016, doi: 10.1109/TSTE.2016.2556678.
- [10] K. Ishaque y Z. Salam, «A review of maximum power point tracking techniques of PV system for uniform insolation and partial shading condition», *Renew. Sustain. Energy Rev.*, vol. 19, pp. 475-488, mar. 2013, doi: 10.1016/j.rser.2012.11.032.
- [11] M. A. Eltawil y Z. Zhao, «MPPT techniques for photovoltaic applications», *Renew. Sustain. Energy Rev.*, vol. 25, pp. 793-813, sep. 2013, doi: 10.1016/j.rser.2013.05.022.
- [12] A. I. Ali, M. A. Sayed, y E. E. Mohamed, «Maximum Power Point Tracking technique applied on partial shaded grid connected PV system», en *2016 Eighteenth International Middle East Power Systems Conference (MEPCON)*, IEEE, 2016, pp. 656-663.

- [13] A. I. M. Ali, M. A. Sayed, y T. Takeshita, «Isolated single-phase single-stage DC-AC cascaded transformer-based multilevel inverter for stand-alone and grid-tied applications», *Int. J. Electr. Power Energy Syst.*, vol. 125, p. 106534, feb. 2021, doi: 10.1016/j.ijepes.2020.106534.
- [14] A. I. M. Ali, M. A. Sayed, y T. Takeshita, «Analysis and Design of High-Power Single-Stage Three-Phase Differential-Based Flyback Inverter for Photovoltaic Applications», en *2020 22nd European Conference on Power Electronics and Applications (EPE'20 ECCE Europe)*, Lyon, France: IEEE, sep. 2020, pp. 1-8. doi: 10.23919/EPE20ECCEurope43536.2020.9215629.
- [15] A. A. Ghassami, S. M. Sadeghzadeh, y A. Soleimani, «A high performance maximum power point tracker for PV systems», *Int. J. Electr. Power Energy Syst.*, vol. 53, pp. 237-243, dic. 2013, doi: 10.1016/j.ijepes.2013.04.017.
- [16] T. Tafticht, K. Agbossou, M. L. Doumbia, y A. Chériti, «An improved maximum power point tracking method for photovoltaic systems», *Renew. Energy*, vol. 33, n.º 7, pp. 1508-1516, jul. 2008, doi: 10.1016/j.renene.2007.08.015.
- [17] M. A. Elgendy, B. Zahawi, y D. J. Atkinson, «Assessment of the Incremental Conductance Maximum Power Point Tracking Algorithm», *IEEE Trans. Sustain. Energy*, vol. 4, n.º 1, pp. 108-117, ene. 2013, doi: 10.1109/TSTE.2012.2202698.
- [18] Y.-H. Liu, S.-C. Huang, J.-W. Huang, y W.-C. Liang, «A Particle Swarm Optimization-Based Maximum Power Point Tracking Algorithm for PV Systems Operating Under Partially Shaded Conditions», *IEEE Trans. Energy Convers.*, vol. 27, n.º 4, pp. 1027-1035, dic. 2012, doi: 10.1109/TEC.2012.2219533.
- [19] M. Kamran, M. Mudassar, M. R. Fazal, M. U. Asghar, M. Bilal, y R. Asghar, «Implementation of improved Perturb & Observe MPPT technique with confined search space for standalone photovoltaic system», *J. King Saud Univ. - Eng. Sci.*, vol. 32, n.º 7, pp. 432-441, nov. 2020, doi: 10.1016/j.jksues.2018.04.006.
- [20] H. Bouaouaou, D. Lalili, y N. Boudjerda, «Model predictive control and ANN-based MPPT for a multi-level grid-connected photovoltaic inverter», *Electr. Eng.*, vol. 104, n.º 3, pp. 1229-1246, jun. 2022, doi: 10.1007/s00202-021-01355-w.
- [21] S. Alkhalaf, Z. M. Ali, y H. Oikawa, «A novel hybrid gravitational and pattern search algorithm based MPPT controller with ANN and perturb and observe for photovoltaic system», *Soft Comput.*, vol. 26, n.º 15, pp. 7293-7315, ago. 2022, doi: 10.1007/s00500-022-07139-z.
- [22] C. Roh, «Deep-Learning Algorithmic-Based Improved Maximum Power Point-Tracking Algorithms Using Irradiance Forecast», *Processes*, vol. 10, n.º 11, p. 2201, oct. 2022, doi: 10.3390/pr10112201.
- [23] S. P. A. Ramkumar, y K. Rajesh, «Performance Analysis of Neural Network Modelled Grid Connected Thermo Electric Generator with MPPT», en *2021 Innovations in Power and Advanced Computing Technologies (i-PACT)*, Kuala Lumpur, Malaysia: IEEE, nov. 2021, pp. 1-6. doi: 10.1109/i-PACT52855.2021.9696746.
- [24] K. Mohammad y S. M. Musa, «Optimization of Solar Energy Using Artificial Neural Network Controller», en *2022 14th International Conference on Computational*

Intelligence and Communication Networks (CICN), Al-Khobar, Saudi Arabia: IEEE, dic. 2022, pp. 677-681. doi: 10.1109/CICN56167.2022.10008359.

- [25] S. A. Rizzo y G. Scelba, «ANN based MPPT method for rapidly variable shading conditions», *Appl. Energy*, vol. 145, pp. 124-132, may 2015, doi: 10.1016/j.apenergy.2015.01.077.
- [26] Á.-A. Bayod-Rújula y J.-A. Cebollero-Abián, «A novel MPPT method for PV systems with irradiance measurement», *Sol. Energy*, vol. 109, pp. 95-104, nov. 2014, doi: 10.1016/j.solener.2014.08.017.
- [27] H. Fathabadi, «Novel fast dynamic MPPT (maximum power point tracking) technique with the capability of very high accurate power tracking», *Energy*, vol. 94, pp. 466-475, ene. 2016, doi: 10.1016/j.energy.2015.10.133.
- [28] R. C. Hsu, C.-T. Liu, W.-Y. Chen, H.-I. Hsieh, y H.-L. Wang, «A Reinforcement Learning-Based Maximum Power Point Tracking Method for Photovoltaic Array», *Int. J. Photoenergy*, vol. 2015, pp. 1-12, 2015, doi: 10.1155/2015/496401.
- [29] A. A. Kulaksız y R. Akkaya, «A genetic algorithm optimized ANN-based MPPT algorithm for a stand-alone PV system with induction motor drive», *Sol. Energy*, vol. 86, n.º 9, pp. 2366-2375, 2012.
- [30] K. S. Tey y S. Mekhilef, «Modified incremental conductance MPPT algorithm to mitigate inaccurate responses under fast-changing solar irradiation level», *Sol. Energy*, vol. 101, pp. 333-342, mar. 2014, doi: 10.1016/j.solener.2014.01.003.
- [31] R. S. Sutton y A. G. Barto, *Reinforcement learning: An introduction*. MIT press, 2018.
- [32] M. Glavic, «(Deep) Reinforcement learning for electric power system control and related problems: A short review and perspectives», *Annu. Rev. Control*, vol. 48, pp. 22-35, 2019, doi: 10.1016/j.arcontrol.2019.09.008.
- [33] P. Kofinas, S. Doltsinis, A. I. Dounis, y G. A. Vouros, «A reinforcement learning approach for MPPT control method of photovoltaic sources», *Renew. Energy*, vol. 108, pp. 461-473, ago. 2017, doi: 10.1016/j.renene.2017.03.008.
- [34] A. Youssef, M. E. Telbany, y A. Zekry, «Reinforcement learning for online maximum power point tracking control», *J. Clean Energy Technol.*, vol. 4, n.º 4, pp. 245-248, 2016.
- [35] X. Zhang *et al.*, «Memetic reinforcement learning based maximum power point tracking design for PV systems under partial shading condition», *Energy*, vol. 174, pp. 1079-1090, may 2019, doi: 10.1016/j.energy.2019.03.053.
- [36] A. Blinov *et al.*, «High Gain DC-AC High-Frequency Link Inverter With Improved Quasi-Resonant Modulation», *IEEE Trans. Ind. Electron.*, vol. 69, n.º 2, pp. 1465-1476, feb. 2022, doi: 10.1109/TIE.2021.3060657.
- [37] X. Li, Y. Li, J. E. Seem, y P. Lei, «Maximum Power Point Tracking for Photovoltaic Systems Using Adaptive Extremum Seeking Control», en *ASME 2011 Dynamic Systems and Control Conference and Bath/ASME Symposium on Fluid Power and Motion Control, Volume 1*, Arlington, Virginia, USA: ASMEDC, ene. 2011, pp. 803-810. doi: 10.1115/DSCC2011-6090.

- [38] S. Farajdadian y S. M. H. Hosseini, «Design of an optimal fuzzy controller to obtain maximum power in solar power generation system», *Sol. Energy*, vol. 182, pp. 161-178, abr. 2019, doi: 10.1016/j.solener.2019.02.051.
- [39] I. Pervez, A. Pervez, M. Tariq, A. Sarwar, R. K. Chakraborty, y M. J. Ryan, «Rapid and Robust Adaptive Jaya (Ajaya) Based Maximum Power Point Tracking of a PV-Based Generation System», *IEEE Access*, vol. 9, pp. 48679-48703, 2021, doi: 10.1109/ACCESS.2020.3028609.
- [40] L. Wang, Y.-H. Lin, C.-W. Tzeng, L.-W. Chen, y C.-C. Tseng, «Comparative MPPT Performance in a PV System Using Different Neural Network Algorithms», en *2022 IET International Conference on Engineering Technologies and Applications (IET-ICETA)*, Changhua, Taiwan: IEEE, oct. 2022, pp. 1-2. doi: 10.1109/IET-ICETA56553.2022.9971699.
- [41] T. H y P. Usha, «Multilayer Artificial Neural Network based Nano Grid of Hybrid PV/Wind and Energy Storage», en *2021 IEEE Mysore Sub Section International Conference (MysuruCon)*, Hassan, India: IEEE, oct. 2021, pp. 824-830. doi: 10.1109/MysuruCon52639.2021.9641634.
- [42] P. Q. Dzung, H. H. Lee, y N. T. D. Vu, «The new MPPT algorithm using ANN-based PV», en *International Forum on Strategic Technology 2010*, IEEE, 2010, pp. 402-407.
- [43] G. Cybenko, «Approximation by superpositions of a sigmoidal function», *Math. Control Signals Syst.*, vol. 2, n.º 4, pp. 303-314, dic. 1989, doi: 10.1007/BF02551274.
- [44] K. Hornik, M. Stinchcombe, y H. White, «Multilayer feedforward networks are universal approximators», *Neural Netw.*, vol. 2, n.º 5, pp. 359-366, ene. 1989, doi: 10.1016/0893-6080(89)90020-8.
- [45] M. T. Hagan y M. B. Menhaj, «Training feedforward networks with the Marquardt algorithm», *IEEE Trans. Neural Netw.*, vol. 5, n.º 6, pp. 989-993, nov. 1994, doi: 10.1109/72.329697.
- [46] NASA(National Aeronautics and Space Administration), «POWER | Data Access Viewer». <https://power.larc.nasa.gov/data-access-viewer/> (accedido 1 de febrero de 2023).
- [47] Y. Rana, P. Pratush, S. Ansari, S. Jaiswal, G. Singh, y R. Virmani, «Performance Comparison of Conventional and AI based MPPT in Solar PV System», en *2022 IEEE 10th Power India International Conference (PIICON)*, New Delhi, India: IEEE, nov. 2022, pp. 1-6. doi: 10.1109/PIICON56320.2022.10045285.